

Desentrañando la fijación de precios de activos con IA: una literatura sistemática Revisar

Yan Chena , Lin Zhanga , Zhilong Xieb , Wenjie Zhangb , Qing Lib,

aEscuela de Finanzas, Universidad de Finanzas del Suroeste y
Economía, Chengdu, 611130, Sichuan, China

bFintech Innovation Center, Universidad del Suroeste de Finanzas y
Economía, Chengdu, 611130, Sichuan, China

Abstracto

La valoración de activos, un elemento fundamental de los estudios financieros reconocido con múltiples Premios Nobel de Economía, está experimentando una transformación con la integración de la inteligencia artificial (IA). Esta revisión sistemática de 782 artículos ilustra la convergencia de las finanzas y la informática, ofreciendo nuevas perspectivas sobre las complejidades de la valoración de activos. En concreto, primero explora los factores que influyen en la valoración de activos y examina diversos modelos econométricos y de aprendizaje automático desde perspectivas financieras e informáticas. Finalmente, presenta una plataforma pública de pruebas, el proyecto FactorWiki, con el objetivo de proporcionar un amplio conjunto de datos que ayude a los investigadores a analizar, evaluar y comprender modelos innovadores. Más importante aún, se aportan tres perspectivas únicas para impulsar los estudios en esta área: los factores de series temporales que influyen en la valoración de activos son muy ruidosos, lo que requiere una mayor atención a la ingeniería de características; la incorporación de teorías económicas fundamentales para fortalecer la relevancia y robustez de los modelos financieros; y la mejora de la interpretabilidad de los modelos de aprendizaje profundo en finanzas para aumentar su utilidad tanto para profesionales del sector como para académicos. Al centrarnos en estas prioridades, el objetivo es catalizar avances significativos en la fijación de precios de los activos, aprovechando el aprendizaje automático para impulsar potencialmente desarrollos innovadores.

Palabras clave: valoración de activos, aprendizaje automático, aprendizaje profundo, predicción de acciones, modelo econométrico

Autor correspondiente.

1

1. Introducción

La fijación de precios de activos, un área importante dentro del campo de las finanzas, ha ganado considerable atención y reconocimiento, ejemplificado por el Premio Nobel de Economía otorgado a cuatro economistas por sus contribuciones en este ámbito, es decir, Harry M. Markowitz (1990), William F. Sharpe (1990), Robert F. Engle (2003) y Eugene F. Fama (2013). La llegada de la IA está revolucionando el campo de la valoración de activos. Inicialmente, las finanzas y la informática siguieron trayectorias distintas en la investigación de este tema. La investigación financiera se ha dedicado a deconstruir el mecanismo de los activos.

La fijación de precios, comenzando por las causas que llevan a la fijación de precios e identificando los factores clave que determinan los precios de los activos [1, 2]. Por el contrario, los enfoques informáticos adoptan una perspectiva integradora, integrando factores clave seleccionados en modelos de aprendizaje automático, con especial énfasis en la precisión y confiabilidad del modelo para pronosticar el stock movimientos [3, 4].

La reciente intersección de las finanzas y la informática en el ámbito de los activos. Los precios se han vuelto cada vez más pronunciados. El sector financiero está demostrando un creciente interés en aprovechar grandes cantidades de datos y sofisticadas técnicas de aprendizaje automático, originadas en la informática, para profundizar en cómo diversos factores influyen en el precio de los activos. Dos destacados artículos académicos publicados en la prestigiosa revista *Journal of Financial Economics* ha contribuido significativamente a este estudio orientado a los datos. Enfoque. Calomiris y Mamaysky implementaron un análisis de informes de noticias de 51 países que abarcan el período de 1998 a 2015 [5]. Su objetivo era predecir riesgos y rentabilidad en los mercados bursátiles, y los resultados fueron prometedores. En otro estudio, Jeon et al. acumularon un conjunto de datos exhaustivo que comprende 21 millones de artículos de noticias relacionados con más de 9000 empresas que cotizan en bolsa y descubrieron una cantidad sustancial de correlación entre el rendimiento de las acciones y la tasa de flujo de noticias [6]. Pasando a la máquina de aprendizaje, un artículo innovador de Gu et al. publicado en la respetada *La Revisión de Estudios Financieros* examinó la influencia de 94 factores en las fluctuaciones del mercado utilizando una variedad de modelos de aprendizaje automático. Su investigación determinó que las técnicas de aprendizaje automático son superiores a los modelos econométricos convencionales [7]. Estudio posterior de Leippold et al., publicado en el *Journal of Financial Economics*, se hicieron eco de estos hallazgos [8]. Cabe destacar que ambas revistas gozan de gran prestigio en la disciplina financiera. En otras palabras, los estudios de Gu et al. y Leippold et al. fueron pioneros en el campo de las finanzas, introduciendo y utilizando redes neuronales BP como un paradigma de investigación para la fijación de precios de activos en los mercados de EE. UU. y China, respectivamente. Su trabajo destacó fundamentalmente el potencial de incorporar... Técnicas de IA en la investigación financiera clásica.

Por otro lado, el campo de la informática ha reconocido las características únicas de los factores clave del mercado de valores. En consecuencia, ha habido un cambio perceptible en el diseño de modelos de aprendizaje automático, alejándose de la replicación de modelos establecidos de otros dominios hacia el desarrollo de modelos específicos de finanzas que tienen en cuenta las características únicas de los datos financieros. Este cambio es evidente en la evolución del aprendizaje automático (ML) clásico basado en modelos como el vecino más cercano (KNN) [3], árboles de decisión [9] y máquinas de vectores de soporte [10] hasta modelos más sofisticados basados en aprendizaje profundo, como el convolucional. Redes neuronales (CNN) [11], memoria a largo plazo (LSTM) [12] y redes neuronales gráficas (GNN) [13]. Por ejemplo, Li et al. propusieron una LSTM basada en eventos. modelo y subrayó su importancia para abordar desafíos como el ruido o el muestreo. desequilibrio en datos heterogéneos de múltiples fuentes en el mercado de valores. [12]. De manera similar, Feng et al. desarrollaron un gráfico temporal CNN que incorpora la evolución temporal de las acciones y las redes relacionales, lo que da como resultado predicciones más precisas relacionadas al mercado de valores[13].

La exploración de los precios de los activos ha despertado la curiosidad de los académicos tanto en Finanzas e informática. La figura 1 ilustra el volumen de artículos académicos publicados en estos sectores durante las últimas dos décadas. Inicialmente, la mayoría de los activos La investigación de precios se centró en el sector financiero. Sin embargo, con la progresión En el campo de la tecnología informática, los investigadores en ciencias de la computación han comenzado a hacer más contribuciones, lo que ha llevado a un aumento reciente en su producción de publicaciones, superando esa de finanzas. Cuando se observa colectivamente, el recuento total de publicaciones en los últimos Veinte años es comparable en ambos campos. Este documento proporciona una visión completa Revisión de 782 artículos académicos. Las contribuciones únicas de este estudio son las siguientes: Sigue:

- Se reconocen tres amplias categorías de factores clave en la determinación del precio de los activos: los fundamentos de la empresa y los indicadores macroeconómicos, la información de los medios de comunicación, y el estado de las empresas relevantes. Con base en estos factores, hemos desarrollado una plataforma conocida como FactorWiki que proporciona 1.231 factores clave en tiempo real

¹Acceda a un recurso valioso en <http://quantplus.zxlearn.cn/Achievement>. Este sitio ofrece una amplia gama de información derivada de estos artículos de investigación. Este sistema ha sido diseñado para agilizar el proceso de búsqueda y recuperación de artículos pertinentes, categorizándolos según...

sobre diversos factores y modelos clave relacionados con la determinación del precio de los activos. Además, incluye Diagramas interactivos y ayudas visuales para mejorar la comprensión de los artículos, permitiendo a los usuarios para extraer información valiosa e identificar tendencias significativas relacionadas con la predicción de acciones.

²Accesible en <https://factorwiki.zxlearn.cn/factor>. Este sitio web ofrece conjuntos de datos que pueden ser descargados directamente, junto con una interfaz de programación de aplicaciones (API) de Python, lo que permite




Figura 1: Descripción general de la publicación.

Determinación del precio de los activos que otros investigadores pueden utilizar como recurso fundamental para sus investigaciones. También incluye una función de conversión de texto a SQL basada en modelos de lenguaje extensos, que ayuda a los inversores a consultar y analizar oportunidades de inversión utilizando lenguaje natural en lugar de comandos SQL. La plataforma no solo agiliza el inicio de las investigaciones en el campo de la predicción bursátil, sino que también establece un estándar para la evaluación y verificación equitativas de nuevos modelos y algoritmos en este campo.

- La investigación enfatiza la fusión de las finanzas y la informática en el ámbito de la fijación de precios de activos, con un enfoque particular en el papel del aprendizaje automático. Se ofrece una revisión exhaustiva de diversos modelos que encapsulan las relaciones entre los factores clave y los mercados bursátiles. Estos abarcan modelos econométricos en finanzas, junto con el aprendizaje automático clásico y modelos sofisticados de aprendizaje profundo en informática. Este análisis destaca el impacto significativo que los métodos avanzados de aprendizaje automático pueden tener en el futuro avance de la investigación sobre precios de activos. Además, se presentan clasificaciones de revistas e instituciones de investigación financieras y de informática basadas en la frecuencia de publicación y las citas de artículos relevantes. Estas clasificaciones son fundamentales para mantener a los investigadores actualizados e identificar posibles áreas de interés.

Se exploran posibles líneas de investigación y posibles caminos dentro del campo. Se sugiere que los estudios futuros prioricen la adquisición de un conocimiento profundo.

Los académicos pueden incorporar fácilmente llamadas a los conjuntos de datos directamente en sus códigos.

Comprensión de las características únicas intrínsecas de los datos del mercado financiero durante la fase de diseño del modelo. Simultáneamente, debe considerarse la integración de los principios económicos que rigen la dinámica del mercado bursátil en los modelos predictivos. Además, la interpretabilidad de los modelos predictivos, que podría revelar los mecanismos fundamentales del mercado, reviste una importancia fundamental para el progreso futuro. Al centrarse en estas prometedoras trayectorias de investigación, la fijación de precios de activos puede impulsarse eficazmente mediante el aprendizaje automático. Esto podría allanar el camino para descubrimientos significativos en este campo, quizás incluso merecedores de un reconocimiento académico considerable, como el Premio Nobel.

2. Factores clave en la determinación del precio de los activos

Inicialmente, los investigadores de las finanzas tradicionales emprendieron investigaciones empíricas para identificar los principales factores que influyen en la valoración de los activos. Analizaron minuciosamente tanto los fundamentos de las empresas como los indicadores macroeconómicos para comprender su impacto individual en el valor de los activos [14, 15, 16]. Esta investigación fundamental sentó las bases para la exploración sistemática de los determinantes críticos en la valoración de los precios de los activos. Posteriormente, con el desarrollo de las finanzas conductuales modernas, surgió la teoría de los "inversores irracionales", que postula que los sesgos cognitivos de los inversores y su racionalidad imperfecta pueden generar comportamientos de inversión emocionales, lo que afecta a los precios de las acciones. Como resultado de su significativa influencia en el "comportamiento irracional" de los inversores, la información de los medios de comunicación ha ganado gradualmente reconocimiento como un factor destacado en las finanzas convencionales [17, 5, 18, 19]. Sin embargo, estos estudios se han centrado principalmente en la información propia de la empresa, es decir, los fundamentos de la empresa y los indicadores macroeconómicos y la información de los medios de comunicación, mientras que descuidan las interacciones entre las empresas relevantes. En los últimos años, los estudios financieros han hecho esfuerzos para establecer una red firme para investigar el impacto del derrame de impulso en los precios de las acciones de empresas relacionadas [20, 21, 22]. En conclusión, se ha realizado una investigación exhaustiva de 782 artículos de investigación sobre este problema clásico en los campos de las finanzas y la informática. Se identificaron tres categorías principales de factores clave en la determinación del precio de los activos: 1) fundamentos de la empresa e indicadores macroeconómicos, 2) información de los medios de comunicación y 3) los estados de las empresas relevantes. La Tabla 1 proporciona un resumen de los estudios relevantes sobre los movimientos del mercado de valores en términos de los diferentes tipos de información de mercado.

- Fundamentos de las empresas e indicadores macroeconómicos: La exploración de la valoración de los activos, basada en la teoría financiera tradicional, postula que los precios reflejan valores fundamentales intrínsecos y factores económicos externos. Esto incluye métricas fundamentales específicas de cada empresa, como su tamaño y rentabilidad, así como indicadores macroeconómicos externos más amplios, como el PIB y

Tabla 1: Comparación de la literatura en términos de información de mercado.

Categoría	Literatura	Enfocar		Método de análisis		Experimento		
		Mercado	Predictor de respuesta de escala	Modelo	Periodo	Tamaño	Métrico	
Fundamentos de la empresa y macroeconómico indicadores	[23]	Nuevo Zelanda	Stock mensual índice	IPC, PIB, EM, ER, IR	GC, JMC	01/1990-01/2003	40 acciones	SS
	[24]	BRIC	Stock mensual índice	Tipo de cambio	ARIMA 03/1999-	06/2006	1.080 observaciones	SS
	[25]	S&P 500, Nikkei 225	Stock mensual índice	Descuento oficial tasa, industrial producción	VEC	01/1965-06/2005	Constituyente existencias	SS
	[15]	Bolsa de Nueva York	Stock mensual devolver	MKT, SMB, HML, RMW, CMA	Lineal modelo	07/1963-12/2013	606 meses	SS
Medios de comunicación de información	[17]	Bolsa Dow Jones	Día Existencias índice	DJIA, emoción	ANA	28/02/2008-19/12/2008	9 millón tuits	Exactitud
	[26]	CSI 100	Acciones de minutos precio	Artículos de noticias, emoción	Tensor modelo	01/01/2011-31/12/2011	89 acciones MAE	
	[27]	Bolsa de Nueva York	Día Existencias devolver	Emoción	Lineal modelo	01/01/1984-17/09/1999	3.709 observaciones	SS
	[28]	Día del S&P 500	Existencias devolver	Emoción, MKT, SMB, HML	Lineal modelo	1980-2004	500 acciones	SS
	[18]	Acciones del S&P 500 Minute	precio	Artículos de noticias	SVR	26/10/2005-26/11/2005	2.809 noticias artículos	SS
[5]	513 condados intentos	Stock mensual devolver	Artículos de noticias	Estadístico modelo	1996-2015	51 economías	SS	
Estados de importante empresas	[29]	CRSP	Stock mensual devolver	Momento de liquidez, impulso de la industria	Lineal modelo	1980-2004	11.484 observaciones	SS
	[22]	CRSP	Stock mensual devolver	Vinculado a la tecnología devolver	Lineal modelo	07/1963-06/2012	561.989 observaciones	SS
	[13]	Bolsa de Nueva York	Día Existencias devolver	Datos históricos del mercado de valores	LSTM, GCN	01/02/2013-12/08/2017	2.763 acciones MSE	
	[30]	Bolsa de Nueva York	Stock mensual devolver	Cobertura de analista compartida edad	Estadístico modelo	01/1984-12/2015	Todas las acciones	SS
	[31]	Día del S&P 500	Existencias devolver	5 relaciones firmes AD-	REVOLVER	02/08/2011-18/11/2013	198 acciones de la República Popular China	

Notas: En esta tabla, SS indica significancia estadística; BRIC indica Brasil, Rusia, India y China; PIB indica el PIB bruto. producto interno bruto; IPC indica el índice de precios al consumidor; MS indica la oferta monetaria; ER indica el tipo de cambio; IR indica la tasa de interés; GC indica la prueba de causalidad de Granger; JMC indica la prueba de cointegración multivariada de Johansen; ARIMA indica Modelo de media móvil integrado autorregresivo; VEC indica modelo de corrección de errores vectoriales; NYSE indica Bolsa de Valores de Nueva York Bolsa; CRSP indica el Centro de Investigación de Precios de Valores; DJIA indica el Promedio Industrial Dow Jones; ANN indica red neuronal artificial; CSI 100 indica el índice de valores chinos 100; MAE indica un error absoluto medio; SVR indica soporte modelo de regresión vectorial; GCN indica red convolucional gráfica; MSE indica error cuadrático medio; AD-GAT indica un Red de atención gráfica impulsada por atributos; PRC indica la curva de precisión-recuerdo.

La investigación fundamental de William F. Sharpe de 1964 estableció la relación lineal entre el riesgo de la cartera de mercado y los retornos esperados de las acciones, un hallazgo innovador que le valió el Premio Nobel de Economía [32, 33, 34]. Basándose en la fundación de Sharpe, Eugene F. Fama subrayó la importancia de métricas fundamentales, en particular el tamaño de la empresa (PYME) y los valores contables a mercado (HML), rentabilidad (RMW) y patrones de inversión (CMA), que fueron fundamentales para su reconocimiento del Premio Nobel [14, 15]. Investigaciones posteriores han Amplió estos conceptos para abarcar factores como el impulso [35] y el crecimiento.

[36], liquidez [37] y volatilidad [38]. Stephen A. Ross enfatizó además la impacto considerable de los indicadores macroeconómicos en los precios de las acciones, lo que ilustra cómo estas métricas, junto con factores específicos de la empresa, son vitales para determinar las tendencias del mercado [16]. Stephen A. Ross destacó el impacto sustancial de indicadores macroeconómicos sobre los precios de las acciones, que muestran que estas métricas, junto con factores específicos de cada empresa, desempeñan un papel crítico en la configuración de las tendencias del mercado [16]. Investigaciones posteriores identificaron que indicadores macroeconómicos significativos como como el PIB [39], la inflación [40], los tipos de interés [23], los tipos de cambio [24], el PNB [41], El IPC [25], las reservas oficiales [42] y la oferta monetaria [43] se encuentran entre los innumerables factores que influyen en la dinámica del mercado bursátil. Estas contribuciones académicas han establecido sistemáticamente la base teórica para la comprensión El impacto de los fundamentos de las empresas y los indicadores macroeconómicos. No obstante, La solidez de estas investigaciones se basa predominantemente en la quintaesencia supuestos de las finanzas tradicionales, como la hipótesis de la eficiencia del mercado [44], Supuesto de comportamiento racional [45] y supuesto de simetría de la información [46], que presentan limitaciones al extrapolarse a las vicisitudes de los mercados financieros reales. Los marcos financieros tradicionales a menudo fallan cuando se trata de... para tener en cuenta fenómenos específicos del mercado, como el impacto de las elecciones presidenciales elecciones en el precio de los activos ³ efectos del cambio de mes ⁴, y la determinación de los ⁵ rendimientos de la primera salida a bolsa. En respuesta, los investigadores modernos de finanzas conductuales están cambiando a explorar el impacto del sentimiento de los inversores en el mercado de valores, buscando... comprensión holística de las anomalías del mercado financiero.

- Información de los medios: En las finanzas conductuales modernas, el "inversor irracional" La teoría sugiere que los sesgos cognitivos y la racionalidad imperfecta de los inversores resultan en comportamientos de inversión emocionales, que a su vez influyen en el mercado de valores. movimientos [50]. En la era del uso generalizado de Internet, la rápida y extensa difusión de la información mediática se ha reconocido gradualmente. como un factor importante que incide en el comportamiento irracional de los inversores. En 2007, Tetlock et al. publicaron dos informes de investigación consecutivos en el Journal of Finanzas, presentando un análisis de noticias en el Wall Street Journal que abarcan

³Leblang y Mukherjee demuestran que las elecciones presidenciales afectan significativamente el mercado volatilidad y retornos, mostrando cómo los eventos políticos pueden influir en la dinámica del mercado de maneras que se extienden más allá de las predicciones de los modelos tradicionales [47].

⁴McConnell y Xu revelan que los rendimientos de las acciones suelen ser más altos en el cambio de mes, lo que presenta un patrón que desafía la hipótesis convencional del mercado eficiente [48].

⁵Baker y Wurgler destacan los importantes retornos del primer día de las IPO, un escenario que no se describe adecuadamente. capturados por modelos estándar basados en la eficiencia del mercado y el comportamiento racional de los inversores [49].

dos décadas, que corroboraron la utilización de información noticiosa para captar la influencia de los comportamientos irracionales de los inversores en los mercados de valores [27, 28].

En 2019, Calomiris y Mamaysky publicaron un artículo en el Journal of Financial Economics, revelando que las tendencias de movimiento del mercado podrían predecirse.

mediante el análisis de noticias financieras en 51 mercados bursátiles diferentes [5]. Estos tres

Los artículos han sentado las bases teóricas para comprender el efecto de

Medios de comunicación en el mercado de valores. Además, la investigación en informática ha aprovechado técnicas modernas de análisis de texto para extraer opiniones de expertos.

y el sentimiento público a partir de la información de los medios de comunicación para estudiar el impacto de medios de comunicación sobre los mercados bursátiles [17, 51, 3, 12, 18, 19, 26, 52, 53], lo que resulta en una práctica Valor para las prácticas empresariales. Por ejemplo, Das y Chen realizaron un trabajo pionero para examinar la relación entre la opinión pública sobre la discusión

tableros y mercados de valores [54], mientras que Zhang y Skiena extrajeron el sentimiento

Información de noticias, blogs y microblogs, proponiendo un enfoque orientado al sentimiento.

estrategia comercial [55]. Cabe destacar que Bollen et al. extrajeron los sentimientos públicos de los inversores de un conjunto de datos de 10 millones de tuits, revelando una correlación sorprendente entre el indicador de sentimiento "calma" y el movimiento del DJIA 3 o 4 días

Más tarde [17]. Además, calcularon una tasa de precisión del 86,7% para predecir

El Dow Jones Índice de Precios al Consumidor (DJIA). Estos notables resultados han llevado al establecimiento de tres instrumentos de cobertura. fondos, a saber, Derwent Capital, DCM Capital y Cayman Atlantic. Estos

Los fondos utilizan el análisis del índice de sentimiento de las redes sociales como herramienta para predecir el comportamiento de las acciones. movimientos del mercado.

- Estados de las empresas relevantes: Los estudios mencionados anteriormente se han centrado principalmente en analizar la influencia de la información histórica propia de una empresa en el movimiento de sus acciones. Sin embargo, en el mercado financiero real, el movimiento de las acciones de una empresa también se ve influenciado por las empresas relevantes, lo que se conoce como efecto de contagio del momentum. Efecto en las finanzas [30]. Investigaciones anteriores han identificado varios factores que contribuyen a la formación de conexiones empresariales relevantes, como la industria compartida. [56, 57], ubicación geográfica [58], vínculos en la cadena de suministro [29, 21], similitud tecnológica [22] u operar en segmentos similares [59]. Por ejemplo, nueva información que afectan a una empresa objetivo puede afectar el rendimiento de las acciones de las empresas aguas arriba y aguas abajo a lo largo de la cadena de suministro [29]. La similitud tecnológica ha demostrado fuerte poder predictivo de los retornos en este tipo de relación [22]. La cobertura de noticias también se ha identificado como un factor relevante, con precios de acciones relevantes empresas que presentan subidas y bajadas similares, particularmente durante las crisis del mercado [60]. Los académicos en el campo de la informática se han esforzado por construir una red de asociaciones corporativas que utilicen las relaciones corporativas antes mencionadas,

y han iniciado una investigación sobre los efectos de contagio del impulso en el Mercado de valores. Por ejemplo, Li et al. han empleado datos históricos de operaciones entre acciones para modelar una matriz dinámica de correlaciones entre acciones y conectar nodos de stock [61]. Li et al. han utilizado datos de revisión de stock para establecer establecer relaciones firmes y predecir la volatilidad de las acciones relacionadas considerando la dirección de la transmisión de información a lo largo de los bordes [62]. A pesar de los importantes esfuerzos, el desafío radica en construir eficazmente una empresa integral. red que incorpora estos factores.

En conclusión, la literatura existente sobre predicción de acciones se ha centrado principalmente sobre los fundamentos de las empresas y los indicadores macroeconómicos, la información de los medios de comunicación y la estados de las empresas relevantes. A través de una revisión exhaustiva de este estudio, se ha... Se estableció que 1231 factores han sido confirmados por expertos financieros como influyentes en el mercado de valores. La Figura 2 ilustra las tendencias en los artículos publicados a lo largo del tiempo. últimos 20 años, centrándose en el examen de tres factores clave distintos en el precio de los activos determinación. La exploración de la influencia de los fundamentos de las empresas y los indicadores macroeconómicos en los mercados bursátiles ha sido un área de investigación de larga data que ha experimentado un notable aumento de interés desde 2016. De manera similar, la investigación de La información de los medios de comunicación en relación con los mercados de valores ha suscitado un entusiasmo considerable entre los investigadores. Además, el avance de la tecnología de la información ha impulsó a los académicos a concentrarse cada vez más en el estudio del impacto del estatus de las empresas relevantes en el mercado de valores durante la última década. Basándose en el Según el conocimiento actual, las investigaciones futuras deberían investigar cómo las condiciones financieras y operativas de las empresas asociadas afectan el precio de los activos de las empresas objetivo. desentrañar la compleja dinámica intercorporativa que influye en las valoraciones del mercado. Esta exploración proporcionará nuevas perspectivas sobre la naturaleza interconectada de los mercados financieros contemporáneos.

De hecho, la accesibilidad a datos de mercado fiables y actualizados sigue siendo una desafío persistente en el campo de las finanzas modernas. En respuesta a este problema, Han desarrollado una plataforma integral de datos de factores denominada FactorWiki, que abarca 1.231 factores clasificados en tres tipos como se mencionó anteriormente y proporciona Actualizaciones en tiempo real. También cuenta con una función de conversión de texto a SQL impulsada por un lenguaje extenso. modelos, ayudando a los inversores a consultar y analizar oportunidades de inversión utilizando Lenguaje natural en lugar de comandos SQL. Esta plataforma sirve como un recurso valioso para que los académicos realicen investigaciones de manera eficiente y sirve como una vía fundamental para... Evaluar y validar nuevos algoritmos e innovaciones en el campo de la predicción bursátil. El objetivo principal de aprovechar la plataforma FactorWiki es contribuir A una comprensión más profunda de los factores multifacéticos que influyen en el mercado de valores. y promover el avance de la investigación sobre predicción de acciones.

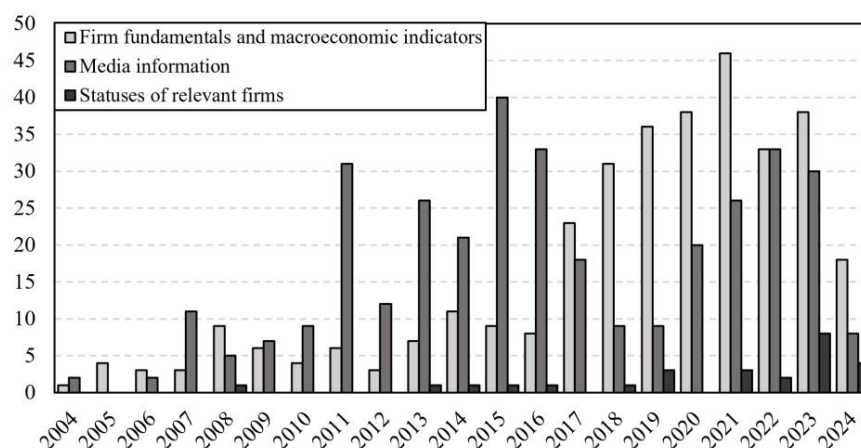


Figura 2: Tendencias de publicaciones según factores clave en la determinación del precio de los activos.

3. Modelo de análisis

En el sector financiero, el análisis cuantitativo del mecanismo del mercado bursátil es crucial para la fijación de precios de los activos. La investigación financiera se ha centrado en deconstruir el mecanismo interno de los movimientos bursátiles mediante modelos econométricos para explorar la causalidad entre diferentes factores clave y el mercado bursátil. En el ámbito de la informática, los métodos iniciales de predicción bursátil se basaban en técnicas clásicas de aprendizaje automático para examinar las influencias no lineales de diversos factores en la dinámica bursátil. Recientemente, se ha producido una notable transición hacia los modelos de aprendizaje profundo, que se distinguen por su eficacia en el análisis de series temporales, la captura de interacciones complejas entre factores y la identificación de los efectos de contagio del momentum. En consecuencia, el aprendizaje profundo se ha consolidado como el marco fundamental de los enfoques de modelado contemporáneos, estableciendo un nuevo estándar de precisión y conocimiento en el análisis de los mercados financieros. En esta sección, se presentarán los modelos econométricos en finanzas, seguidos de los modelos basados en aprendizaje automático en informática, incluido el aprendizaje automático clásico y el aprendizaje ⁶.

profundo. La Tabla 2 enumera los tres modelos típicos y sus resultados de investigación representativos. La Figura 3 presenta la tendencia de los modelos de análisis durante los últimos 20 años. Los modelos econométricos han sido durante mucho tiempo un foco de estudio y aplicación en finanzas, debido a su reconocida importancia en el campo. Los investigadores han mostrado un interés constante en los modelos clásicos basados en aprendizaje automático. Desde 2020, se ha observado un notable aumento en...

⁶Para obtener información detallada sobre estos modelos, consulte http://quantplus.zxlearn.cn/upload/achievementSource/ASC_Appendix.pdf.

El uso de modelos basados en aprendizaje profundo para el estudio del mercado bursátil. Este auge de popularidad se debe principalmente a la notable eficacia demostrada por los modelos LSTM para capturar las características inherentes de las series temporales de los mercados financieros. En consecuencia, ha surgido una considerable cantidad de investigación centrada en el desarrollo y la aplicación de modelos de aprendizaje profundo basados en LSTM.

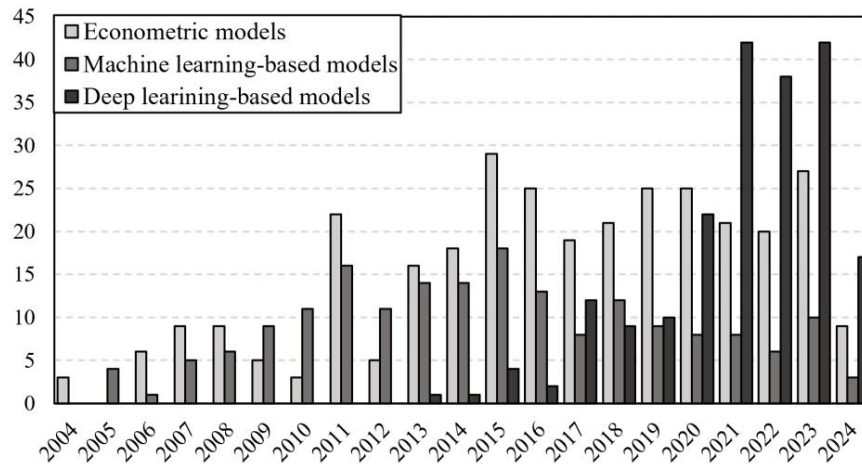


Figura 3: Tendencias de publicación por modelos de análisis.

3.1. Modelos econométricos

Los modelos econométricos son fundamentales en el análisis financiero, ya que van más allá de la correlación para descubrir relaciones causales que influyen en los precios de los activos. Ofrecen un marco estructurado para analizar la dinámica del mercado en la fijación de precios de los activos. Entre los modelos clave en este ámbito se incluyen el CAPM [32, 33, 34] y el modelo multifactorial [76, 14, 15], que proporcionan información sobre cómo los diferentes factores afectan los precios de los activos y la dinámica del riesgo y la rentabilidad. Para abordar las complejidades temporales de los datos financieros, se utilizan diversos modelos de series temporales, como el modelo autorregresivo (AR) [77], el modelo de media móvil (MA) [78], el modelo de media móvil autorregresiva (ARMA) [79] y el modelo de media móvil integrada autorregresiva (ARIMA) [65]. Además, el modelo de Heteroscedasticidad Condicional Autorregresiva (ARCH) [80] y el modelo de ARCH Generalizado (GARCH) [81] son cruciales para comprender y pronosticar la agrupación de la volatilidad en series temporales financieras, ofreciendo información valiosa para la gestión de riesgos y la valoración de derivados. La Figura 4 presenta una representación visual de la hoja de ruta de los modelos econométricos en el contexto de la valoración de activos.

En concreto, la introducción del modelo de media-varianza (MV) por parte de Harry M. Markowitz fue un momento crucial en las finanzas, al vincular el riesgo de la cartera con la varianza del rendimiento y establecer

Tabla 2: Comparación de la literatura en términos del modelo de análisis utilizado.

Categoría	Literatura	Enfocar		Método de análisis		Experimento				
		Mercado	Escala	Predictor de respuesta	Modelo	Periodo	Tamaño	Métrico		
Econométrico modelo	[1]	Acciones mensuales de AMEX		devolver	Tamaño de la empresa, edad, flujo de fondos	Correlación coeficientes	01/1983-12/2001	400.000 observaciones	SS	
	[63]	Día de AMEX		Existencias índice	Precio, rentabilidad, volumen	Bivariado análisis	01/07/2005-30/08/2007	19.807 cepo	Correlación	
	[64]	Acciones del mes de la Bolsa de Nueva York		devolver	MKT	CAPM	1926-1975	Índice	SS	
	[14]	Acciones mensuales de AMEX		devolver	MKT, PYMES, HML	Fama-Francés	1963-1991	acciones estadounidenses mercado	SS	
	[65]	26 países	Stock mensual	devolver	Tasa de inflación	ARIMA	01/1947-12/1979	26 índices bursátiles	SS	
Clásico Basado en ML modelos	[66]	Atenas	Día	Existencias índice	Precios, indicadores técnicos	lógica difusa tecnología	15/11/1996-06/05/2012	Índice	SS	
	[67]	CRSP	Cuarto de acción		devolver	Beneficio, valor, Relación precio-beneficio	Bayes ingenio modelo	1994-2007	145.479 observaciones	SS
	[68]	India Dow Jones	Día	Existencias índice	Emoción	SVM, SOFNN	2015-2018	476 millones tuits	Exactitud	
	[69]	Brasil	Acciones de minutos		precio	Precio, volumen	LSTM	1994-2007	brasileño mercado de valores	Exactitud
	[70]	Día de AMEX	Existencias		devolver, volumen	Emoción, volumen	SVM, NN, RF, lineal modelo	12/2012-10/2015	3.800 cepo	Exactitud
Profundo basado en el aprendizaje modelo	[71]	Japón	Día	Existencias precios	IPC, ratio precio-beneficio	LSTM	2001-2008	50 acciones	Exactitud	
	[72]	Día de AMEX	Existencias índice		Emoción	CNN, DNN	06/12/2009-26/07/2011	4 índices	Exactitud	
	[12]	CSI 100 días	Existencias precios		Volumen, P/E ratio, rotación tasa	Impulsado por eventos LSTM	01/01/2015-31/12/2015	91 acciones	Exactitud, MCC	
	[73]	CRSP	Día	Existencias precios	Precio, emociones	DNN	06/06/2013-31/12/2013	5.000 cepo	Exactitud	
	[74]	Día del S&P 500	Existencias precio		Artículo de noticias	DNN	10/2006-12/2013	Índice	Exactitud	
	[75]	Nifty 50, Sensex, S&P 500	Día	Existencias precio	Precio, volumen	DNN	1/2010-12/2019	Índice	RMSE, MAPE	

Notas: En esta tabla, SS indica significancia estadística; AMEX indica bolsa de valores estadounidense; RF indica bosque aleatorio. modelo; CAPM indica modelo de fijación de precios de activos de capital; DNN indica modelos de redes neuronales profundas; MCC indica correlación de Matthews coeficiente; RMSE indica error cuadrático medio; MAPE indica error porcentual absoluto medio.

Las bases de la teoría financiera moderna al ilustrar la relación riesgo-rendimiento

[45]. Ampliando este trabajo de base, William F. Sharpe formuló el Principio de los Activos de Capital.

Modelo de precios CAPM (por sus siglas en inglés) para dilucidar la conexión entre los factores de riesgo del mercado y rendimientos anticipados de las acciones [32]. Cabe señalar que Markowitz y Sharpe fueron galardonados con el Premio Nobel de Economía en 1990 por sus contribuciones pioneras a la fijación de precios de activos. Bruner et al. proporcionaron una guía detallada sobre la aplicación del CAPM.

para observar los precios de las acciones en varios mercados desarrollados y emergentes [82]. En el Tras la introducción del CAPM, han surgido una gran cantidad de extensiones y derivados del modelo.

Surgió para abordar aspectos más matizados de los mercados financieros. Entre ellos, Mer-

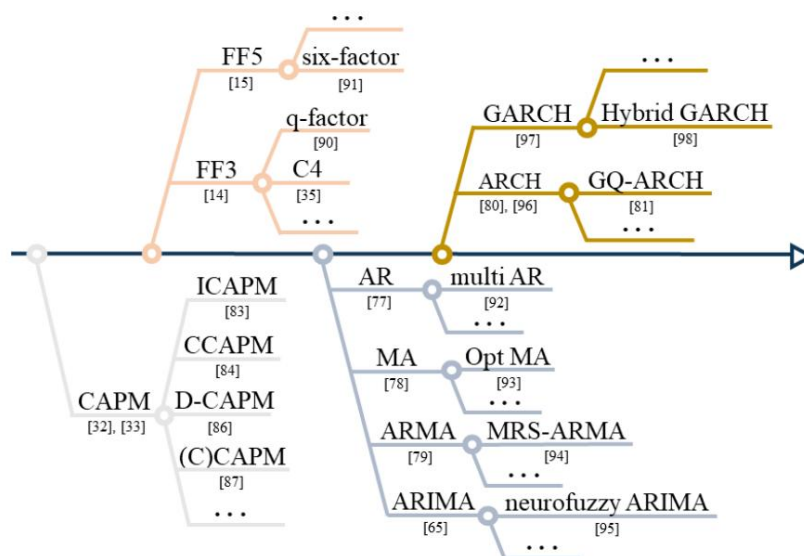


Figura 4: Hoja de ruta de los modelos econométricos en la fijación de precios de activos.

El CAPM intertemporal (ICAPM) de Ton se destaca por su consideración de variables variables en el tiempo. oportunidades de inversión y estrategias de cobertura de riesgos, ofreciendo una perspectiva dinámica sobre los precios de los activos [83]. De manera similar, la adaptación de Breeden integra el consumo basado factores en la ecuación de precios de los activos, introduciendo una beta de consumo para capturar La sensibilidad de los precios de los activos a los cambios en el consumo anticipado [84]. Modelos adicionales como el CAPM condicional [85], el D-CAPM [86] y el (C)CAPM [87]

Ampliar aún más los principios fundamentales del CAPM, adaptando el modelo original a encapsular diversas condiciones del mercado y comportamientos de los inversores.

La extensión del CAPM de Ross a través de la teoría de precios de arbitraje (APT) postula que el precio de los activos está determinado por una combinación lineal de varios factores y sus Sensibilidades o exposiciones correspondientes, que van más allá del simple riesgo de mercado. Él Se recomiendan modelos multifactoriales para un análisis más completo, aunque APT No se especifica la naturaleza exacta de estos factores [16]. En línea con este enfoque multifactorial, el modelo de tres factores de Fama y French (FF3) representa una evolución significativa, integrando factores de tamaño (PYME) y valor (HML), además del mercado. La capitalización de mercado y la relación valor contable/valor de mercado afectan sus rendimientos, lo que ejemplifica aún más la aplicación de teorías multifactoriales en la fijación de precios de activos [14]. Ampliando el FF3, el modelo de cuatro factores de Carhart (C4) incorpora un factor de impulso que captura La tendencia de las acciones a seguir comportándose en línea con su trayectoria reciente [35]. Este modelo proporciona una perspectiva más dinámica sobre los precios de los activos, reconociendo

Bordeando el efecto momentum en el mercado de valores. Para aumentar la complejidad, el modelo de cinco factores de Fama y French (FF5) introduce dos factores adicionales: la rentabilidad de las empresas (RMW) y la inversión de las empresas (CMA) [15]. Este modelo está diseñado para considerar las variaciones en los retornos atribuibles a las diferencias en la rentabilidad y los patrones de inversión, ofreciendo un marco integral para comprender el precio de los activos. Las contribuciones de Fama al desarrollo de estos modelos multifactoriales han sido altamente aclamadas, culminando en un Premio Nobel de Economía. Nichol y Dowling encontraron que en el mercado de valores del Reino Unido, el modelo FF5 demuestra un rendimiento superior en comparación con el modelo FF3 [88]. Estos modelos, es decir, el FF3, C4 y FF5, se han convertido en herramientas indispensables para los investigadores financieros que profundizan en la dinámica del mercado y los retornos de los activos. Su adaptabilidad se demuestra mediante diversas modificaciones, como un modelo de cuatro factores que amplía el FF3 al incorporar un factor de valoración errónea [89], un modelo de factor q que incluye factores de mercado, tamaño, inversión y rentabilidad [90], y un modelo de seis factores que se basa en el FF5 [91]. Estas adaptaciones resaltan la flexibilidad y la relevancia sostenida de estos modelos en el panorama cambiante de la investigación financiera.

Los estudios mencionados pasan por alto las características de las series temporales inherentes a los movimientos del mercado, centrándose principalmente en los resultados derivados de datos estáticos. Para abordar esta deficiencia, los investigadores han desarrollado modelos de series temporales esenciales para comprender mejor la dinámica de los mercados financieros. El modelo AR, por ejemplo, utiliza valores pasados de una variable para predecir sus valores futuros, lo que ofrece información valiosa sobre las tendencias y patrones del mercado [77]. El modelo MA utiliza términos de error pasados para ofrecer una perspectiva matizada sobre el suavizado de datos y el análisis de tendencias [78]. Para perfeccionar estos enfoques, se introdujo el modelo ARMA, que combina las ventajas de los modelos AR y MA para proporcionar un marco más completo para el análisis de datos de series temporales [79]. Si bien los modelos AR, MA y ARMA son eficaces para gestionar series temporales uniformes, enfrentan desafíos debido a la naturaleza errática de los datos bursátiles. Aquí es donde entra en juego el modelo ARIMA, que extiende el modelo ARMA con técnicas de diferenciación para gestionar eficazmente datos no uniformes [65]. Los modelos AR, MA, ARMA y ARIMA son fundamentales para los analistas financieros, ya que ofrecen información detallada sobre la dinámica del mercado y la rentabilidad de los activos. Su versatilidad se evidencia en diversas variantes, como el AR iterado multipaso [92], el MA optimizado [93], el MRS-ARMA (Markov Regime-Switching ARMA) [94] y el ARIMA neurodifuso [95]. Estas adaptaciones subrayan la aplicabilidad y adaptabilidad duraderas de estos modelos en el campo de la investigación financiera, demostrando su capacidad para evolucionar y abordar fenómenos complejos del mercado.

Los mercados financieros exhiben una agrupación de volatilidad, modelada eficazmente por el modelo ARCH de Engle, que le valió un Premio Nobel [80]. Este modelo es crucial para comprender

La volatilidad del mercado actual se ha aplicado en diversos estudios, como el de Bodurtha. y el análisis de Mark de los rendimientos del mercado bursátil estadounidense [96]. El modelo GARCH, una extensión de Bollerslev, mejora este análisis al incorporar tanto modelos autorregresivos como componentes de media móvil, que se están utilizando ampliamente en la investigación financiera [97]. Por ejemplo, French et al. emplearon el modelo GARCH para vincular los rendimientos de las acciones y los movimientos del mercado [98]. Sin embargo, una evaluación exhaustiva realizada por Hansen y Lunde de 330 modelos de tipo ARCH, incluido GARCH, demostraron que ningún modelo se destaca uniformemente en la predicción del comportamiento del mercado, lo que subraya la importancia de seleccionar el modelo apropiado en función del contexto financiero específico [81].

En conclusión, los modelos econométricos suelen adoptar un enfoque basado en la "deconstrucción", centrándose en los factores individuales que afectan a los mercados bursátiles y posiblemente pasando por alto sus efectos combinados [7]. Estos modelos abordan principalmente factores estructurados. y a menudo descuidan la dinámica compleja introducida por elementos no estructurados como Texto de artículos de noticias [51]. El recuento de artículos se utiliza como indicador de influencia del mercado [99, 100]. Puede que no capture completamente el impacto de las noticias, ya que pasa por alto la profundidad del contenido, potencialmente Simplificando el efecto de las noticias en el comportamiento del mercado. Las investigaciones futuras deberían integrar información textual de alta dimensión en los modelos econométricos, yendo más allá de su simple tratamiento. como un simple factor. Además, es crucial combinar información estructurada y no estructurada. modelos de datos para proporcionar una comprensión integral de la dinámica del mercado.

Además, para facilitar que los colegas investigadores se mantengan informados sobre los últimos avances en investigación financiera dentro del campo y obtener información valiosa Se ofrecen perspectivas sobre tendencias emergentes y áreas focales para futuros esfuerzos de investigación, clasificaciones integrales de trabajos representativos, revistas e instituciones de investigación. presentado. Estas clasificaciones se derivan de los recuentos de citas. Específicamente, ⁷. de documentos relevantes.

- Trabajos representativos: Identificar los estudios más influyentes en el campo de precios de activos en las finanzas, la Tabla 3 presenta un resumen completo de Estudios que han obtenido citas significativas y han logrado avances metodológicos notables, sirviendo colectivamente como pilares fundamentales de este campo. Por ejemplo, el trabajo seminal de Fama en el artículo principal [44] introdujo La "hipótesis del mercado eficiente", una teoría muy influyente que ha dado forma La trayectoria de la investigación financiera. El tercer artículo [14] de Fama propuso La FF3, que sentó una base sólida para las investigaciones posteriores sobre el Factores de impacto que afectan a los mercados de valores, estableciéndolo como un tema de investigación destacado. paradigma. Estas contribuciones sustanciales hechas por Fama en estos seminales

⁷Las estadísticas de citas de cada referencia se basan en Google Scholar al 10 de junio de 2024.

Sus artículos desempeñaron un papel fundamental en su reconocimiento y posterior obtención del Premio Nobel de Economía. Además, el segundo artículo [32] de Sharpe, que destacaba la importancia del CAPM en economía, desempeñó un papel crucial en la configuración de la teoría y la práctica de las finanzas modernas y contribuyó decisivamente a su obtención del Premio Nobel.

- **Revistas:** Para investigar la inclinación de las revistas financieras hacia los temas de valoración de activos y su impacto, presentamos clasificaciones basadas en la frecuencia de publicación de artículos y el número correspondiente de citas recibidas (véase la Tabla 4). El Journal of Finance ocupa la posición preeminente, con 51 publicaciones y el mayor número de citas (242.115). El Journal of Financial Economics comparte el segundo puesto, con 31 publicaciones relevantes y 45.130 citas.

La Revista de Estudios Financieros consigue la tercera posición con 24 artículos.

Estas tres revistas gozan de amplio reconocimiento como publicaciones de primer nivel en el campo de las finanzas a nivel mundial. Por consiguiente, el análisis de la valoración de activos se perfila como un área importante dentro de esta disciplina.

- **Instituciones de investigación:** Para determinar la larga trayectoria y las sustanciales contribuciones de las instituciones de investigación en el campo de la valoración de activos, se ha realizado una clasificación basada en el historial de publicaciones consistente y el impacto de las citas de cada institución, como se presenta en la Tabla 5. Cabe destacar que la Universidad de Chicago, la Universidad de Harvard, el Dartmouth College y la Universidad de Washington han demostrado una presencia sostenida en el campo de la valoración de activos, con 33, 12, 11 y 9 artículos publicados, respectivamente. Asimismo, la Universidad Northwestern, la Universidad del Sur de California y la Universidad de Yale, además de las instituciones mencionadas, también han ejercido una influencia considerable en este ámbito, como lo demuestran sus respectivos recuentos de citas de 25.527, 24.440 y 12.254.

3.2. Modelos basados en aprendizaje automático

En comparación con los modelos econométricos para la valoración de activos, los modelos basados en aprendizaje automático ofrecen una lista más amplia de posibles variables predictoras y especificaciones funcionales más completas para abordar problemas de predicción más complejos. En primer lugar, los modelos econométricos se enfrentan a dificultades para integrar numerosos factores de información del mercado, en particular al abordar las complejas relaciones no lineales entre diversos factores y las fluctuaciones bursátiles. Los métodos econométricos tradicionales suelen cuantificar datos complejos, como artículos periodísticos, en valores escalares o vectores simples, como las puntuaciones de sentimiento.

Tabla 3: Trabajos representativos en términos de citas en el ámbito financiero.

Título de referencia	Diario del año	Citas
[44] Mercados de capital eficientes: una revisión de la teoría y la experiencia trabajar	1970 J FINANC	38.369
[32] Precios de los activos de capital: una teoría del equilibrio del mercado bajo condiciones de riesgo	1964 J FINANC	33.662
[14] Factores de riesgo comunes en los rendimientos de las acciones y los bonos	1993 J FINANCIACIÓN 32,151	
[101] La sección transversal de los rendimientos esperados de las acciones	1992 25,02 J FINANC	
[35] Sobre la persistencia en el rendimiento de los fondos mutuos	1997 J FINANCIACIÓN 23,529	
[102] Riesgo, rentabilidad y equilibrio: pruebas empíricas	1973 J FINANCIACIÓN 20,132	
[103] El comportamiento de los precios de las bolsas de valores	1965 J BUS 16,858	
[64] La relación entre el rendimiento y el valor de mercado de las acciones comunes	1981 J FINANC ECON 10,921	
[34] Equilibrio en un mercado de activos de capital	1996 ECONOMÉTRICA 9,856	
[15] Un modelo de valoración de activos de cinco factores	2015 J FINANC ECON 9,233	
[104] El riesgo de los operadores de ruido en los mercados financieros	1990 J POLIT ECON 9,128	
[105] Mercados de valores, bancos y crecimiento económico	1998 AM ECON REV 9,017	
[106] El ajuste de los precios de las acciones a la nueva información	1969 INT ECON REV 8,951	
[76] Las fuerzas económicas y el mercado de valores	1986 8,417 J BUS	
[107] Psicología del inversor y reacciones exageradas y subreaccionadas del mercado de valores	1998 J FINANC 8,214	
[49] El sentimiento de los inversores y la representación transversal de los rendimientos de las acciones	2006 J FINANC	7.631
[108] Factores de tamaño y relación precio-valor contable en las ganancias y los rendimientos	1995 J FINANC	5.721
[27] Dando contenido al sentimiento de los inversores: el papel de los medios de comunicación el mercado de valores	2007 J FINANC	5.334
[109] Condiciones comerciales y rendimientos esperados de las acciones y cautiverio	1989 J FINANC ECON 5,334	
[15] Rendimientos de dividendos y rentabilidades esperadas de las acciones	1988 J FINANC ECON 5,101	
[110] Sentimiento de los inversores en el mercado de valores	2007 J ECON PER-ESPECTRO	5.008
[33] Precios de los valores, riesgo y ganancias máximas de la diversificación	1965 J FINANC	4.835
[111] Una mirada integral al desempeño empírico de la predicción de primas de acciones	2008 REV FINANCIAMIENTO SEMENTAL	4.304
[112] El modelo de valoración de activos de capital: teoría y evidencia	2004 J ECON PER-ESPECTRO	4.283
[113] Precios de las acciones, ganancias y dividendos esperados	1988 J FINANC	3.837
[114] Psicología del inversor y fijación de precios de los	2001 J FINANC	3.758
[115] Paseos aleatorios en los precios del mercado de valores En busca de	1995 ANAL FINANCIERO J	3.724
[116] atención El CAPM condicional y la sección transversal de los dividendos esperados devoluciones	2011 J FINANC	3.553
[113] atención El CAPM condicional y la sección transversal de los dividendos esperados devoluciones	1996 J FINANC	3.478
[117] La rentabilidad de las acciones y la estructura	1987 J FINANC ECON 3,206	
[118] temporal de las acciones. ¿Es todo eso solo ruido? El contenido informativo de los foros bursátiles en internet.	2004 J FINANC 3,096	
[119] Predecir el exceso de rentabilidad de las acciones a partir de una muestra: ¿puede algo superar el promedio histórico?	2008 REV FINANCIAMIENTO SEMENTAL	3.040
[120] Consumo, riqueza agregada y rentabilidad esperada de las acciones	2001 J FINANC	2.899
[28] Más que palabras: cuantificar el lenguaje para medir empresas Fundamentos	2008 J FINANC	2.853
[45] La utilidad de la riqueza	1952 J POLIT ECON 2,844	
[121] Predecir la rentabilidad de los mercados de acciones y bonos	1986 J FINANC ECON 2,518	

Tabla 4: Influencia de las revistas en función del número de publicaciones en el ámbito financiero.

Diario	Número	Citas	Publicaciones
J FINANC	51	242.115	[122], [27], [2], [32], [14], [29], [123], [28], [33], [35], [124], [125], [108], [126], [67], [107], [49], [113], [114], [120], [116], [118], [127], [128], [129], [130], [131], [132], [133], [134], [135], [136], [137], [138], [139], [140], [141], [99], [142], [143], [144], [145], [146], [147], [148], [149], [49], [85], [91], [150], [151]
J FINANC ECON	31	45.130	[15], [22], [30], [64], [109], [117], [121], [152], [153], [154], [155], [156], [100], [157], [158], [159], [160], [161], [162], [163], [164], [165], [166], [167], [165], [161], [168], [6], [169], [170], [92]
REV FINANC STUD	24	18.490	[58], [7], [111], [119], [171], [172], [173], [174], [175], [176], [177], [178], [179], [180], [181], [182], [183], [184], [185], [186], [187], [89], [90], [188]
FINANCIACIÓN DEL BANCO J	11	2.498	[189], [190], [191], [192], [193], [194], [195], [196], [197], [198], [199], [200], [201]
ANAL FINANCIERO J	9	7.373	[40], [38], [115], [202], [203], [204], [48]
PAC-CUENCA FINANC J	6	8.921	[43], [205], [206], [207], [208], [209]
J. POLIT. ECON.	5	35.574	[20], [45], [102], [104], [87]
EUR FINANC MANAG 5		1.579	[210], [211], [212], [213], [214]
AM ECON REV	4	10.991	[105], [215], [216], [217]
REPRESENTANTE CIENTIFICO	4	2.151	[218], [219], [220], [221]
FINANCIACIÓN CUANTITATIVA	4	467	[222], [223], [224], [225]
J BUS	3	26.544	[103], [76], [226]

o el recuento de palabras, que pueden pasar por alto detalles sutiles pero cruciales. En segundo lugar, investigaciones financieras recientes han subrayado la importancia de las interacciones entre factores clave en Revelando los movimientos de las acciones [7]. La naturaleza inherente de "aprendizaje" del aprendizaje automático Los enfoques proporcionan una vía prometedora para estimar las interacciones entre las características [12]. Por último, como sistema económico, el movimiento de una acción está inherentemente influenciado por múltiples acciones relevantes, conocidas como efectos de contagio de impulso en finanzas [30]. Mientras que Los modelos econométricos enfrentan desafíos para identificar empresas vecinas y capturar Sus influencias, el aprendizaje profundo basado en gráficos presenta una solución prometedora para capturar los efectos indirectos del impulso de las empresas relevantes sobre la empresa objetivo [31].

En general, la predicción de acciones se puede caracterizar ampliamente como una clasificación o tareas de regresión, con el objetivo de predecir tendencias, como al alza, a la baja, o movimientos planos, o valores reales, como precios de acciones, volúmenes de negociación, facturación, y devuelve. Supongamos que hay una colección de empresas cotizadas $\{1, 2, 3, \dots, M\}$, cada una de que tiene N características $\{x_{t,1}^i, x_{t,2}^i, x_{t,3}^i, \dots, x_{t,N}^i\}$ (por ejemplo, precio de las acciones, tamaño de la empresa, industria) en el momento t . En consecuencia, cada empresa se etiqueta con una etiqueta y_{t+1}^i indicando Su estado futuro de existencias. Para la predicción de existencias, la matriz de entrada $X \in \mathbb{R}^{m \times n}$ registra el factores clave históricos de M empresas con N características empresariales. Más específicamente, la elemento $x_{t,k}^i$ ésimo de la matriz X indica el valor de k característica de la empresa i en ese momento

Tabla 5: Influencia de las instituciones de investigación en términos del número de publicaciones en el ámbito financiero.

Instituto	Citas numéricas	Artículos	
Universidad de Chicago	33	215.668	[103], [14], [15], [29], [7], [20], [126], [115], [102], [104], [106], [109], [112], [130], [131], [139], [99], [144], [159], [160], [171], [181], [204], [215], [216], [217], [226], [227], [228], [229], [230], [231],[232]
Universidad de Harvard	12	45.418	[33], [38], [49], [110], [119], [20], [29], [159], [104], [233],[49]
Universidad de Dartmouth	11	58.949	[15], [112], [139], [144], [160], [171], [204], [226], [156], [14], [108]
Universidad de Washington	9	37.147	[32], [58], [133], [142], [152], [154], [142], [230], [234]
Universidad de Texas	7	11.702	[27], [28], [175], [235], [236], [237], [238]
Universidad de Pensilvania	6	7.505	[121], [145], [155], [239],[36],[89]
Instituto Tecnológico de Massachusetts	6	7.434	[39], [128], [129], [240], [241], [242]
Universidad Northwestern	5	25.527	[64], [132], [172], [107],[85]
Universidad de Nueva York	5	8.200	[38], [189], [110], [203], [243]
Universidad del Sur de California 4		24.440	[35], [135], [177], [142]
Universidad de Carolina del Norte	4	5.224	[137], [176], [183], [244]
Universidad de Notre Dame	4	3.553	[116], [140], [245], [170]
Universidad de Yale	3	12.254	[76], [113],[188]
Universidad de Michigan	3	9.219	[107], [157], [177]
Universidad de Princeton	3	7.043	[113], [117], [224]
Instituto Europeo de Negocios Administración	2	8.946	[134], [138]
Laboratorio de Investigación Naval de los Estados Unidos, Universidad de Minnesota	2	2.715	[246], [247]
	2	1.879	[127], [132]

t. El objetivo de la predicción de stock es encontrar un mecanismo de mapeo apropiado ($Y = f(X)$) aprendida a partir de muestras de entrenamiento. Varios algoritmos de aprendizaje automático han se ha utilizado ampliamente para fines de fijación de precios de activos. La Tabla 6 presenta el objetivo Funciones, algoritmos de solución y trabajos relevantes de aprendizaje automático representativo enfoques. Además, la Figura 5 ilustra la hoja de ruta del aprendizaje automático basado en modelos en la predicción del mercado de valores.

3.2.1. La intervención del aprendizaje automático clásico

En las primeras etapas de la investigación, la predicción de acciones se abordó principalmente como una Problema binario en el marco del aprendizaje automático clásico. El mercado Los indicadores de movimiento se clasifican en dos categorías: movimiento ascendente y descendente, mentos. Algoritmos clásicos de aprendizaje automático ⁸, como KNN [3], regresión logística

⁸Los modelos clásicos de aprendizaje automático varían significativamente, cada uno adaptado para un análisis de datos específico. y tareas de extracción de características. KNN, por ejemplo, detecta patrones a través de la proximidad de los datos, mientras que

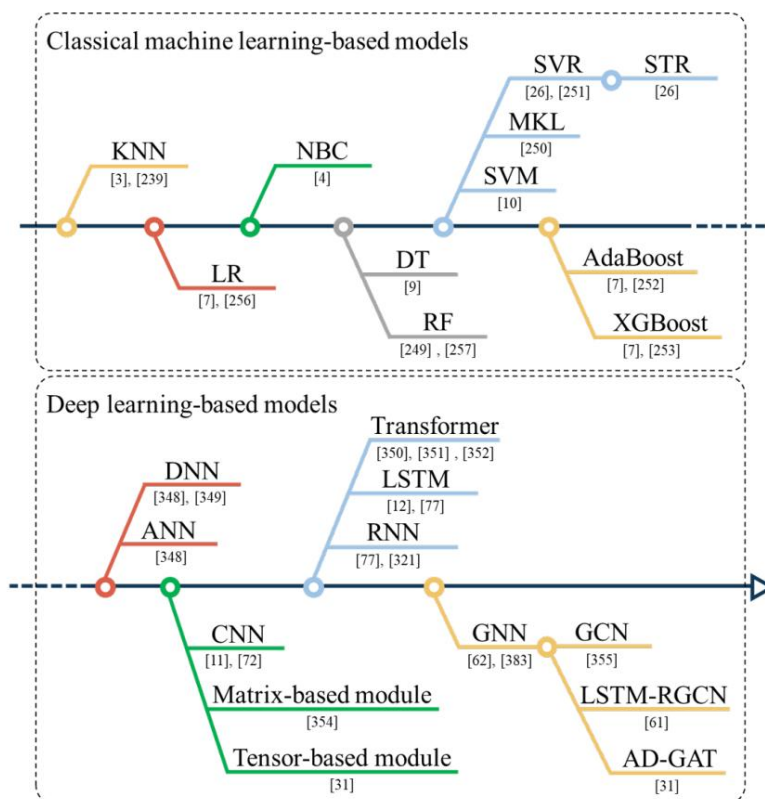


Figura 5: Hoja de ruta de los modelos basados en aprendizaje automático en la predicción de acciones.

Se emplean métodos como el (LR) [248], el clasificador bayesiano ingenuo (NBC) [4], los árboles de decisión (DT) [9], el bosque aleatorio (RF) [249], las máquinas de modelado de valores (SVM) [10], el aprendizaje de múltiples núcleos (MKL) [250], la SVR [251], la regresión tensorial de soporte (STR) [26] y el algoritmo de integración de aprendizaje automático [252, 253] para clasificar la información de mercado en estos dos tipos según su impacto en la tendencia del mercado. Al comparar los vectores de características de la nueva información, los datos se pueden clasificar en uno de los dos tipos mencionados.

En concreto, Wuthrich et al. utilizaron el modelo KNN para predecir el impacto de los artículos de noticias en las tendencias de los índices bursátiles y descubrieron que la precisión de los pronósticos era significativamente mayor que las conjeturas aleatorias y comparable a las de los expertos humanos.

Los modelos de regresión logística establecen relaciones lineales para resultados binarios. Las máquinas de modelado de valores (SVM), que utilizan métodos kernel, son eficaces con datos no lineales, ofreciendo definiciones adaptables de límites de decisión. Debido a esta variedad, cada modelo se analiza individualmente, resumiendo sus fortalezas y debilidades para la predicción del mercado bursátil.

Tabla 6: Modelos representativos basados en aprendizaje automático para la predicción de acciones.

Modelo	Funciones objetivo, di,j	Solución
KNN	$i = \text{voto } y_k \quad (d_i = (N \sum_{n=1}^n x_i - x_n)^p)^{1/p}$	Voto mayoritario
Regresión logística	$P(y_{t+1} = i) = \frac{1}{1 + e^{-(wT x_i t, n + b)}}$	Dios mio
Clasificador bayesiano ingenuo	$P(y_{t+1} = i x_{t,n}) = \frac{P(y_{t+1} = i) \prod_{j=1}^n P(x_{t,n}^j y_{t+1} = i)}{\sum_{y \in Y} P(y_{t+1} = y) \prod_{j=1}^n P(x_{t,n}^j y_{t+1} = y)}$ $\text{arg máx}_y (P(y_{t+1} = y) \prod_{j=1}^n P(x_{t,n}^j y_{t+1} = y))$	Solución de fórmula
Árbol de decisiones	Ganancia = H(Y) - H(Y X)	EM
Bosques aleatorios	$y_{t+1}^i = 1/J \cdot \sum_{j=1}^J DJ(x_i^j)$	POEMA
SVM	$\text{signo}(wT \cdot (x_{t,n} + b)), \min w, b \quad W^2$ $wT \cdot (x_{t,n} + b) - 1 \geq 0$	SMO
SVR	$\text{signo}(wT \cdot (x_{t,n} + b)), \min w, b, \xi, \xi^* \quad W^2 + C \cdot \sum_{j=1}^n (\xi_j + \xi_j^*)$ $wT \cdot (x_{t,n} + b) - 1 \geq 0 \quad \forall j \quad y_{t+1} = y$	SMO
AdaBoost	$y_{t+1}^i = \sum_{j=1}^J w_j \cdot \text{signo}(w_j T \cdot (x_i + b_j))$	POEMA
XGBoost	$+ DJ(x_i)$	GB
ANA	$= \text{activo}(wT x_i + b), \text{arg min } w, b \quad = 1(\bar{y}^i - y_{t+1}^i)^2$	prediccion, datos, generacion
CNN	$= \text{activo}(wT x_{im} + b),$ $\text{conv}(x = \{t, n, w, b\}, x_{im} = \text{agrupacion}(x = \{k, w, b\} \text{ hola}))$ $\text{activo}(wT h + b), h^l = f(x_{el}^i, x_{el}^{i-1}, \dots, x_{el}^{i-t+1})$	prediccion, datos, generacion
LSTM	$= \text{activo}(wT h_{zt} = i + \sigma(Wz \cdot ht - 1, xi_{Tennessee}, b), rt = \sigma(Wr \cdot ht - 1, xi_{Tennessee}, b)),$ $ht = \tanh(W \cdot rt_{Tennessee}, ht - 1, xi_{Tennessee}), ht = (1 - zt) \cdot ht - 1 + zt \cdot ht$	BPTT, GD
Transformador	Atención(Q, K, V) = $\text{soft tmax}(\frac{QK^T}{\sqrt{dk}})V$, $\text{head}_i = \text{Atencion}(QWQ_{yo}, KW_{yo}, KVWV)$, $\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)WO_{co[i]}ne[i]$	prediccion, datos, generacion
GNN	$= \text{activo}(wT g_i + b), g_i = f(x_i, x_t, ne[i], g_{x,t})$	prediccion, datos, generacion

Notas: En esta tabla, GD indica descenso de gradiente; EM indica método exhaustivo; PO indica optimización por fases; SMO indica optimización mínima secuencial; GB indica refuerzo de gradiente; BP indica propagación hacia atrás; BPTT indica retropropagación a través del tiempo.

[3]. El modelo KNN está bien establecido, es simple y altamente interpretable para los mercados financieros, y puede guiar eficazmente las decisiones de inversión. Sin embargo, una limitación del método KNN es que se basa principalmente en un número limitado de muestras del mercado y no considera la información de muestras distantes, por lo que no utiliza la información general del mercado [254]. Dutta y Bandopadhyay emplearon LR para predecir la rentabilidad utilizando datos bursátiles de 30 empresas cotizadas y descubrieron que los modelos LR mejoraron significativamente la predicción de acciones [248]. El modelo LR integra diversos factores que influyen en los mercados y presupone una relación lineal entre estos elementos. Funciona bien cuando se trata con menos factores o con un

Algunos factores específicos presentan relaciones lineales, pero presenta dificultades para gestionar las relaciones no lineales existentes en los mercados financieros [7]. Para abordar las limitaciones del LR, se ha utilizado ampliamente un NBC basado en el teorema de Bayes [255]. Por ejemplo, Li exploró la asociación entre los informes anuales de las empresas y los precios de las acciones utilizando un NBC [4]. Sin embargo, el NBC asume que los factores clave del mercado financiero no están correlacionados entre sí, lo cual no se corresponde con las características de los datos reales del mercado financiero y puede afectar la eficacia del clasificador [7]. En otro estudio, Rachlin et al. utilizaron un DT para capturar la influencia de las noticias en las tendencias de los precios de las acciones e informaron que el DT superó al NBC en cuanto a capacidad predictiva [9]. El DT ofrece ventajas como un bajo esfuerzo computacional, simplicidad, alta precisión e interpretabilidad. Ayuda a los analistas financieros a generar estrategias comerciales comprensibles, facilita la inferencia causal y orienta las inversiones. El proceso de aprendizaje de los DT es susceptible al sobreajuste, lo que reduce la capacidad de generalización para nuevos datos. Para superar este problema, el método RF utiliza múltiples DT para entrenar y predecir muestras. Khaidem et al. emplearon un clasificador RF para predecir las fluctuaciones bursátiles en numerosos mercados bursátiles estadounidenses durante un período de 14 años, observando la robustez del modelo y logrando una alta precisión de predicción a largo plazo [249].

La investigación mencionada anteriormente se centra principalmente en datos estructurados, mientras que las finanzas conductuales exploran el impacto de la información mediática no estructurada en la predicción del mercado bursátil. Por ejemplo, Mittermayer y Knolmayer extrajeron contenido textual de redes sociales y descubrieron que dicho contenido afecta al mercado bursátil [10]. Por lo tanto, muchas palabras del texto se han convertido en parte integral de los sistemas de pronóstico financiero. Sin embargo, el manejo de la alta dimensionalidad de los vectores de texto, que puede alcanzar decenas de miles de dimensiones, plantea desafíos para los métodos de aprendizaje automático mencionados anteriormente. SVM puede abordar este problema mediante la adopción de métodos de mapeo no lineal para transformar las muestras del espacio original a un espacio de características de mayor dimensión. La función de decisión final de la SVM se determina únicamente por unos pocos vectores de soporte, y una cantidad significativa de texto se abstrae en datos de texto de entrenamiento vectorizados, mitigando el problema del "desastre de dimensionalidad". Utilizando una SVM de un solo núcleo, Mittermayer y Knolmayer investigaron el impacto del contenido de las noticias en las tendencias del precio de las acciones y descubrieron que las SVM que utilizan factores de vectores de texto alcanzan una mayor precisión [10]. Sin embargo, los modelos SVM a menudo requieren la elección de una función de núcleo y la especificación de sus parámetros con base en la experiencia o la experimentación. En el campo de la predicción bursátil, las características consideradas en la información de entrada suelen ser heterogéneas, como las características del texto de las noticias, las características de los datos históricos del precio de las acciones de las empresas y las características fundamentales. MKL aborda esta heterogeneidad fusionando múltiples funciones de núcleo y aprendiendo automáticamente los pesos, eliminando la necesidad de seleccionar el núcleo

Funciones. Nassirtoussi y Aghabozorgi descubrieron que MKL supera a las funciones de un solo núcleo. SVM y KNN en la predicción del efecto de las características multidimensionales en las noticias sobre las acciones volatilidad del mercado [250].

Además de predecir la tendencia alcista o bajista del mercado de valores, la previsión de valores reales también es un tema de investigación crucial en el mercado financiero.

Sobre la base de SVM, Guo et al. propusieron el algoritmo SVR para tareas de predicción financiera.

Seleccionaron al azar cinco acciones de la Bolsa de Valores de Shanghai y encontraron

que el modelo SVR produce resultados prometedores en la predicción de precios de acciones específicas [251].

Además, para capturar las interacciones entre los factores clave en la determinación del precio de los activos, Li et al. introdujeron un enfoque basado en tensores para capturar de manera integral

los impactos de factores clave interactivos en precios de acciones específicas y propuso el STR

modelo [26]. Aprovechando el avance del modelo SVR al modelo STR, el

El rendimiento algorítmico se duplicó.

En realidad, el mercado de valores implica el comportamiento de toma de decisiones de múltiples partidos. Tratar a los modelos individuales como tomadores de decisiones independientes, "conjunto"

Los métodos pueden simular el comportamiento de toma de decisiones grupal en los mercados financieros. Esto

Este enfoque puede considerar eficazmente varias fuentes de información, lo que conduce a una mejora

resultados de predicción y toma de decisiones. Por ejemplo, Zhang y Chen utilizaron el

Algoritmo de conjunto Adaptive Boosting (AdaBoost) para predecir el rendimiento de las acciones en el

Mercado chino, logrando una precisión mejorada del 5% en comparación con los no conjuntos

algoritmos [252]. Dado que el mercado financiero suele exhibir un gran número

De características altamente correlacionadas, Dey et al. emplearon el método eXtreme Gradient Boosting

Algoritmo (XGBoost) para clasificar cada factor de influencia y filtrar los factores de impacto más influyentes [7].

Este enfoque simplifica el modelo y facilita una fácil

comprensión de los resultados de las previsiones [253].

En resumen, el conjunto de modelos clásicos basados en aprendizaje automático (ML) destacados anteriormente demuestra una tendencia general de mejora incremental. Estas variaciones en la eficiencia y la

eficacia entre los modelos se delinear en la Figura 6. En concreto, Phongmekin y Jarumaneeroj descubrieron ⁹.

que el aprendizaje automático (LR) ofrece ventajas.

para los inversores reacios al riesgo sobre KNN debido a su sesgo reducido en los recuentos positivos verdaderos.

⁹Es fundamental reconocer que comparar directamente la eficiencia y la eficacia de varias La comparación de modelos es un desafío debido a las considerables diferencias en los conjuntos de datos y los períodos de tiempo entre los estudios. Por lo tanto, la estrategia implicó realizar un análisis comparativo exhaustivo basado en Literatura existente que permite proporcionar descripciones generales del rendimiento de las máquinas clásicas. modelos de aprendizaje a nivel macro. Además, al comprender la necesidad de un conjunto de datos estandarizado a gran escala para una evaluación más científica de los avances de los modelos, la plataforma FactorWiki fue... Esta plataforma ofrece un amplio conjunto de datos de prueba con 1231 factores que abarcan los últimos 30 años. años, lo que representa el mayor conjunto de datos disponible en este campo.

ing [256]. Además, Rachlin et al. emplearon DT para examinar el impacto de las noticias en los precios de las acciones, destacando que DT supera al NBC en términos de poder predictivo [9]. Además, Nassiroussi y Aghabozorgi demostraron que MKL supera el rendimiento tanto de SVM de kernel único como de KNN al pronosticar los efectos de las características de las noticias multidimensionales en la volatilidad del mercado [250]. Notablemente, la transición de SVR a STR mejora significativamente el rendimiento algorítmico [26]. Además, Basak et al. observaron que RF supera a otros modelos basados en árboles en la predicción de la dirección del precio de las acciones para el mediano y largo plazo [257]. En otro caso, la aplicación de Zhang y Chen del algoritmo de conjunto AdaBoost para predecir los retornos de las acciones en el mercado chino resultó en una mejora de precisión del 5% sobre los algoritmos sin conjunto [252]. Finalmente, Tooehaei y Moeini determinaron que XGBoost supera a 14 métodos diferentes basados en bagging y boosting en rendimiento predictivo [258].

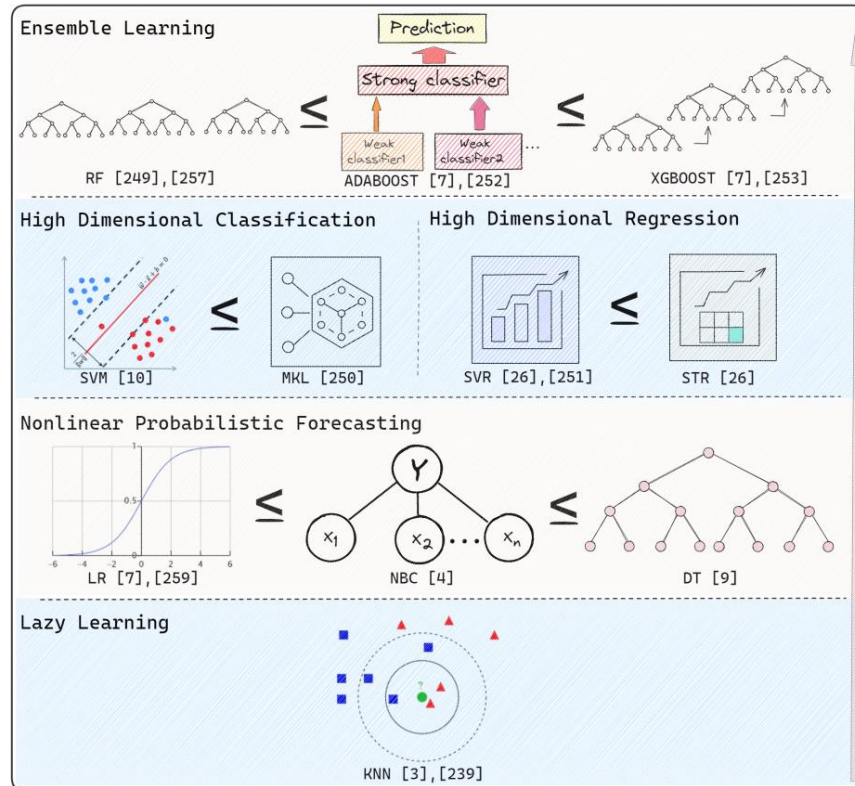


Figura 6: Eficiencia y efectividad de los modelos ML clásicos: una visión comparativa.

Sin embargo, estos modelos tienen limitaciones. En primer lugar, es posible que no capturen completamente la

interacciones entre factores clave que son esenciales para comprender los movimientos de las acciones en la investigación financiera. En segundo lugar, los modelos clásicos de aprendizaje automático podrían no ser lo suficientemente eficientes para manejar la naturaleza secuencial de los datos bursátiles, incluyendo las dependencias y patrones temporales, que son cruciales para una predicción bursátil precisa. Por último, en el mercado financiero real, es importante considerar la influencia de otras empresas relevantes sobre el movimiento bursátil de una empresa, lo que genera interdependencias y correlaciones. La incorporación de estos efectos en los modelos clásicos de aprendizaje automático presenta un impacto significativo. La investigación futura debería centrarse en el desarrollo de modelos de aprendizaje profundo que superen estas limitaciones, proporcionando una comprensión más matizada del mercado de valores dinámico.

Además, para ayudar a los investigadores académicos a mantenerse bien informados sobre la vanguardia actual de la investigación en el dominio de los modelos clásicos basados en ML para acciones, se presentan artículos. En concreto,

- **Trabajos representativos:** Identificar los estudios más influyentes en el ámbito de pronóstico del mercado de valores utilizando modelos clásicos basados en ML y teniendo en cuenta los rápidos avances en la tecnología de la información, se requiere una metodología sistemática. Se ha empleado un esquema de clasificación basado en dos períodos de tiempo distintos: La era anterior a 2014 y el período posterior desde 2014 hasta la actualidad. Por Aprovechando las fechas de publicación precisas de cada artículo, una curación meticulosa Se ha realizado una revisión de las Tablas 7 y 8 para proporcionar una síntesis completa de las obras más citadas dentro de estos rangos temporales específicos. Además, Se han proporcionado comentarios detallados para dilucidar las contribuciones distintivas de estos estudios. Estas tablas cuidadosamente elaboradas no solo facilitan Un proceso de revisión simplificado para los investigadores, que les brinda un acceso conveniente a obras seminales, sino que también sirven para ofrecer una perspectiva holística sobre la trayectoria de desarrollo de los modelos clásicos basados en ML y permitir la identificación de tendencias emergentes que dan forma a la trayectoria de este campo.
- **Revistas:** Investigar el énfasis de las revistas académicas en la predicción de acciones movimientos utilizando modelos clásicos basados en ML y evaluar su impacto, clasificaciones actuales basadas en la frecuencia de los artículos publicados en revistas relevantes y sus correspondientes recuentos de citas, como se presenta en la Tabla 9. El ranking lo ocupa Sistemas Expertos con Aplicaciones, con 32 publicaciones y 10.723 citas. En segundo lugar, se encuentra Sistemas Basados en el Conocimiento, con 7 publicaciones relevantes y 1.153 citas.

ciones. El tercer puesto lo ocupan los Sistemas de Apoyo a la Decisión, con 6 áreas relevantes. publicaciones y 1.884 citas. Cabe destacar que otras revistas de este dominio tiene menos de 6 artículos. Además, las Transacciones ACM en Los sistemas de información y las ciencias de la información, además de las revistas antes mencionadas, también han ejercido una influencia considerable en este dominio, como como lo demuestran sus respectivos recuentos de citaciones de 1.325 y 896.

- Instituciones de investigación: Evaluar las contribuciones de las instituciones de investigación.

En la previsión del mercado de valores utilizando modelos clásicos basados en ML, una clasificación basada Se realizó un estudio sobre los registros de publicaciones y el impacto de las citas, como se presenta en la Tabla 10. La institución mejor clasificada, la Universidad de Arizona, publicó 7 artículos relevantes. artículos y recibió 2.197 citas. Universidad Southwestern de Finanzas y Economía, ocupó el segundo lugar con 6 artículos y 608 citas. Universidad de la Ciudad de Hong Kong consiguió la tercera posición con 4 artículos y 612 citas, mientras que La Universidad de Tsinghua obtuvo el cuarto puesto con 4 artículos y 220 citas. Otras instituciones publicaron menos de 4 artículos en esta área.

3.2.2. Nuevas tendencias en el aprendizaje profundo

Los investigadores han explorado cada vez más el uso de redes neuronales artificiales (RNA) como una posible solución para abordar los problemas de no linealidad y correlación entre Factores de impacto en el mercado. Por ejemplo, Hinton y Salakhutdinov demostraron que Las ANN utilizadas para predecir la tendencia del índice S&P 500 lograron una clasificación más alta precisión en comparación con los algoritmos clásicos de aprendizaje automático [348]. Sin embargo, las ANN tradicionales enfrentan desafíos para capturar las complejas no linealidades y correlaciones inherentes a las influencias del mercado. Hinton y Salakhutdinov propusieron un marco de aprendizaje profundo con múltiples capas ocultas que permite la captura de información de alto nivel. abstracciones y extracción de características más informativas de los datos [348]. Esto El avance ha mejorado efectivamente el rendimiento de las redes neuronales, lo que Fomentando un mayor desarrollo de enfoques de aprendizaje profundo en el ámbito académico y la industria. Ding et al. emplearon una red neuronal profunda (DNN) para demostrar la superioridad de los pronósticos diarios. sobre pronósticos semanales y mensuales. Los hallazgos revelaron que la red profunda El modelo supera a los enfoques de aprendizaje superficial en términos de precisión de predicción [349].

Vale la pena señalar que los modelos de aprendizaje profundo, si bien son variados, todos se basan en el marco de la red neuronal, utilizando funciones de reenvío y activación ponderadas. La diversidad surge de estructuras de red especializadas diseñadas para distintos desafíos de análisis de datos: las redes neuronales recurrentes abordan datos de series temporales, las redes neuronales convolucionales Las redes abordan las interacciones de factores y las redes neuronales gráficas analizan el impulso. Efectos secundarios. Inicialmente, la fijación de precios de activos aprovechó los modelos clásicos de aprendizaje automático de

Tabla 7: Trabajos representativos sobre modelos clásicos basados en ML publicados antes de 2014 en términos de citas.

Revista del año de referencia	Modelo de citas	Contribución única
[17]	2011 J COMPUT SCI 7,126 SOFNN	Este estudio utiliza la red neuronal difusa autoorganizada (SOFNN) para predecir Valores del DJIA basados en la opinión pública de Twitter. Tasa de precisión alcanzada para el DJIA. La predicción es del 86,7%.
[19]	2009 ACM T IN-SISTEMA DE FORMULARIO	1.254 SVR Este estudio utiliza diferentes representaciones textuales para modelar noticias financieras y empleó la RVS para estimar los precios de las acciones 20 minutos después de la publicación de la noticia. Un nombre propio. El esquema superó al enfoque de la bolsa de palabras.
[259]	2005 OMEGA-INT J GESTIONAR S	1.250 ARIMA, SVM Este estudio propone una metodología híbrida que combina los modelos ARIMA y SVM para pronosticar los precios de las acciones. El modelo híbrido aprovechó las fortalezas de ARIMA para patrones lineales y SVM para patrones no lineales en los datos.
[260]	Sistema experto 2011 APLICACIÓN	1.157 ANA, SVM Este estudio compara el rendimiento de una ANN y un SVM en la predicción de acciones. direcciones de movimiento. La RNA mostró un rendimiento promedio significativamente mejor. (75,74%) en comparación con el SVM (71,52%).
[261]	Sistema experto 2011 APLICACIÓN	1.036 MLP, DAN2, GARCH Este estudio compara el rendimiento de los modelos de redes neuronales dinámicas (multicapa) perceptrón (MLP), red neuronal artificial dinámica (DAN2) y redes neuronales híbridas (GARCH) en predicciones del mercado de valores, encontrando que el modelo MLP supera a DAN2 y GARCH.
[262]	SISTEMA EXPERTO 2000 APLICACIÓN	1.008 GA Este estudio utiliza un algoritmo genético (AG) para optimizar la discretización de características y pesos de conexión en ANN para la predicción del índice de precios de acciones, ampliando el tradicional El papel del AG más allá de mejorar el algoritmo de aprendizaje.
[263]	2003 COMPUT OPER RES	763 PNN Este estudio exploró la capacidad predictiva de una red neuronal probabilística (PNN) en Pronosticando la rentabilidad de los índices de mercado. El PNN mostró un rendimiento superior debido a Sus robustas capacidades de detección de valores atípicos e identificación de errores.
[264]	2010 CONOCIMIENTO-SISTEMA BASADO	497 GFS, ANA Este artículo integra sistemas difusos genéticos (GFS) y redes neuronales artificiales (ANN) para un rendimiento superior en la predicción del precio de las acciones en comparación con los métodos anteriores.
[265]	2011 CONOCIMIENTO-SISTEMA BASADO	475 RBFNN Este estudio emplea una red neuronal con función de base radial (RBFNN) para entrenar y Predecir los índices bursátiles de la Bolsa de Shanghái. Los autores introdujeron El algoritmo de enjambre de peces artificiales (AFSA) para optimizar la RBFNN.
[266]	2013 DECIS SUP-SISTEMA DE PUERTO	469 SVM Este estudio mejora los métodos de minería de texto al incorporar la retroalimentación del mercado en la selección de características y emplear características expresivas, lo que da como resultado una clasificación superior. precisiones en comparación con enfoques anteriores.
[267]	2012 DECIS SUP-SISTEMA DE PUERTO	462 SVR Este estudio utiliza el sistema Arizona Financial Text (AZFinText) y el sentimiento herramienta de análisis para predecir los precios de las acciones, con resultados que indican que los artículos con sentimientos negativos exhibieron la mayor previsibilidad en la dirección de los precios.
[268]	2005 COMPUT OPER RES	368 ANA Este estudio compara el poder predictivo del modelo de tres factores de Fama-French con modelos de redes neuronales. Los hallazgos revelaron que los modelos de redes neuronales Superaron los modelos lineales en términos de precisión de predicción.
[18]	2009 INFORMAR PRO-GESTIÓN DE CESS	270 SVR Este estudio compara el rendimiento de las predicciones de AZFinText con las de fondos cuantitativos existentes y expertos en valoración de acciones. El rendimiento de la negociación de sistemas fue del 8,50 %. superó a conocidos expertos comerciales.
[269]	SISTEMA EXPERTO 2009 APLICACIÓN	207 SVR Este estudio demuestra la eficacia de una arquitectura de dos etapas para mejorar el stock Predicción de precios en comparación con un único modelo SVM, lo que ofrece una alternativa prometedora para la previsión de series temporales financieras.
[270]	SISTEMA EXPERTO 2009 APLICACIÓN	203 ANA Este estudio desarrolla un sistema integrado que combina ventanas de tiempo dinámicas, razonamiento basado en casos y una red neuronal para predecir puntos de decisión de compra/venta de acciones. Comercio. El novedoso enfoque reduce eficazmente las falsas alarmas en la toma de decisiones.
[271]	2007 LIE TRANSACCIONES	125 SVR, MLP Este estudio aplica redes de perceptrones multicapa (MLP) y SVR con varios insumos para predecir los valores futuros de las acciones, teniendo en cuenta la influencia de los factores financieros Indicadores y análisis técnico.

Diversos campos con una personalización mínima para datos financieros. Sin embargo, el aprendizaje profundo... ha desplazado el enfoque hacia el desarrollo de modelos adaptados a los aspectos únicos de datos financieros. La clasificación de los métodos de aprendizaje profundo refleja esta evolución, organizando modelos basados en su alineación con las características distintivas de los datos financieros, subrayando el cambio hacia soluciones personalizadas en la investigación de precios de activos.

- Propiedades de las series de tiempo: Para el análisis del movimiento del mercado de valores, la entrada

Tabla 8: Trabajos representativos sobre modelos clásicos basados en ML en los últimos 10 años en términos de citas.

Revista del año de referencia	Modelo de citas	Contribución única
[7] FINANCIAMIENTO REV 2020 SEMENTAL	1.869 ENet, RF, GBRT, ANN	Este estudio compara los métodos de aprendizaje automático para medir el riesgo de los activos primas en la valoración empírica de activos. Es la primera publicación de un informe de alto nivel. Revista financiera para utilizar modelos de aprendizaje automático en el campo de los activos precios, destacando el reconocimiento del aprendizaje automático como una investigación paradigma en finanzas.
[272] EXPERTO 2015 APLICACIÓN DEL SISTEMA	1.185 ANN, SVM, RF, NBC	Este estudio evalúa cuatro modelos de predicción, a saber, ANN, SVM, RF, y NBC, para el movimiento de acciones y la predicción del índice de precios de acciones. RF demuestra el rendimiento general más alto entre los cuatro modelos.
[273] EXPERTO 2015 APLICACIÓN DEL SISTEMA	698 RF, AB, KF, ANN, LR, SVM, KNN	Este estudio compara el rendimiento de los métodos de conjunto (RF, Ad-aBoost (AB) y Kernel Factory (KF)) frente a los modelos de clasificador único. (ANN, LR, SVM y KNN). Los resultados demuestran la superioridad de RF, seguido de SVM, KF, AB, ANN, KNN y LR.
[274] 2014 J MATEMÁTICAS	698 ARIMA, ANA	Este estudio compara el rendimiento de pronóstico de ARIMA y ANN Modelos basados en datos de la Bolsa de Valores de Nueva York. Los resultados muestran la superioridad del modelo ANN sobre ARIMA en la predicción del precio de las acciones.
[275] 2014 CONOCIMIENTO-SISTEMA BASADO	556 SVM	Este estudio mejora la predicción del precio de las acciones al utilizar el sentimiento financiero. diccionarios para construir un espacio de sentimientos, mejorando los modelos anteriores de bolsas de palabras.
[70] EXPERTO 2017 APLICACIÓN DEL SISTEMA	449 ANN, SVM, RF	Este estudio propone una metodología para evaluar el valor predictivo de los datos de microblogging para las variables del mercado bursátil. Incorpora el sentimiento. y indicadores de atención de Twitter e índices de encuestas.
[276] <small>Logo de Campos de la A a la Z de 2015</small>	326 LDA	Esta investigación mejora la precisión de la predicción del precio de las acciones en un 6,07 % en comparación con un modelo basado en precios históricos mediante la incorporación de análisis simultáneos de temas y sentimientos de datos de redes sociales.
[277] 2018 J FINANC DATOS CIENCIA	327 SVR	Este estudio utiliza SVR para predecir los precios de las acciones en varios mercados. segmentos y frecuencias. Los hallazgos destacan la eficacia predictiva de SVR, particularmente con actualizaciones regulares del modelo.
[52] 2014 INFORM SCI-ENCINAS	299 SVR	Este estudio utiliza un modelo SVR para predecir los movimientos bursátiles según los medios de comunicación, considerando tanto las noticias como el estado de ánimo del público. Los hallazgos sugieren que las acciones se ven influenciadas por artículos sobre cuestiones de reestructuración y ganancias. Además, las empresas que operan en sectores de la vida cotidiana demuestran una mayor previsibilidad en comparación con otras empresas.
[8] 2022 J FINANC ECON	259 LAZO, GBRT, RF, ANA	Este estudio examina una amplia gama de factores de predicción de retorno utilizando diversos algoritmos de aprendizaje automático. Representa la primera publicación en un Una importante revista financiera empleará modelos de aprendizaje automático para la fijación de precios de activos. en el mercado chino.
[278] 2020 J AMB INTEL ZUMBIDO COM-PONER	256 RF	Este estudio examina el impacto de las redes sociales y los datos de noticias financieras. sobre la precisión de las predicciones del mercado de valores a diez días. Integración de estos... Las fuentes de datos logran un rendimiento predictivo superior.
[279] EXPERTO 2019 APLICACIÓN DEL SISTEMA	147 EMD2FNN.	Este estudio presenta EMD2FNN, un enfoque híbrido que combina la descomposición modal empírica y una red neuronal basada en una máquina de factorización, para la predicción de tendencias del mercado bursátil. Los resultados experimentales demuestran un rendimiento superior del método propuesto en comparación con los enfoques tradicionales en condiciones similares.
[280] 2016 DECIS SUP-SISTEMA DE PUERTO	113 MKL	Este estudio utiliza la técnica MKL para integrar información de múltiples categorías de noticias, demostrando la concurrencia y la adecuación Uso ponderado de artículos periodísticos para la previsión financiera.
[281] 2018 APPL SOFT COMPUT	111 WNN	Este estudio propone un método de red neuronal Wavelet (WNN) para predecir la tendencia del precio de las acciones basado en un conjunto aproximado, que reduce las dimensiones de entrada. y optimiza la estructura para un mejor rendimiento.
[26] 2016 ACM T IN-SISTEMA DE FORMULARIO	95 STR	Este estudio presenta el modelo STR, un enfoque basado en tensores que captura los impactos interactivos de factores clave en precios de acciones específicas. El modelo propuesto se basa en el modelo SVR y logra resultados significativos. mejoró el rendimiento algorítmico, duplicando su eficacia.
[282] 2015 AAAI	51 TENSOR REGRESA-SIÓN	Este estudio propone un enfoque de aprendizaje de regresión tensorial supervisada para Explorar el impacto conjunto de diferentes fuentes de información en los mercados de valores. A diferencia de los enfoques anteriores que concatenan características de varias fuentes de información en un solo vector, este estudio modela el multifacético Información de los inversores y sus vínculos intrínsecos mediante tensores. El enfoque propuesto busca identificar patrones no lineales entre los movimientos bursátiles y la nueva información.

Tabla 9: Influencia de las revistas en función de las publicaciones que utilizan modelos clásicos basados en ML.

Diario	Número	Citas	Publicaciones
APLICACIÓN DE SISTEMA EXPERTO	32	11.273	[70], [283], [284], [273], [272], [285], [250], [286], [287], [260], [261], [288], [270], [269], [289], [290], [291], [292], [293], [262], [294], [279], [295], [296], [297], [298], [299], [294], [70], [279], [300], [258]
SISTEMA BASADO EN EL CONOCIMIENTO	7	1.211	[301], [275], [302], [303], [304], [305], [306]
SISTEMA DE SOPORTE DECIS	6	1.945	[53], [280], [266],[307], [267], [308]
INFORMAR CIENCIAS	4	917	[52], [309], [310], [311]
APPL SOFT COMPUT	4	440	[312], [281], [313], [314]
ENG APPL ARTIF INTEL	4	129	[315], [316], [317], [318]
INFORMAR PROCESO DE GESTIÓN 3		712	[18], [319], [320]
SIGKDD	3	532	[321], [322], [323]
SISTEMA DE INFORMACIÓN ACM T	2	1.352	[26], [19]
ECONOMÍA INFORMÁTICA	2	682	[324], [325]
COMPUTACIÓN SUAVE	2	114	[326], [327]

Tabla 10: Influencia de las instituciones de investigación en función de las publicaciones que utilizan modelos clásicos basados en ML.

Instituto	Número	Citas	Artículos
Universidad de Arizona	6	2.240	[19], [328], [18], [329], [267], [282], [26]
Universidad del Suroeste de Fi- Finanzas y economía	6	639	[52], [282], [284], [330], [53], [26]
Universidad de la Ciudad de Hong Kong	4	638	[331], [332], [275], [333]
Universidad de Tsinghua	4	246	[334], [335], [336], [323]
Instituto de Tecnología de Harbin	3	401	[269], [337], [338]
Universidad Nacional de Taiwán	3	246	[269], [337], [339]
Universidad Yuan-Ze	2	631	[290], [340]
Universidad de Friburgo	2	562	[266], [341]
Universidad de Fundan	2	150	[342], [283]
Universidad de Wisconsin	2	131	[343], [344]
Academia China de Ciencias	2	130	[345], [346]
Universidad de Correos y Telégrafos de Beijing Telecomunicaciones	2	72	[347], [315]

Los datos de formación exhiben propiedades de series temporales significativas, donde los resultados de los datos de entrada actuales se ven afectados por los datos de entrada anteriores [77, 65]. El temporal La función de memoria de las redes neuronales recurrentes (RNN) les permite capturar cambios en los precios de las acciones a lo largo del tiempo, lo que las hace muy adecuadas para la simulación de máquinas. Aplicaciones del aprendizaje en la predicción del mercado bursátil. Por ejemplo, Zhang et al. Se utilizaron RNN para predecir la volatilidad de las acciones a corto plazo de 50 empresas que cotizan en bolsa. [322]. El estudio encontró que los modelos RNN que incorporan la frecuencia de Las transacciones de datos y las series temporales de datos superan a las DNN tradicionales, lo que produce

Resultados superiores en la predicción de la volatilidad de las acciones. Sin embargo, las RNN tradicionales sufren el problema de la desaparición del gradiente durante la retropropagación a través de... tiempo, lo que limita su capacidad para capturar dependencias a largo plazo en series de tiempo datos, como los precios de las acciones. Este problema se conoce comúnmente como el "olvido". Problema. Para abordar esta limitación, se introdujo el modelo LSTM. LSTM es una arquitectura RNN extendida con mecanismos de control especializados (entrada puertas, puertas de olvido y puertas de salida), que aborda eficazmente el olvido problema al retener y actualizar selectivamente la información, lo que permite modelo para mantener la memoria a largo plazo de los patrones históricos de precios. Como resultado, LSTM surgió como una herramienta destacada e influyente para predecir el mercado de valores. movimientos, ganando popularidad y reconocimiento significativos en el campo. Akita et et al. emplearon un modelo basado en LSTM para investigar el impacto de los eventos noticiosos sobre los movimientos de las acciones y descubrió que LSTM superó a otros modelos como DNN, SVR y Simple-RNN en términos de precisión [71]. Li et al. introdujeron Un modelo LSTM impulsado por eventos que supera a las DNN tradicionales en la captura Los variados impactos de los factores clave en la determinación del precio de los activos en diferentes intervalos de tiempo [12]. En los últimos tiempos, los modelos de lenguaje grande (LLM) basados en transformadores han demostrado ser prometedores para mejorar la captura de datos financieros. Secuencias y comprensión de los medios en la investigación del movimiento del mercado bursátil. El mecanismo de atención utilizado en la arquitectura del Transformer permite la captura bidireccional de dependencias entre todas las posiciones de entrada en la serie, en A diferencia de las RNN, que capturan secuencialmente las dependencias dentro de una longitud fija. Ventana de entradas pasadas. Esto es particularmente relevante para el mercado de valores financieros. pronóstico, donde las tendencias pasadas pueden influir en las tendencias futuras a lo largo del tiempo intervalo. Además, los LLM basados en Transformer pueden aprovechar la formación previa en grandes cantidades de datos textuales, como artículos de noticias, informes financieros y redes sociales publicaciones en los medios, para aprender representaciones del lenguaje natural específicas del dominio. Estas Las representaciones aprendidas pueden transferirse a tareas posteriores de pronóstico del mercado de valores financiero [350]. Ding et al. descubrieron que los LLM basados en Transformer propuestos superan a los LSTM en la captura de dependencias a muy largo plazo. a partir de datos de series temporales financieras [351]. López-Lira y Tang muestran que la integración de ChatGPT, un modelo avanzado de lenguaje grande, para el análisis de sentimientos de Los titulares de noticias mejoran las predicciones de la rentabilidad del mercado de valores y optimizan las estrategias de negociación cuantitativa [352]. Gao et al. presentaron StockFormer, un híbrido Máquina comercial que combina codificación predictiva con aprendizaje de refuerzo Optimizar las políticas comerciales considerando la dinámica futura y las correlaciones de activos, superando significativamente los métodos existentes en los retornos de la cartera y Índices de Sharpe en tres conjuntos de datos financieros [353].

- **Interacciones factoriales:** En la investigación financiera, la importancia de las interacciones entre los factores que revelan los movimientos bursátiles ha cobrado importancia [7]. Por ello, los informáticos han comenzado a explorar formas de capturar los efectos de las interacciones entre diferentes categorías de factores, como los datos históricos de operaciones, noticias y el sentimiento en redes sociales. El enfoque tradicional implica Combinando estos diferentes tipos de información de mercado en un único vector de supercaracterísticas como entrada para el modelo, lo que puede descuidar las interacciones. Entre las diversas fuentes de información dimensional en el espacio de información de mercado heterogéneo de múltiples fuentes, Hoseinzade y Haratizadeh propusieron un modelo de aprendizaje profundo basado en CNN para manejar las interacciones entre diferentes fuentes de información del mercado a través de operaciones convolucionales [11]. mecanismo de reparto de peso de la capa convolucional y agrupamiento apropiado Las estrategias proporcionan a las CNN varios tipos de "invariancia", como la invariancia de rotación, que son aplicables a datos de entrada distribuidos espacialmente. Esto permite El modelo para capturar las correlaciones entre diferentes dimensiones del mercado información. Huang et al. aplicaron DNN y CNN para predecir el efecto de La información del sentimiento público de Twitter sobre los precios de las acciones y determinaron la superioridad de las CNN sobre las DNN [72]. Ding et al. utilizaron CNN para explorar la Influencia de los medios de Internet y los datos comerciales históricos en los movimientos del mercado [349]. Sin embargo, las capas convolucionales de las CNN pueden resultar en pérdida de información debido a a las operaciones de agrupamiento y la elección del tamaño del filtro, lo que afecta el modelo. Capacidad para capturar características de interacción. Para abordar esto, Huang et al. propusieron Un módulo estático basado en matrices que fusiona diferentes factores, considera las interacciones entre características y reduce la pérdida de información [354]. Experimentos con datos de mercado reales. demostró la eficacia de este enfoque sobre las CNN. Además, Cheng y Li introdujo un nuevo enfoque de modelado estático basado en tensores para capturar señales de mercado multimodales con interacciones no lineales de orden superior [31]. a módulos estáticos basados en matrices, que capturan solo interacciones de segundo orden, El enfoque basado en tensores tiene un mayor poder expresivo y explicativo. interacciones complejas entre diferentes factores. Experimentos realizados utilizando Tres años de datos demostraron la superioridad del modelo basado en tensores propuesto. acercarse.
- **Efectos de contagio del momentum:** Las investigaciones realizadas en el campo de las finanzas han reveló que la volatilidad de una empresa que cotiza en el mercado de valores puede verse influenciada Debido a la volatilidad de las empresas asociadas, se creó un fenómeno conocido como efecto de derrame de momentum [30, 58, 29]. A pesar del reconocimiento de este fenómeno, Pocos modelos financieros han capturado eficazmente el impacto del impulso

Efecto de derrame en los mercados bursátiles. En los últimos años, el campo de la informática ha presenciado avances en las redes neuronales de grafos (GNN), un enfoque prometedor para representar la relevancia de las empresas utilizando representaciones gráficas como entrada para las redes neuronales. Las GNN permiten asociar empresas en función de diversos factores, como relaciones de cooperación y competencia, conexiones en la cadena de suministro y asociaciones reportadas por los medios de comunicación, formando así una red compleja de empresas asociadas para el estudio del fenómeno de derrame de momentum.

Por ejemplo, Li et al. propusieron el modelo Msub-GNN, que incorpora datos de revisión de acciones en la relación gráfica y predice la volatilidad de las acciones relacionadas al considerar la dirección de transmisión de información a lo largo de los bordes [62]. Chen et al. presentaron un método novedoso para la predicción de tendencias bursátiles utilizando un modelo CNN basado en características convolucionales de gráficos que integra tanto información del mercado de valores como información de acciones individuales [355]. Para investigar los efectos de derrame de impulso de las relaciones corporativas que varían con el tiempo, Li et al. propusieron un modelo LSTM-RGCN que utiliza datos comerciales históricos entre acciones para modelar una matriz dinámica de correlaciones entre acciones y conecta nodos de acciones [61]. Los hallazgos de estos estudios indican que la integración de series de tiempo y métodos basados en gráficos supera el rendimiento de los modelos clásicos de aprendizaje automático y LSTM. En contraste con la construcción de una red de relaciones corporativas basada en asociaciones conocidas, Cheng y Li introdujeron AD-GAT, que emplea un mecanismo de atención para detectar efectos de derrame de impulso implícito en señales de mercado que cambian dinámicamente, mostrando un desempeño superior en comparación con los modelos GNN y LSTM convencionales [31].

Resumiendo los avances recientes, los modelos de aprendizaje profundo en finanzas muestran una clara progresión: aquellos que capturan series temporales superan a las DNN estándar, los modelos que analizan interacciones factoriales superan a los de series temporales, y los de mejor desempeño son aquellos que capturan los efectos indirectos del momentum de la empresa. Esta tendencia de eficiencia y efectividad se detalla en la Figura 7. Específicamente, las RNN, especialmente con datos de series temporales y frecuencia de transacciones, muestran predicciones mejoradas de la volatilidad de las acciones, como lo señalaron Zhang et al. [322]. La capacidad de LSTM para superar el problema de "olvido" de las RNN ha demostrado ser superior para el análisis de tendencias bursátiles a largo plazo, como lo evidencian Akita et al. [71]. Además, los LLM basados en Transformer, que utilizan datos preentrenados extensos, superan a los LSTM al capturar dependencias de datos más amplias, un hallazgo respaldado por Ding et al. [351]. En el ámbito de la captura de interacciones factoriales, Huang et al. demostraron que las CNN superan a las DNN al aprovechar el sentimiento de Twitter y los datos históricos para las predicciones del precio de las acciones [72]. Para contrarrestar la pérdida de información en las CNN, Huang et al. introdujeron un módulo estático basado en matrices que mejoró el análisis de interacción de características, superando a las CNN en pruebas empíricas [354]. Además, el enfoque basado en tens

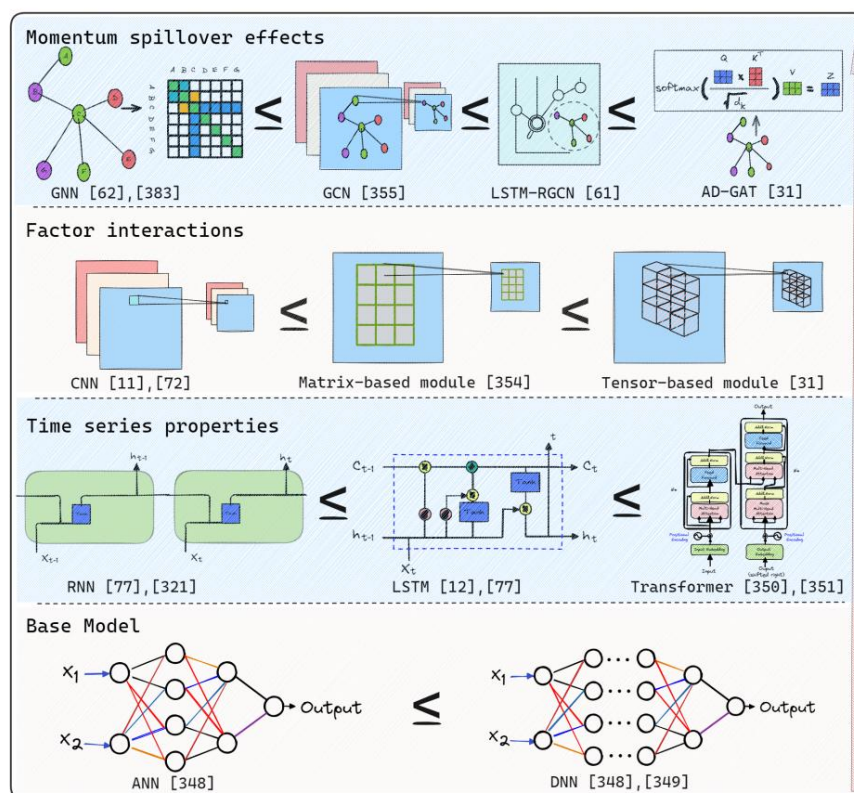


Figura 7: Eficiencia y eficacia de los modelos de aprendizaje profundo: una visión comparativa.

métodos basados en matrices para capturar señales de mercado multifacéticas [31]. Al estudiar Efectos de derrame de impulso: las redes neuronales de gran potencia (GNN) conectan hábilmente a las empresas a través de diversos factores, creando una red compleja para el análisis. El modelo CNN convolucional de gráficos de Chen et al. La fusión de datos específicos del mercado y de las acciones mejora la predicción de las tendencias bursátiles [355]. Li et al. El modelo LSTM-RGCN de et al., que utiliza datos comerciales históricos, supera los modelos LSTM y de aprendizaje automático tradicionales al capturar de manera efectiva las correlaciones dinámicas de acciones. [61]. Además, el modelo AD-GAT de Cheng y Li, que emplea un mecanismo de atención, supera a los métodos GNN y LSTM convencionales en la detección del momento. efectos de contagio [31].

En conclusión, los estudios recientes centrados en propiedades de datos como series temporales e interacciones de factores han hecho avanzar significativamente la fijación de precios de activos, superando a los métodos tradicionales. DNN [72, 354, 322, 71]. Las investigaciones futuras deberían explorar más a fondo las características únicas de los datos del mercado financiero para optimizar los modelos de aprendizaje profundo para la fijación de precios de activos. La investigación de los efectos de contagio del momentum también representa una oportunidad para mejorar la predicción.

modelos alineándolos con los principios económicos que subyacen a la dinámica del mercado [61, 31]. Además, dado que los modelos econométricos tienen como objetivo aclarar la causalidad Entre los factores clave y la fijación de precios, la interpretabilidad de los modelos es fundamental. Por lo tanto, Mejorar la interpretabilidad de los modelos de aprendizaje profundo, especialmente aquellos que diseccionan La mecánica de los movimientos bursátiles es fundamental. Utilizar mecanismos de atención... El aprendizaje profundo ofrece una vía prometedora para identificar las causas subyacentes de los movimientos de acciones, lo que permite a las partes interesadas comprender mejor los riesgos del mercado.

Para mapear la evolución de los esfuerzos de predicción de acciones utilizando aprendizaje profundo y pronosticar su trayectoria, una selección curada de obras representativas organizadas por Se presenta su cronología de publicaciones y contribuciones. Además, se ofrece una visión general de las principales revistas y conferencias (según su inclusión en Computing Research & Clasificación de Educación (CORE) y Métricas de Google Académico) e instituciones de investigación Se proporciona información en función de su prolificidad en este campo.

- Trabajos representativos: La Tabla 11 proporciona una descripción general completa de estudios influyentes en el campo de la predicción del mercado de valores utilizando modelos basados en aprendizaje profundo, que se han publicado en revistas o conferencias de renombre. Cada estudio se acompaña de comentarios detallados para destacar sus contribuciones únicas. Esta tabla ofrece una perspectiva holística sobre el desarrollo de la... Modelos basados en el aprendizaje en la predicción del mercado bursátil. Por lo tanto, facilita la identificación de tendencias emergentes que dan forma a la trayectoria de este campo.
- Revistas o congresos: Para investigar las principales revistas y congresos En el campo de la predicción de movimientos bursátiles mediante modelos basados en aprendizaje profundo, presentamos clasificaciones basadas en la frecuencia de artículos publicados en foros relevantes, como la Conferencia AAAI sobre Inteligencia Artificial. (AAAI), que incluye 12 artículos [356, 31, 357, 358, 359, 360, 361, 55, 362, 363, 364, 365]; la Conferencia Conjunta Internacional sobre Inteligencia Artificial (IJCAI), que presenta 8 artículos [349, 366, 351, 367, 368, 369, 370, 353]; IEEE Transactions on Knowledge and Data Engineering, que presenta 7 artículos [12, 371, 372, 57, 373, 374, 375]; Applied Soft Computing, que incluye 4 artículos [376, 377, 378, 379]; Descubrimiento de conocimiento y minería de datos de ACM (SIGKDD), que incluye 2 artículos [322, 380]; ACM Transactions on Information Systems, con 1 artículo [13]; la Conferencia Internacional sobre Máquinas de Aprendizaje (ICML), que incluye 1 artículo [381].
- Instituciones de investigación: Sólo unas pocas instituciones de investigación seleccionadas han exhibido Un compromiso sostenido con el estudio de modelos basados en aprendizaje profundo en el campo de predicción del mercado de valores durante la última década, como lo demuestra su historial de publicaciones de tres o más artículos sobre el tema. Las instituciones de investigación

En este sentido, cabe citar la Universidad Southwestern de Finanzas y Economía (11 artículos [12, 31, 369, 354, 382, 383, 372, 62, 384, 374, 385]), la Universidad de Pekín (7 artículos [386, 366, 357, 380, 367, 387, 375]), el Instituto Tecnológico de Nanyang Universidad (5 artículos [388, 360, 389, 390, 391]), Instituto de Tecnología de Harbin (4 artículos [349, 392, 393, 394]), Universidad Jiao Tong de Shanghai (3 artículos [395, 358, 396]), Universidad de Ciencia y Tecnología de China (3 artículos [397, 398, 359]) y la Universidad de Ciencia y Tecnología Electrónica de China (3 artículos [399, 400, 401]). Además, varias instituciones, entre ellas la Universidad del Sur, la Universidad de Pensilvania 12, han hecho contribuciones notables al campo de Pronóstico del mercado de valores mediante la oferta de conjuntos de datos de prueba de acceso público. Estos conjuntos de datos sirven como recursos indispensables que permiten a los investigadores evaluar y comparar la efectividad de sus modelos con puntos de referencia estandarizados.

En resumen, la fijación de precios de activos en finanzas cuenta con una historia ilustre que se extiende a lo largo de Ocho décadas, marcadas por métodos de investigación consolidados y logros notables. Sin embargo, las limitaciones de los modelos econométricos han impulsado una integración de técnicas de aprendizaje automático, lo que proporciona una nueva perspectiva sobre este tema de larga data. Tema. En las primeras etapas, los estudios pioneros adoptaron métodos predictivos bien establecidos. modelos de otros dominios, como KNN, árboles de decisión y SVM, para abordar la Las complejidades de la fijación de precios de activos con aprendizaje automático. Posteriormente, reconociendo la propiedades únicas de los movimientos de acciones, se utilizaron técnicas de aprendizaje profundo cuidadosamente Se incorporaron para atender estas características distintivas de la fijación de precios de activos. Este enfoque innovador ha allanado un camino prometedor para la aplicación del aprendizaje automático. en la fijación de precios de los activos. Sin embargo, el camino hacia una fusión fluida de máquinas... El aprendizaje de técnicas de fijación de precios de activos sigue siendo un trabajo en progreso y se han realizado importantes inversiones. Se requieren esfuerzos para alcanzar este ambicioso objetivo.

4. Conclusión

La fijación de precios de los activos es una piedra angular de la teoría financiera, reconocida a través del Premio Nobel. Premios otorgados a destacados expertos como Harry M. Markowitz, William F. Sharpe, Eugene F. Fama y Robert F. Engle. Métodos econométricos tradicionales en finanzas. A pesar de su énfasis en la causalidad, a menudo no logran dilucidar por completo los intrincados problemas Dinámica del mercado bursátil. La integración de la Inteligencia Artificial (IA) introduce...

¹⁰FactorWiki: <https://factorwiki.zxlearn.cn/factor>.

¹¹Centro de Investigación de Precios de Valores (CRSP): <https://www.crsp.org>.

¹²Servicios de Datos de Investigación de Wharton (WRDS): <https://wrds-www.wharton.upenn.edu>

Tabla 11: Contribuciones de trabajos representativos con el método de aprendizaje profundo.

Revista del año de referencia [349]	Modelo	Contribución única
IJCAI 2015	CNN	Este estudio emplea una CNN para la predicción del mercado bursátil basada en eventos. Al extraer eventos de textos noticiosos y representarlos como vectores densos, la CNN... Capta las influencias a corto y largo plazo de estos eventos sobre los movimientos de los precios de las acciones.
[322] SIGKDD 2017	SFM RNN. Este estudio propone una RNN de Memoria de Estado y Frecuencia (SFM) para la predicción del precio de las acciones, capturando patrones multifrecuenciales en datos de mercado. Supera a los modelos autorregresivos y LSTM en experimentos con datos de precios reales.	
[371] 2018 IEEE T KNOWL DATOS EN	DNN	Este estudio presenta DeepClue, un sistema diseñado para facilitar la interpretación de modelos de aprendizaje profundo basados en texto para la predicción del precio de las acciones. DeepClue visualmente Presenta los factores clave aprendidos por el modelo, cerrando la brecha entre el modelo y los usuarios finales.
[13] 2019 ACM T INFORM SISTEMA	TGCNN	Este estudio formula la predicción de acciones como una tarea de clasificación e introduce un marco de clasificación relacional de acciones. Este marco incorpora un gráfico temporal. Componente de red neuronal convolucional (TGCNN), que captura eficazmente las relaciones sensibles al tiempo entre existencias y codifica las relaciones entre existencias para mejorar precisión de predicción.
[12] 2020 IEEE T KNOWL DATOS EN	Impulsado por eventos LSTM	Este estudio presenta un modelo LSTM impulsado por eventos y basado en tensores para abordar los desafíos relacionados con la integración de la información y la heterogeneidad de los datos de entrada en el inventario. predicción. Los resultados experimentales muestran el rendimiento superior de la propuesta Enfoque comparado con algoritmos de última generación.
[357] 2020 AAAI	Vista múltiple Red de fusión	Este estudio presenta un análisis exhaustivo de las revisiones de acciones públicas y sus Utilidad para predecir los movimientos bursátiles. El estudio propone un marco de aprendizaje profundo que consta de tres componentes clave: detección de la postura de inversión sensible al tiempo y al objetivo, agregación dinámica de posturas basada en expertos y análisis de acciones. predicción de movimiento.
[61] IJCAI 2020	LSTM-RGCN	Este estudio propone el modelo de red convolucional de gráficos relacionales LSTM (LSTM-RGCN) para capturar interconexiones entre acciones utilizando su correlación. Matriz. Los resultados destacan la capacidad del modelo para predecir los movimientos bursátiles más allá de la influencia de las noticias y brindan información sobre el comportamiento general del mercado.
[381] 2020 ICML	LFMs	Este estudio compara el rendimiento de los modelos de FLactor Lookahead (LFM), incluyendo MLP, LSTM y RNN, con enfoques de factores estándar para acciones predicción. Los resultados revelan la superioridad de los LFM tanto en términos absolutos rendimientos y rendimientos ajustados al riesgo.
[57] 2021 IEEE T KNOWL DATOS EN	FinGAT	Este estudio presenta las redes de atención de gráficos financieros (FinGAT) para recomendar las K mejores acciones rentables según la tasa de retorno utilizando series temporales de acciones. precios e información del sector, sin depender de relaciones predefinidas entre acciones.
[31] 2021 AAAI	AD-GAT	Este estudio propone una red de atención gráfica basada en atributos (AD-GAT), para Efectos indirectos del momento del modelo. AD-GAT considera los efectos indirectos sensibles a los atributos mediante multiplicando los atributos transformados de las empresas conectadas e infiriendo una empresa dinámica relaciones a partir de señales del mercado utilizando un mecanismo de atención desenmascarado.
[372] 2022 IEEE T KNOWL DATOS EN	DAN	Este estudio construye un gráfico de conocimiento del mercado híbrido bitipificado (MKG) para modelar El impulso bursátil se extiende a los mercados financieros reales. Además, propone un modelo dual. Redes de Atención (DAN) con módulos de atención interclase e intraclase para Conozca las características de propagación del impulso de las acciones en el MKG construido.
[369] IJCAI 2022	S-GRN	Este estudio presenta S-GRN, una red de enrutamiento de gráficos basada en subsecuencias, para Propagación del riesgo de variantes entre entidades de series temporales. S-GRN emplea dinámica Mecanismos de mensajería entre pares de nodos basados en dependencias de patrones de subsecuencia.
[383] 2022 INFORM SCI- ENCIAS	FinHGNN	Este estudio presenta una nueva red neuronal de grafos heterogéneos condicionales (FinHGNN) para capturar múltiples efectos indirectos en la fijación de precios de activos. La Fin-HGNN incorpora dos mecanismos de diseño único: preserva la conectividad de los atributos relacionales y utiliza un mecanismo de paso de mensajes condicional.
[373] 2023 IEEE T KNOWL DATOS EN	HATR-I	Este estudio propone una interacción temporal-relacional adaptativa jerárquica Modelo HATR-I para la predicción de tendencias bursátiles. El HATR-I captura eficazmente las regularidades de transición a corto y largo plazo de la dinámica bursátil mediante el uso de modelos dilatados en cascada. convoluciones y caminos de compuerta.
[353] IJCAI 2023	StockFormer	Este estudio presentó StockFormer, una máquina de comercio híbrida que combina codificación predictiva con aprendizaje de refuerzo para optimizar las políticas comerciales al considerar dinámicas futuras y correlaciones de activos.[353].
[364] 2024 AAAI	MDGNN	Este estudio presenta la red neuronal gráfica dinámica multirrelacional Marco (MDGNN), que utiliza un gráfico dinámico para capturar relaciones en evolución entre acciones, proporcionando una perspectiva holística sobre sus interconexiones.
[379] 2024 APPL SOFT COMPUT	MV-LSTM	Este estudio presenta un modelo LSTM multivariado (MV) que estima el futuro Valores de las acciones mediante el análisis de datos históricos de acciones relacionadas, utilizando información dentro de la ventana Normalización e información con estado para detectar dependencias ocultas.

Nuevas perspectivas que ofrecen un mayor potencial a este valioso dominio. aprendizaje automático, Gu et al., en un artículo fundamental en la Review of Financial Studies, investigaron el impacto de 94 factores en la volatilidad del mercado, revelando el aprendizaje automático. ventaja sobre los enfoques tradicionales [7]. En apoyo de esto, el trabajo de Leippold et al. en el Journal of Financial Economics confirmó ventajas similares [8]. Ambas revistas son muy valoradas en los círculos financieros. En otras palabras, Gu et al. y Leippold et al. fueron Estudios pioneros en finanzas que introdujeron y utilizaron redes neuronales BP como paradigma de investigación para la fijación de precios de activos en los mercados de Estados Unidos y China, respectivamente. Su trabajo destacó esencialmente el potencial de incorporar técnicas modernas de IA a la investigación financiera clásica. A medida que se desarrolla este nuevo paradigma, los investigadores están... Analizando cada vez más la influencia colectiva de los factores clave en los precios de los activos a través de modelos avanzados de aprendizaje automático. Este cambio representa un alejamiento de los silos El enfoque causal de la econometría tradicional se dirige a revelar la mecánica compleja detrás de los movimientos de las acciones.

En este riguroso análisis se revisan 782 artículos académicos, destacando la fusión de finanzas y ciencias de la computación para navegar en este territorio complejo. Basándonos en esta revisión sistemática y en esfuerzos anteriores en la fijación de precios de activos con máquinas aprendizaje[12, 26, 31, 52, 53, 354, 382, 383, 372, 282, 284, 330, 369, 374], el estudio aboga por estudios futuros para explorar las siguientes tres direcciones prometedoras para investigación:

- Descifrando patrones en medio del ruido: mientras los académicos exploran las complejidades de los datos del mercado financiero, como las series temporales y las interacciones de los factores, Para refinar sus modelos analíticos, se enfrentan a un desafío notable: la prevalencia de factores de ruido. Los mercados financieros son un sistema dinámico, donde numerosos Los factores sirven como elementos esenciales. A diferencia de la claridad del impacto que cada palabra... o píxeles que tenga en el texto o las imágenes, donde las inexactitudes sean fácilmente identificables, Los factores de los mercados financieros son complejos y están envueltos en un ruido sustancial e irreconocible. Este ruido a menudo oculta los verdaderos patrones, lo que dificulta... Para identificar y priorizar con precisión los factores clave. Por lo tanto, el alto nivel de ruido... En la valoración de activos, los factores pueden verse desde dos perspectivas. Primero, los factores influyentes están ocultos entre miles de factores potenciales. Segundo, incluso Dentro de un factor importante de serie temporal, sólo una pequeña porción puede ser influyente en la configuración del mercado. Esta complejidad hace que sea inadecuado aplicar directamente modelos de aprendizaje automático bien desarrollados de otras áreas, lo que requiere... Surgimiento de un nuevo campo de investigación llamado AIECON (IA para la Economía). Esto es Uno de los puntos de partida de esta revisión de investigación, donde las finanzas tradicionales La investigación está siendo transformada por las modernas tecnologías de IA, lo que da lugar al surgimiento de un campo interdisciplinario. Para distinguir los patrones verdaderos del ruido,

Se requiere un enfoque sistemático que abarque la extracción de características de los datos y Diseño de modelos sofisticados. El trabajo notable en esta área incluye soluciones para Explorar y extraer interacciones de características [374] y capturar factores más influyentes, como la información de los medios [12] y los estados de las empresas relevantes.

[31] Los avances recientes en transformadores con mecanismos de atención son prometedores. al destacar características o subsecuencias importantes de series temporales para la fijación de precios de activos [369].

- Integración de principios económicos fundamentales en la construcción de modelos: incorporación de supuestos o teorías económicas en el diseño de máquinas.

El aprendizaje es un espíritu esencial de la IA para las finanzas. En la investigación textual, el enfoque es en palabras, considerados los "átomos más pequeños", mientras que en el análisis de imágenes, estos átomos son píxeles. Sin embargo, en el ámbito del mercado financiero, los "átomos más pequeños" son representada por más de mil factores influyentes complejos e impredecibles.

La llegada de modelos a gran escala ofrece un enfoque novedoso para comprender La intrincada dinámica del sector financiero al hacer predicciones a nivel de estos "átomos más pequeños". Sin embargo, la aplicación de estos modelos al sector financiero presenta desafíos sustanciales debido a los numerosos factores involucrados y Su intensa volatilidad, que complica el entrenamiento del modelo, es crucial.

La futura dirección de la investigación es cómo integrar eficazmente los conocimientos económicos fundamentales. principios en modelos. Esta integración ayuda a limitar las interacciones impredecibles entre los "átomos más pequeños" o factores. Las primeras investigaciones se remontan a...

Volviendo al profesor Yu Zheng, quien rediseñó la función de pérdida de las redes neuronales para Asegurar la monotonía de la volatilidad implícita utilizando un modelo de valoración de opciones basado en Black-Scholes [402]. En el mercado bursátil, para capturar los efectos de contagio del impulso Entre poblaciones, los trabajos piloto utilizaron redes neuronales de grafos clásicas. Sin embargo, las redes neuronales de grafos convencionales no pueden capturar correlaciones con diferentes desfases temporales. y escalas debido al diseño de la matriz de compartición. Cheng y Li propusieron una Esquema para diseñar un nuevo mecanismo de paso de mensajes en GNN basado en la fenómeno de adelanto-rezago (o supuestos) en la economía, logrando algún resultado positivo Resultados [369]. Se pueden encontrar más detalles en estudios recientes en AAAI [31] y IEEE TKDE [374]. Sin embargo, la incorporación de supuestos o teorías económicas El diseño de modelos de aprendizaje automático aún está en sus inicios y requiere Análisis y exploración más profundos.

- Mejorar la interpretabilidad de los modelos de aprendizaje profundo: si bien la investigación actual se centra principalmente en impulsar el rendimiento de los modelos de aprendizaje profundo, En los modelos, existe una brecha significativa en la provisión de explicaciones visuales de los factores influyentes. Esta falta de transparencia es particularmente problemática en el sector financiero.

Donde comprender la lógica detrás de las predicciones del modelo es crucial para una toma de decisiones informada y la prevención de riesgos. Métodos econométricos tradicionales. Pueden analizar la causalidad entre los fenómenos, pero tienen dificultades para retratar cómo Estas relaciones se desarrollan gradualmente y conducen al resultado final. Para las repercusiones del momentum en la valoración de los activos, los métodos econométricos tradicionales pueden determinar que otras empresas influyan en la empresa objetivo. Sin embargo, debido a que La influencia de otras empresas se comprime en un simple escalar en el modelo econométrico, es imposible rastrear qué empresas están influyendo en el mercado. objetivo y cómo se transmite esta influencia. En contraste, las GNN convencionales puede identificar qué empresas tienen influencia. Desafortunadamente, porque La influencia entre nodos en las redes neuronales globales (GNN) se transmite a través de múltiples capas de transformación no lineal, por lo que es difícil rastrear los detalles de estas influencias. En un estudio piloto, Cheng y Li utilizaron un único proceso lineal de transmisión y agregación de mensajes para mantener la interpretabilidad del modelo. Por lo tanto, en el estudio de En los modelos interpretables de IA para las finanzas, se deben abordar dos niveles de cuestiones. En primer lugar, los métodos de aprendizaje profundo deben proporcionar una interpretabilidad de nivel superficial (por ejemplo, En segundo lugar, los algoritmos de modelos de aprendizaje profundo deben mejorarse para satisfacer las demandas de interpretabilidad económica. proporcionando una interpretabilidad de nivel más profundo (por ejemplo, la fuerza de la influencia entre empresas en diferentes momentos y diversos factores influyentes). Esto plantea muy Altas exigencias para los investigadores, que necesitan comprender tanto las técnicas de aprendizaje profundo como las leyes fundamentales de la economía para diseñar modelos interpretables. que satisfagan necesidades reales.

Concentrarse en estas trayectorias de investigación puede impulsar la fijación de precios de activos mediante el aprendizaje automático, lo que podría conducir a descubrimientos significativos en este campo. Estos hallazgos podrían incluso merecer reconocimiento académico, como el Premio Nobel, por revelar los mecanismos ocultos de la fijación de precios de activos mediante el aprendizaje automático contemporáneo. Paradigmas. Sin embargo, aún queda mucho trabajo por hacer para integrar fluidamente la fijación de precios de activos con técnicas avanzadas de aprendizaje automático.

Para profesionales, 1231 factores influyentes y modelos básicos de aprendizaje automático Se compartieron a través de la plataforma FactorWiki, que puede ayudar a los profesionales rápidamente. Construir combinaciones entre diferentes modelos y factores para construir inversiones decisiones y prevención de riesgos. La plataforma también ofrece capacidades de análisis basadas en modelos de lenguaje de gran tamaño, que permiten una rápida visualización de datos y un análisis factorial en profundidad, y la construcción eficiente de modelos de valoración de activos. Esto mejora la eficiencia de la proceso y asegura la interpretabilidad de los modelos, tomando decisiones de inversión más confiable y persuasivo.

Referencias

- [1] X. Zhang, Incertidumbre de la información y rentabilidad de las acciones, *The Journal of Finance* 61 (1) (2006) 105–137.
- [2] JE Engelberg, CA Parsons, El impacto causal de los medios en los mercados financieros, *The Journal of Finance* 66 (1) (2011) 67–97.
- [3] B. Wuthrich, V. Cho, S. Leung, D. Permunetilleke, K. Sankaran, J. Zhang, Pronóstico diario del mercado de valores a partir de datos web textuales, en: *Actas de la conferencia SMC'98. Conferencia internacional IEEE de 1998 sobre sistemas, hombre y cibernética* (n.º de cat. 98CH36218), vol. 3, IEEE, 1998, págs. 2720-2725.
- [4] F. Li, El contenido informativo de las declaraciones prospectivas en los documentos corporativos: un enfoque ingenuo de aprendizaje automático bayesiano, *Journal of Accounting Research* 48 (5) (2010) 1049–1102.
- [5] CW Calomiris, H. Mamaysky, Cómo las noticias y su contexto impulsan el riesgo y los retornos en todo el mundo, *Journal of Financial Economics* 133 (2) (2019) 299– 336.
- [6] Y. Jeon, TH McCurdy, X. Zhao, Las noticias como fuentes de saltos en los retornos de las acciones: evidencia de 21 millones de artículos de noticias para 9000 empresas, *Journal of Financial Economics* 145 (2) (2022) 1–17.
- [7] S. Gu, B. Kelly, D. Xiu, Fijación de precios de activos empíricos mediante aprendizaje automático, *The Revista de Estudios Financieros* 33 (5) (2020) 2223–2273.
- [8] M. Leippold, Q. Wang, W. Zhou, Aprendizaje automático en el mercado de valores chino, *Revista de Economía Financiera* 145 (2) (2022) 64–82.
- [9] G. Rachlin, M. Last, D. Alberg, A. Kandel, Admiral: Un sistema de comercio financiero basado en minería de datos, en: *Simposio IEEE de 2007 sobre inteligencia computacional y minería de datos*, IEEE, 2007, págs. 720-725.
- [10] M.-A. Mittermayer, GF Knolmayer, Newscats: Un sistema de categorización y comercio de noticias, en: *Sexta Conferencia Internacional sobre Minería de Datos (ICDM)*, IEEE, 2006, págs. 1002-1007.
- [11] E. Hoseinzade, S. Haratizadeh, Cnnpred: Predicción del mercado de valores basada en CNN utilizando un conjunto diverso de variables, *Expert Systems with Applications* 129 (2019) 273–285.

- [12] Q. Li, J. Tan, J. Wang, H. Chen, Un modelo lstm multimodal impulsado por eventos para la predicción de acciones utilizando noticias en línea, *IEEE Transactions on Knowledge and Data Engineering* 33 (10) (2020) 3323–3337.
- [13] F. Feng, X. He, X. Wang, C. Luo, Y. Liu, T.-S. Chua, Clasificación relacional temporal para predicción de acciones, *ACM Transactions on Information Systems* 37 (2) (2019) 1–30.
- [14] EF Fama, KR French, Factores de riesgo comunes en los rendimientos de acciones y bonos, *Journal of Financial Economics* 33 (1) (1993) 3 – 56.
- [15] EF Fama, KR French, Un modelo de valoración de activos de cinco factores, *Journal of Financial Economics* 116 (1) (2015) 1–22.
- [16] SA Ross, La teoría del arbitraje en la fijación de precios de activos de capital, en: *Manual de los fundamentos de la toma de decisiones financieras: Parte I, Vol. 13*, World Scientific, 1976, págs. 341-360.
- [17] J. Bollen, H. Mao, X. Zeng, El estado de ánimo de Twitter predice el mercado de valores, *Journal de la ciencia computacional* 2 (1) (2011) 1–8.
- [18] RP Schumaker, H. Chen, Un sistema cuantitativo de predicción de acciones basado en noticias financieras, *Procesamiento de la información y gestión* 45 (5) (2009) 571–583.
- [19] RP Schumaker, H. Chen, Análisis textual de la predicción del mercado de valores utilizando noticias financieras de última hora: el sistema de texto azfin, *ACM Transactions on Information Systems* 27 (2) (2009) 1–19.
- [20] L. Cohen, A. Frazzini, C. Malloy, El pequeño mundo de la inversión: conexiones en juntas directivas y retornos de fondos mutuos, *Journal of Political Economy* 116 (5) (2008) 951–979.
- [21] L. Menzly, O. Ozbas, Segmentación del mercado y previsibilidad cruzada de retornos, *The Journal of Finance* 65 (4) (2010) 1555–1580.
- [22] CM Lee, ST Sun, R. Wang, R. Zhang, Vínculos tecnológicos y retornos predecibles, *Journal of Financial Economics* 132 (3) (2019) 76–96.
- [23] C. Gan, M. Lee, HHA Yong, J. Zhang, Variables macroeconómicas e interacciones del mercado de valores: evidencia de Nueva Zelanda, *Gestión de inversiones e innovaciones financieras* 4 (3) (2006) 89–101.

- [24] RD Gay Jr, Efecto de las variables macroeconómicas en los retornos del mercado de valores de cuatro economías emergentes: Brasil, Rusia, India y China, *International Business & Economics Research Journal (IBER)* 7 (3) (2008).
- [25] A. Humpe, P. Macmillan, ¿Pueden las variables macroeconómicas explicar los movimientos a largo plazo del mercado bursátil? Una comparación entre Estados Unidos y Japón, *Applied Financial Economics* 19 (2) (2009) 111–119.
- [26] Q. Li, Y. Chen, LL Jiang, P. Li, H. Chen, Un marco de información basado en tensores para predecir el mercado de valores, *ACM Transactions on Information Systems* 34 (2) (2016) 1–30.
- [27] PC Tetlock, Dando contenido al sentimiento de los inversores: el papel de los medios de comunicación en el mercado de valores, *The Journal of Finance* 62 (3) (2007) 1139–1168.
- [28] PC Tetlock, M. Saar-Tsechansky, S. Macskassy, Más que palabras: cuantificar el lenguaje para medir los fundamentos de las empresas, *The Journal of Finance* 63 (3) (2008) 1437–1467.
- [29] L. Cohen, A. Frazzini, Vínculos económicos y rendimientos predecibles, *The Journal of Finance* 63 (4) (2008) 1977–2011.
- [30] U. Ali, D. Hirshleifer, Cobertura compartida de analistas: Unificación de los efectos de contagio del impulso, *Journal of Financial Economics* 136 (3) (2020) 649–675.
- [31] R. Cheng, Q. Li, Modelado del efecto de contagio del momento para la predicción de acciones a través de redes de atención gráfica impulsadas por atributos, en: *Actas de la Conferencia AAAI sobre Inteligencia Artificial (AAAI)*, Vol. 35, 2021, págs. 55-62.
- [32] WF Sharpe, Precios de los activos de capital: Una teoría del equilibrio del mercado en condiciones de riesgo, *The Journal of Finance* 19 (3) (1964) 425–442.
- [33] J. Lintner, Precios de los valores, riesgo y ganancias máximas de la diversificación, *The Revista de Finanzas* 20 (4) (1965) 587–615.
- [34] J. Mossin, Equilibrio en un mercado de activos de capital, *Econometrica: Journal of the Econometric Society* (1966) 768–783.
- [35] MM Carhart, Sobre la persistencia en el rendimiento de los fondos mutuos, *The Journal of Finanzas* 52 (1) (1997) 57–82.
- [36] JS Abarbanell, BJ Bushee, Retornos anormales a un análisis fundamental estrategia, *Accounting Review* (1998) 19–45.

- [37] JA Ou, SH Penman, Análisis de estados financieros y predicción de retornos de acciones, *Journal of accounting and economics* 11 (4) (1989) 295–329.
- [38] M. Baker, B. Bradley, J. Wurgler, Los puntos de referencia como límites al arbitraje: comprensión de la anomalía de baja volatilidad, *Financial Analysts Journal* 67 (1) (2011) 40–54.
- [39] PA Diamond, ¿Qué rendimientos del mercado de valores podemos esperar en el futuro?, *Social Security Bulletin* 63 (2000) 38–52.
- [40] F. Modigliani, RA Cohn, Inflación, valoración racional y mercado, *Fi-Revista de analistas financieros* 35 (2) (1979) 24–44.
- [41] P. Wongbangpo, SC Sharma, Interacciones dinámicas fundamentales macroeconómicas y del mercado de valores: países de la ASEAN-5, *Journal of asian Economics* 13 (1) (2002) 27–51.
- [42] M. Ibrahim, Variables macroeconómicas y precios de las acciones en Malasia: un análisis empírico, *Asian Economic Journal* 13 (2) (1999) 219–231.
- [43] CM Bilson, TJ Brailsford, VJ Hooper, Selección de variables macroeconómicas como factores explicativos de los retornos de los mercados bursátiles emergentes, *Pacific-Basin Finance Journal* 9 (4) (2001) 401–426.
- [44] EF Fama, Mercados de capital eficientes: una revisión de la teoría y el trabajo empírico, *Revista de Finanzas* 25 (2) (1970) 383–417.
- [45] H. Markowitz, La utilidad de la riqueza, *Journal of Political Economy* 60 (2) (1952) 151–158.
- [46] GA Akerlof, El mercado de los “limones”: incertidumbre de calidad y el mercado mecanismo, en: *Incertidumbre en economía*, Elsevier, 1978, págs. 235-251.
- [47] D. Leblang, W. Bernhard, La política de ataques especulativos en las democracias industriales, *Organización Internacional* 54 (2) (2000) 291–324.
- [48] JJ McConnell, W. Xu, Rendimientos de acciones a finales de mes, *Financial Analysts Journal* 64 (2) (2008) 49–64.
- [49] M. Baker, J. Wurgler, El sentimiento de los inversores y la sección transversal de los rendimientos de las acciones, *The Journal of Finance* 61 (4) (2006) 1645–1680.

- [50] D. Hirshleifer, SS Lim, SH Teoh, Llevados a la distracción: Eventos extraños y reacción insuficiente a las noticias de ganancias, *The Journal of Finance* 64 (5) (2009) 2289–2325.
- [51] Q. Li, Y. Chen, J. Wang, Y. Chen, H. Chen, Medios web y mercados de valores: una encuesta y direcciones futuras desde una perspectiva de big data, *IEEE Transactions on Knowledge and Data Engineering* 30 (2) (2017) 381–399.
- [52] Q. Li, T. Wang, P. Li, L. Liu, Q. Gong, Y. Chen, El efecto de las noticias y el estado de ánimo del público en los movimientos bursátiles, *Information Science* 278 (2014) 826–840.
- [53] Q. Li, et al., Comercio cuantitativo basado en información web pública y con conocimiento de medios, *Decision Support Systems* 61 (2014) 93–105.
- [54] SR Das, MY Chen, Yahoo! para Amazon: Extracción de sentimientos de conversaciones informales en la web, *Management Science* 53 (9) (2007) 1375–1388.
- [55] W. Zhang, S. Skiena, Estrategias comerciales para explotar el sentimiento de los blogs y las noticias, en: *Actas de la conferencia internacional AAAI sobre la web y los medios sociales (ICWSM)*, vol. 4, 2010, págs. 375-378.
- [56] TJ Moskowitz, M. Grinblatt, ¿Las industrias explican el impulso?, *The Journal of Finance* 54 (4) (1999) 1249–1290.
- [57] Y.-L. Hsu, Y.-C. Tsai, C.-T. Li, Fingat: Redes de atención de gráficos financieros para recomendar las k mejores acciones rentables, *IEEE Transactions on Knowledge and Data Engineering* 35 (1) (2023) 469–481. doi:10.1109/TKDE.2021.3079496.
- [58] CA Parsons, R. Sabbatucci, S. Titman, Efectos de adelanto-retraso geográficos, *Revista de Estudios Financieros* 33 (10) (2020) 4721–4770.
- [59] L. Cohen, D. Lou, Empresas complicadas, *Journal of Financial Economics* 104 (2) (2012) 383–400.
- [60] R. Xing, Q. Li, J. Zhao, X. Xu, Red corporativa basada en medios y sus efectos en el mercado de valores, *Emerging Markets Finance and Trade* 57 (15) (2021) 4211–4236.
- [61] W. Li, R. Bao, K. Harimoto, D. Chen, J. Xu, Q. Su, Modelado de la relación bursátil con una red gráfica para la predicción del movimiento bursátil durante la noche, en: *Actas de la Vigésima Novena Conferencia Conjunta Internacional sobre Inteligencia Artificial*, 2020, págs. 4541–4547.

- [62] X. Li, J. Wang, J. Tan, S. Ji, H. Jia, Un método de pronóstico de acciones basado en redes neuronales gráficas que utiliza la fusión de datos heterogéneos de múltiples fuentes, *Multimedia Tools and Applications* 81 (30) (2022) 43753–43775.
- [63] KT Chi, J. Liu, FC Lau, Una perspectiva de red del mercado de valores, *Revista de Finanzas Empíricas* 17 (4) (2010) 659–667.
- [64] RW Banz, La relación entre el rendimiento y el valor de mercado de las acciones comunes, *Journal of Financial Economics* 9 (1) (1981) 3–18.
- [65] NB Gultekin, Rendimientos del mercado de valores e inflación: evidencia de otros países, *The Journal of Finance* 38 (1) (1983) 49–65.
- [66] K. Chourmouziadis, PD Chatzoglou, Un sistema difuso inteligente de negociación de acciones a corto plazo para ayudar a los inversores en la gestión de carteras, *Expert Systems with Applications* 43 (2016) 298–311.
- [67] N. Jegadeesh, S. Titman, Retornos a la compra de ganadores y venta de perdedores: Implicancias para la eficiencia del mercado de valores, *The Journal of Finance* 48 (1) (1993) 65–91.
- [68] A. Mittal, A. Goel, Predicción de acciones utilizando el análisis del sentimiento de Twitter, *Universidad de Stanford, CS229* 15 (2012) 2352.
- [69] DM Nelson, AC Pereira, RA De Oliveira, Predicción del movimiento de precios del mercado de valores con redes neuronales lstm, en: *Conferencia conjunta internacional sobre redes neuronales (IJCNN) de 2017, IEEE, 2017, pp. 1419-1426.*
- [70] N. Oliveira, P. Cortez, N. Areal, El impacto de los datos de microblogging para la predicción del mercado de valores: uso de Twitter para predecir retornos, volatilidad, volumen de operaciones e índices de sentimiento de encuestas, *Expert Systems with Applications* 73 (2017) 125–144.
- [71] R. Akita, A. Yoshihara, T. Matsubara, K. Uehara, Aprendizaje profundo para predicción de acciones usando información numérica y textual, en: *Computer and Information Science (ICIS), 2016 IEEE/ACIS 15th International Conference on, IEEE, 2016, págs. 1–6.*
- [72] Y. Huang, K. Huang, Y. Wang, H. Zhang, J. Guan, S. Zhou, Explotación de los estados de ánimo de Twitter para impulsar la predicción de tendencias financieras basadas en modelos de redes profundas, en: *Conferencia internacional sobre computación inteligente, Springer, 2016, págs. 449-460.*

- [73] Y. Peng, H. Jiang, Aprovechar las noticias financieras para predecir los movimientos de los precios de las acciones utilizando incrustaciones de palabras y redes neuronales profundas, preimpresión de arXiv arXiv:1506.07220 (2015).
- [74] HD Huynh, LM Dang, D. Duong, Un nuevo modelo para la predicción de movimientos de precios de acciones utilizando redes neuronales profundas, en: Actas del 8º Simposio Internacional sobre Tecnologías de la Información y la Comunicación, 2017, págs. 57-62.
- [75] G. Kumar, UP Singh, S. Jain, Sistema inteligente evolutivo híbrido y modelo econométrico de series de tiempo híbrido para la previsión de precios de acciones, International Journal of Intelligent Systems 36 (9) (2021) 4902–4935.
- [76] N.-F. Chen, R. Roll, SA Ross, Fuerzas económicas y el mercado de valores, The Journal of Business (1986) 383–403.
- [77] J. Conrad, G. Kaul, Reversión a la media en los rendimientos esperados en el horizonte corto, The Review of Financial Studies 2 (2) (1989) 225–240.
- [78] Y. Han, G. Zhou, Y. Zhu, Cómo controlar las caídas del impulso: un simple stop-loss estrategia, disponible en SSRN 2407199 (2016).
- [79] JH Van Binsbergen, RS Koijen, Regresiones predictivas: un enfoque de valor presente, The Journal of Finance 65 (4) (2010) 1439–1471.
- [80] RF Engle, Heterocedasticidad condicional autorregresiva con estimaciones de la varianza de la inflación del Reino Unido, Econométrica: Revista de la Sociedad Econométrica (1982) 987–1007.
- [81] PR Hansen, A. Lunde, Una comparación de pronósticos de modelos de volatilidad: ¿hay algo mejor que un garch (1, 1)?, Journal of Applied Econometrics 20 (7) (2005) 873–889.
- [82] RF Bruner, W. Li, M. Kritzman, S. Myrgren, S. Page, Integración del mercado en mercados desarrollados y emergentes: evidencia del CAPM, Emerging Markets Review 9 (2) (2008) 89–103.
- [83] RC Merton, Un modelo de fijación de precios de activos de capital intertemporal, Econométrica: Revista de la Sociedad Econométrica (1973) 867–887.
- [84] DT Breeden, Un modelo de fijación de precios de activos intertemporales con consumo estocástico y oportunidades de inversión, Journal of Financial Economics 7 (3) (1979) 265–296.

- [85] R. Jagannathan, Z. Wang, El CAPM condicional y la sección transversal de los rendimientos esperados, *The Journal of Finance* 51 (1) (1996) 3–53.
- [86] J. Estrada, Riesgo sistemático en mercados emergentes: el d-capm, *Emerging Markets Review* 3 (4) (2002) 365–379.
- [87] M. Lettau, S. Ludvigson, Resucitando el (c) capm: una prueba transversal cuando las primas de riesgo varían en el tiempo, *Journal of political economy* 109 (6) (2001) 1238–1287.
- [88] E. Nichol, M. Dowling, Rentabilidad y factores de inversión para los modelos de fijación de precios de activos del Reino Unido, *Economics Letters* 125 (3) (2014) 364–366.
- [89] RF Stambaugh, Y. Yuan, Factores de valoración errónea, *La revisión de estudios financieros* 30 (4) (2017) 1270–1315.
- [90] K. Hou, C. Xue, L. Zhang, Digerir anomalías: un enfoque de inversión, *The Review of Financial Studies* 28 (3) (2015) 650–705.
- [91] F. Barillas, J. Shanken, Comparación de modelos de fijación de precios de activos, *The Journal of Finance* 73 (2) (2018) 715–754.
- [92] M. Marcellino, JH Stock, MW Watson, Una comparación de métodos de predicción de series temporales macroeconómicas directos e iterados de múltiples pasos, *Journal of econometrics* 135 (1-2) (2006) 499–526.
- [93] A. Raudys, Z. Pabar̃skait̃e, Optimización de la suavidad y precisión del promedio móvil para datos de precios de acciones, *Desarrollo tecnológico y económico de la economía* 24 (3) (2018) 984–1003.
- [94] C.-C. Chen, W.-J. Tsay, Un enfoque de cambio de régimen de Markov para la cobertura de índices bursátiles, *Journal of Futures Markets* 31 (2) (2011) 165–191.
- [95] C. Li, T.-W. Chiang, Pronóstico arima neurodifuso complejo: un nuevo enfoque que utiliza conjuntos difusos complejos, *IEEE Transactions on Fuzzy Systems* 21 (3) (2012) 567–584.
- [96] JN Bodurtha Jr, NC Mark, Prueba del CAPM con riesgos y retornos variables en el tiempo, *The Journal of Finance* 46 (4) (1991) 1485–1505.
- [97] T. Bollerslev, Heterocedasticidad condicional autorregresiva generalizada, *Jour-Revista de Econometría* 31 (3) (1986) 307–327.

- [98] KR French, GW Schwert, RF Stambaugh, Rendimientos esperados de las acciones y volatilidad, *Journal of Financial Economics* 19 (1) (1987) 3–29.
- [99] ML Mitchell, JH Mulherin, El impacto de la información pública en el mercado de valores mercado, *The Journal of Finance* 49 (3) (1994) 923–950.
- [100] WS Chan, Reacción del precio de las acciones a las noticias y a la ausencia de noticias: deriva y reversión después de los titulares, *Journal of Financial Economics* 70 (2) (2003) 223–260.
- [101] EF Fama, KR French, La sección transversal de los rendimientos esperados de las acciones, *Revista de Finanzas* 47 (2) (1992) 427–465.
- [102] EF Fama, JD MacBeth, Riesgo, rendimiento y equilibrio: pruebas empíricas, *Revista de Economía Política* 81 (3) (1973) 607–636.
- [103] EF Fama, El comportamiento de los precios de las acciones, *The Journal of Business* 38 (1) (1965) 34–105.
- [104] JB De Long, A. Shleifer, LH Summers, RJ Waldmann, Riesgo de los operadores de ruido en los mercados financieros, *Journal of Political Economy* 98 (4) (1990) 703–738.
- [105] R. Levine, S. Zervos, Mercados de valores, bancos y crecimiento económico, *The American Economic Review* (1998) 537–558.
- [106] EF Fama, L. Fisher, MC Jensen, R. Roll, El ajuste de los precios de las acciones a la nueva información, *International economic review* 10 (1) (1969) 1–21.
- [107] K. Daniel, D. Hirshleifer, A. Subrahmanyam, Psicología del inversor y reacciones exageradas y insuficientes del mercado de valores, *The Journal of Finance* 53 (6) (1998) 1839–1885.
- [108] EF Fama, KR French, Factores de tamaño y relación precio-valor contable en ganancias y retornos, *The Journal of Finance* 50 (1) (1995) 131–155.
- [109] EF Fama, KR French, Condiciones comerciales y rendimientos esperados de acciones y bonos, *Journal of Financial Economics* 25 (1) (1989) 23–49.
- [110] M. Baker, J. Wurgler, Sentimiento de los inversores en el mercado de valores, *Journal of Economic Perspectives* 21 (2) (2007) 129–152.
- [111] I. Welch, A. Goyal, Una mirada integral al desempeño empírico de la predicción de primas de acciones, *The Review of Financial Studies* 21 (4) (2008) 1455–1508.

- [112] EF Fama, KR French, El modelo de fijación de precios de activos de capital: teoría y evidencia, *Journal of Economic Perspectives* 18 (3) (2004) 25–46.
- [113] JY Campbell, RJ Shiller, Precios de las acciones, ganancias y dividendos esperados, *The Journal of Finance* 43 (3) (1988) 661–676.
- [114] D. Hirshleifer, Psicología del inversor y fijación de precios de activos, *The Journal of Finance* 56 (4) (2001) 1533–1597.
- [115] EF Fama, Caminatas aleatorias en los precios del mercado de valores, *Financial Analysts Journal* 51 (1) (1995) 75–80.
- [116] Z. Da, J. Engelberg, P. Gao, En busca de atención, *The Journal of Finance* 66 (5) (2011) 1461–1499.
- [117] JY Campbell, Retornos de acciones y estructura temporal, *Journal of Financial Economics* 18 (2) (1987) 373–399.
- [118] W. Antweiler, MZ Frank, ¿Es todo lo que dicen sólo ruido? El contenido informativo de los foros de bolsa de Internet, *The Journal of Finance* 59 (3) (2004) 1259–1294.
- [119] JY Campbell, SB Thompson, Predicción de rendimientos excesivos de acciones fuera de la muestra: ¿puede algo superar el promedio histórico?, *The Review of Financial Studies* 21 (4) (2008) 1509–1531.
- [120] M. Lettau, S. Ludvigson, Consumo, riqueza agregada y rendimientos bursátiles esperados, *The Journal of Finance* 56 (3) (2001) 815–849.
- [121] DB Keim, RF Stambaugh, Predicción de rendimientos en los mercados de acciones y bonos, *Journal of Financial Economics* 17 (2) (1986) 357–390.
- [122] PK Illieditsch, JV Ganguli, S. Condie, Inercia de la información, *The Journal of Finance* 76 (1) (2021) 443–479.
- [123] M. Anton, C. Polk, Acciones conectadas, *The Journal of Finance* 69 (3) (2014) 1099–1127.
- [124] G. Cespa, X. Vives, El concurso de belleza y el trading de corto plazo, *The Journal of Finance* 70 (5) (2015) 2099–2154.
- [125] PL Cheng, MK Deets, Los rendimientos de la cartera y la teoría del paseo aleatorio, *Revista de Finanzas* 26 (1) (1971) 11–30.

- [126] EF Fama, Mercados de capital eficientes: una revisión de la teoría y el trabajo empírico, *The Journal of Finance* 25 (2) (1970) 383–417.
- [127] B.-S. Lee, Relaciones causales entre los retornos de acciones, las tasas de interés, la actividad real y la inflación, *The Journal of Finance* 47 (4) (1992) 1591–1603.
- [128] JL Davis, EF Fama, KR French, Características, covarianzas y rendimientos promedio: 1929 a 1997, *The Journal of Finance* 55 (1) (2000) 389–406.
- [129] Z. Bodie, Las acciones comunes como cobertura contra la inflación, *The Journal of Finance* 31 (2) (1976) 459–470.
- [130] EF Fama, Componentes del rendimiento de la inversión, *The Journal of Finance* 27 (3) (1972) 551–567.
- [131] O. Lamont, Ganancias y rendimientos esperados, *The Journal of Finance* 53 (5) (1998) 1563–1587.
- [132] W. Breen, LR Glosten, R. Jagannathan, Importancia económica de las variaciones predecibles en los retornos de los índices bursátiles, *The Journal of Finance* 44 (5) (1989) 1177– 1189.
- [133] CR Nelson, Inflación y tasas de rendimiento de las acciones comunes, *The Journal of Finance* 31 (2) (1976) 471–483.
- [134] L. Fang, J. Peress, Cobertura mediática y la sección transversal de los retornos de las acciones, *The Revista de Finanzas* 64 (5) (2009) 2023–2052.
- [135] DH Solomon, Publicidad selectiva y precios de las acciones, *The Journal of Finance* 67 (2) (2012) 599–638.
- [136] AA Robichek, MC Bogue, Una nota sobre el comportamiento de las relaciones precio/ganancias esperadas a lo largo del tiempo, *The Journal of Finance* 26 (3) (1971) 731– 735.
- [137] D. García, Sentimiento durante las recesiones, *The Journal of Finance* 68 (3) (2013) 1267–1300.
- [138] J. Peress, Los medios de comunicación y la difusión de información en los mercados financieros: evidencia de las huelgas de periódicos, *The Journal of Finance* 69 (5) (2014) 2007– 2043.

- [139] EF Fama, KR French, El costo corporativo del capital y el retorno de la inversión corporativa, *The Journal of Finance* 54 (6) (1999) 1939–1967.
- [140] A. Ben-Rephael, BI Carlin, Z. Da, RD Israelsen, Consumo de información y fijación de precios de activos, *The Journal of Finance* 76 (1) (2021) 357–394.
- [141] R. Geske, R. Roll, El vínculo fiscal y monetario entre los rendimientos de las acciones y inflación, *The Journal of Finance* 38 (1) (1983) 1–33.
- [142] KR Ahern, J. Harford, La importancia de los vínculos industriales en las olas de fusiones, *The Journal of Finance* 69 (2) (2014) 527–576.
- [143] CC Holt, La influencia de la duración del crecimiento en los precios de las acciones, *The Journal of Finance* 17 (3) (1962) 465–475.
- [144] EF Fama, KR French, La prima de valor y el CAPM, *The Journal of Finance* 61 (5) (2006) 2163–2185.
- [145] JF Jaffe, G. Mandelker, El “efecto Fisher” para activos riesgosos: una investigación empírica, *The Journal of Finance* 31 (2) (1976) 447–458.
- [146] D. Pettenuzzo, R. Sabbatucci, A. Timmermann, Noticias de flujo de caja y dinámica del precio de las acciones, *The Journal of Finance* 75 (4) (2020) 2221–2270.
- [147] M. Ungeheuer, M. Weber, La percepción de la dependencia, las decisiones de inversión y los precios de las acciones, *The Journal of Finance* 76 (2) (2021) 797–844.
- [148] LA Lochstoer, PC Tetlock, ¿Qué impulsa los retornos anómalos?, *The Journal of Finance* 75 (3) (2020) 1417–1455.
- [149] R. Gürkaynak, HG Karasoy-Can, SS Lee, Evaluación del mercado de valores de la transmisión de la política monetaria: el efecto del flujo de caja, *The Journal of Finance* 77 (4) (2022) 2375–2421.
- [150] X. Chen, L. An, Z. Wang, J. Yu, Desbordamiento de la atención en la fijación de precios de los activos, *Revista de Finanzas* 78 (6) (2023) 3515–3559.
- [151] GR Duffee, Noticias macroeconómicas en precios de activos y realidad, *The Journal of Finance* 78 (3) (2023) 1499–1543.
- [152] J. Pontiff, LD Schall, Ratios valor contable-valor de mercado como predictores de la rentabilidad del mercado, *Journal of Financial Economics* 49 (2) (1998) 141–160.

- [153] SP Kothari, J. Shanken, Relación precio-valor contable, rendimiento de dividendos y rendimientos esperados del mercado: un análisis de series temporales, *Journal of Financial Economics* 44 (2) (1997) 169–203.
- [154] T. Gilbert, Agregación de información en torno a anuncios macroeconómicos: las revisiones importan, *Journal of Financial Economics* 101 (1) (2011) 114–131.
- [155] RF Stambaugh, Regresiones predictivas, *Journal of Financial Economics* 54 (3) (1999) 375–421.
- [156] EF Fama, KR French, Rentabilidad, inversión y rendimientos promedio, *Jour-Revista de Economía Financiera* 82 (3) (2006) 491–518.
- [157] G. Kaul, Retornos de acciones e inflación: El papel del sector monetario, *Journal of Financial Economics* 18 (2) (1987) 253–276.
- [158] GR Duffee, Rendimientos de acciones y volatilidad: un análisis a nivel de empresa, *Journal of Economía financiera* 37 (3) (1995) 399–420.
- [159] N. Barberis, A. Shleifer, Estilo de inversión, *Journal of Financial Economics* 68 (2) (2003) 161–199.
- [160] EF Fama, KR French, Desacuerdo, gustos y precios de los activos, *Journal of Economía financiera* 83 (3) (2007) 667–689.
- [161] I. Chaieb, H. Langlois, O. Scaillet, Factores y primas de riesgo en los retornos de acciones internacionales individuales, *Journal of Financial Economics* 141 (2) (2021) 669–692.
- [162] Y. Xu, Y. Xuan, G. Zheng, Búsqueda en Internet y riesgo de caída del precio de las acciones: evidencia de un experimento cuasi natural, *Journal of Financial Economics* 141 (1) (2021) 255–275.
- [163] F. Jiang, J. Lee, X. Martin, G. Zhou, Sentimiento de los gerentes y retornos de las acciones, *Journal of Financial Economics* 132 (1) (2019) 126–149.
- [164] Y. Chen, GW Eaton, BS Paye, ¿Micro(estructura) antes que macro? El poder predictivo de la iliquidez agregada para los retornos de acciones y la actividad económica, *Journal of Financial Economics* 130 (1) (2018) 48–73.
- [165] D. Hirshleifer, D. Jiang, YM DiGiovanni, Beta del estado de ánimo y estacionalidades en los retornos de las acciones, *Journal of Financial Economics* 137 (1) (2020) 272–295.

- [166] M. Cosemans, R. Frehen, Teoría de la saliencia y precios de las acciones: evidencia empírica, *Journal of Financial Economics* 140 (2) (2021) 460–483.
- [167] M. Boons, F. Duarte, F. De Roon, M. Szymanowska, Riesgo de inflación variable en el tiempo y rentabilidad de las acciones, *Journal of Financial Economics* 136 (2) (2020) 444–470.
- [168] A. Edmans, A. Fernandez-Perez, A. Garel, I. Indriawan, Sentimiento musical y retornos bursátiles en todo el mundo, *Journal of Financial Economics* 145 (2) (2022) 234–254.
- [169] N. Cakici, A. Zaremba, Teoría de la saliencia y la sección transversal de los retornos de acciones: evidencia internacional y adicional, *Journal of Financial Economics* 146 (2) (2022) 689–725.
- [170] Z. Chen, Z. Da, D. Huang, L. Wang, Índice de aprobación económica presidencial y la sección transversal de los retornos de las acciones, *Journal of Financial Economics* 147 (1) (2023) 106–131.
- [171] EF Fama, KR French, Diseccionando anomalías con un modelo de cinco factores, *The Review of Financial Studies* 29 (1) (2016) 69–103.
- [172] RJ Hodrick, Rendimientos de dividendos y retornos esperados de acciones: procedimientos alternativos para inferencia y medición, *The Review of Financial Studies* 5 (3) (1992) 357–386.
- [173] A. Ang, G. Bekaert, Previsibilidad del rendimiento de las acciones: ¿existe?, *The Review of Estudios financieros* 20 (3) (2007) 651–707.
- [174] PC Tetlock, ¿Resuelven las noticias financieras públicas la información asimétrica? *Revista de Estudios Financieros* 23 (9) (2010) 3520–3557.
- [175] JM Griffin, NH Hirschey, PJ Kelly, ¿Qué importancia tienen los medios financieros en los mercados globales?, *The Review of Financial Studies* 24 (12) (2011) 3941–3992.
- [176] C. Dougal, J. Engelberg, D. Garcia, CA Parsons, Periodistas y el mercado de valores, *The Review of Financial Studies* 25 (3) (2012) 639–679.
- [177] KR Ahern, D. Sosyura, Se rumorea: sensacionalismo en los medios financieros, *The Review of Financial Studies* 28 (7) (2015) 2050–2093.
- [178] H. Chen, P. De, Y. Hu, B.-H. Hwang, Sabiduría de las multitudes: El valor de las opiniones sobre acciones transmitidas a través de las redes sociales, *The Review of Financial Studies* 27 (5) (2014) 1367–1403.

- [179] T. Hendershott, AJ Menkveld, R. Praz, MS Seasholes, Dinámica de precios de activos con atención limitada, disponible en SSRN 1651098 (2020).
- [180] A. Agrawal, I. Hacamo, Z. Hu, Dispersión de información entre empleados y rentabilidad de las acciones, *The Review of Financial Studies* 34 (10) (2021) 4785–4831.
- [181] M. Brunnermeier, E. Farhi, RS Kojien, A. Krishnamurthy, SC Ludvigson, H. Lustig, S. Nagel, M. Piazzesi, Perspectivas sobre el futuro de la fijación de precios de los activos, *The Review of Financial Studies* 34 (4) (2021) 2126–2160.
- [182] SM Hartzmark, DH Solomon, Reconsiderando los retornos, *The Review of Financial Studies* 35 (1) (2022) 343–393.
- [183] J. Green, JR Hand, XF Zhang, Las características que proporcionan información independiente sobre los retornos promedio mensuales de las acciones estadounidenses, *The Review of Financial Studies* 30 (12) (2017) 4389–4436.
- [184] D. Dicks, P. Fulghieri, Incertidumbre, sentimiento de los inversores e innovación, *The Review of Financial Studies* 34 (3) (2021) 1236–1279.
- [185] M. Lettau, M. Pelger, Factores que se ajustan a las series temporales y a la sección transversal de los rendimientos de las acciones, *The Review of Financial Studies* 33 (5) (2020) 2274–2325.
- [186] Y. Amihud, J. Noh, Ilíquidez y rentabilidad de las acciones ii: Efectos transversales y de series de tiempo, *The Review of Financial Studies* 34 (4) (2021) 2101–2123.
- [187] J. Brogaard, TH Nguyen, TJ Putnins, E. Wu, ¿Qué mueve los precios de las acciones? Los roles de las noticias, el ruido y la información, *The Review of Financial Studies* 35 (9) (2022) 4341–4386.
- [188] L. Bybee, B. Kelly, Y. Su, Fijación narrativa de precios de activos: factores de riesgo sistemáticos interpretables a partir de textos de noticias, *The Review of Financial Studies* 36 (12) (2023) 4759–4787.
- [189] EJ Elton, MJ Gruber, Teoría moderna de cartera, 1950 hasta la fecha, *Journal of Banking & Finance* 21 (11-12) (1997) 1743–1759.
- [190] KP Evans, Saltos intradía y anuncios de noticias macroeconómicas de EE.UU., *Journal of Banking & Finance* 35 (10) (2011) 2511–2527.
- [191] G. Birz, JR Lott, El efecto de las noticias macroeconómicas en los retornos de las acciones: nueva evidencia de la cobertura periodística, *Journal of Banking & Finance* 35 (11) (2011) 2791–2800.

- [192] I. Medovikov, ¿Cuándo presta atención el mercado de valores a las noticias económicas? Nueva evidencia de cópulas y agencias de noticias, *Journal of Banking & Finance* 65 (2016), pp. 27-40.
- [193] JH Ben, X. Li, K. Duncan, J. Xu, Gasto en relaciones corporativas y riesgo de caída del precio de las acciones: evidencia de la campaña anticorrupción de China, *Journal of Banking & Finance* 113 (2020) 105758.
- [194] T. Renault, Sentimiento de los inversores online intradía y patrones de retorno en el mercado de valores estadounidense, *Journal of Banking & Finance* 84 (2017) 25–40.
- [195] S. Behrendt, A. Schmidt, El mito de Twitter revisitado: sentimiento intradía de los inversores, actividad en Twitter y volatilidad del retorno de las acciones a nivel individual, *Journal of Banking & Finance* 96 (2018) 355–367.
- [196] TK Chue, FA Gul, GM Mian, Sentimiento agregado de los inversores y sincronidad del rendimiento de las acciones, *Journal of Banking & Finance* 108 (2019) 105628.
- [197] F. Xie, HD Anderson, J. Chi, J. Liao, ¿La propiedad estatal residual aumenta la volatilidad del retorno de las acciones? Evidencia de la privatización secundaria de China, *Journal of Banking & Finance* 100 (2019) 234–251.
- [198] N. Cakici, A. Zaremba, Liquidez y la sección transversal de los rendimientos de las acciones internacionales, *Journal of Banking & Finance* 127 (2021) 106123.
- [199] H. Mohrschladt, El ordenamiento de los rendimientos históricos y la sección transversal de los rendimientos subsiguientes, *Journal of Banking & Finance* 125 (2021) 106064.
- [200] S. Foerster, J. Tsagarelis, G. Wang, ¿Son los flujos de efectivo mejores predictores del retorno de las acciones que las ganancias?, *Financial Analysts Journal* 73 (1) (2017) 73–99.
- [201] R. Gibson Brandon, P. Krueger, PS Schmidt, Desacuerdo en la calificación ESG y retorno de las acciones, *Financial Analysts Journal* 77 (4) (2021) 104–127.
- [202] EF Brigham, JL Pappas, Duración del crecimiento, cambios en las tasas de crecimiento y precios de las acciones corporativas, *Financial Analysts Journal* 22 (3) (1966) 157–162.
- [203] R. Tumarkin, RF Whitelaw, ¿Noticias o ruido? Publicaciones en Internet y precios de las acciones, *Financial Analysts Journal* 57 (3) (2001) 41–51.
- [204] EF Fama, KR French, La anatomía de los retornos de las acciones de valor y crecimiento, *Financial Analysts Journal* 63 (6) (2007) 44–54.

- [205] H. Aman, Un análisis del impacto de la cobertura mediática en las caídas y subidas de los precios de las acciones: evidencia de Japón, *Pacific-Basin Finance Journal* 24 (2013) 22–38.
- [206] PK Narayan, D. Bannigidadmath, ¿Las noticias financieras predicen el rendimiento de las acciones? Nueva evidencia de acciones islámicas y no islámicas, *Pacific-Basin Finance Journal* (2015).
- [207] J. Jang, Anomalías en el rendimiento de las acciones e inversores individuales en el mercado de valores de Corea, *Pacific-Basin Finance Journal* 46 (2017) 141–157.
- [208] Z. Dai, H. Zhu, Predicibilidad del retorno de las acciones desde una perspectiva de modelo mixto, *Pacific-Basin Finance Journal* 60 (2020) 101267.
- [209] S. Wang, L. Yu, Q. Zhao, ¿Explican los modelos factoriales el rendimiento de las acciones cuando los precios se comportan de forma explosiva? Evidencia de China, *Pacific-Basin Finance Journal* 67 (2021) 101535.
- [210] T. Dimpfl, S. Jank, ¿Pueden las consultas de búsqueda en Internet ayudar a predecir la volatilidad del mercado de valores?, *European financial management* 22 (2) (2016) 171–192.
- [211] A. Carretta, V. Farina, D. Martelli, F. Fiordelisi, P. Schwizer, El impacto de las noticias de prensa sobre gobierno corporativo en los retornos del mercado de valores, *European Financial Management* 17 (1) (2011) 100–119.
- [212] TO Sprenger, A. Tumasjan, PG Sandner, IM Welp, Tweets and trades: The information content of stock microblogs, *European Financial Management* 20 (5) (2014) 926–957.
- [213] Q. Lin, Impulso idiosincrásico y la sección transversal de los retornos de las acciones: más evidencia, *European Financial Management* 26 (3) (2020) 579–627.
- [214] B. Cornell, Preferencias ESG, riesgo y rentabilidad, *European Financial Management* 27 (1) (2021) 12–19.
- [215] EF Fama, Dos pilares de la fijación de precios de activos, *The American Economic Review* 104 (6) (2014) 1467–85.
- [216] EF Fama, Los efectos de las decisiones de inversión y financiación de una empresa sobre el bienestar de sus tenedores de valores, *The American Economic Review* 68 (3) (1978) 272–284.

- [217] EF Fama, Las relaciones empíricas entre los dividendos y las decisiones de inversión de las empresas, *The American Economic Review* 64 (3) (1974) 304–318.
- [218] HS Moat, C. Curme, A. Avakian, DY Kenett, HE Stanley, T. Preis, Cuantificación de los patrones de uso de Wikipedia antes de los movimientos del mercado de valores, *Informes científicos* 3 (1) (2013) 1801.
- [219] I. Zheludev, R. Smith, T. Aste, ¿Cuándo pueden las redes sociales liderar los mercados financieros?, *Informes científicos* 4 (2014) 1–12.
- [220] M. Alanyali, HS Moat, T. Preis, Cuantificación de la relación entre las finanzas Noticias sociales y mercado de valores, *Informes científicos* 3 (1) (2013) 1–6.
- [221] T. Preis, HS Moat, HE Stanley, Cuantificación del comportamiento comercial en los mercados financieros utilizando tendencias de Google, *Informes científicos* 3 (1) (2013) 1–6.
- [222] SY Yang, SYK Mo, A. Liu, Sentimiento de la comunidad financiera de Twitter y su relación predictiva con el movimiento del mercado de valores, *Quantitative Finance* 15 (10) (2015) 1637–1656.
- [223] F. Lillo, S. Miccichè, M. Tumminello, J. Piilo, RN Mantegna, Cómo las noticias afectan el comportamiento comercial de diferentes categorías de inversores en un mercado financiero, *Quantitative Finance* 15 (2) (2015) 213–229.
- [224] R. Luss, A. d'Aspremont, Predicción de retornos anormales a partir de noticias usando clasificación de texto, *Quantitative Finance* 15 (6) (2015) 999–1012.
- [225] S. Isaenko, Capital de lento movimiento y rentabilidad de las acciones, *Quantitative Finance* 20 (6) (2020) 969–984.
- [226] EF Fama, KR French, Pronóstico de rentabilidad y ganancias, *The Journal de Negocios* 73 (2) (2000) 161–175.
- [227] EF Fama, MR Gibbons, Inflación, rendimientos reales e inversión de capital, *Journal of Monetary Economics* 9 (3) (1982) 297–323.
- [228] EF Fama, Análisis de cartera en un mercado paretiano estable, *Management Science* 11 (3) (1965) 404–419.
- [229] S. Gu, B. Kelly, D. Xiu, Modelos de fijación de precios de activos con autocodificador, *Journal of Econometrics* 222 (1) (2021) 429–450.

- [230] C. Pflueger, E. Siriwardane, A. Sunderam, Percepciones de riesgo del mercado financiero y la macroeconomía, *The Quarterly Journal of Economics* 135 (3) (2020) 1443–1491.
- [231] K. Adam, D. Matveev, S. Nagel, ¿Reflejan las expectativas de las encuestas sobre el rendimiento de las acciones ajustes de riesgo?, *Journal of Monetary Economics* 117 (2021) 723–740.
- [232] J. Jiang, B. Kelly, D. Xiu, (re-)imag (in) ing tendencias de precios, *The Journal of Finance* 78 (6) (2023) 3193–3249.
- [233] DM Cutler, JM Poterba, LH Summers, ¿Qué mueve los precios de las acciones? (1988).
- [234] CM Lee, K. Li, ¿Por qué los emisores de acciones previstos obtienen rendimientos bajos?, *The Review of Asset Pricing Studies* 13 (1) (2023) 181–221.
- [235] JH Choi, A. Kalay, G. Sadka, Noticias de ganancias, ganancias esperadas y retornos agregados de acciones, *Journal of Financial Markets* 29 (2016) 110–143.
- [236] SP Kothari, X. Li, JE Short, El efecto de las revelaciones de la gerencia, los analistas y la prensa comercial sobre el costo del capital, la volatilidad del retorno y los pronósticos de los analistas: un estudio que utiliza análisis de contenido, *The Accounting Review* 84 (5) (2009) 1639–1670.
- [237] M. Hadzic, D. Weinbaum, N. Yehuda, Contenido de noticias, reacción errónea de los inversores y previsibilidad del retorno de las acciones, *Reacción errónea de los inversores y previsibilidad del retorno de las acciones* (septiembre de 2015) (2015).
- [238] J. Li, H. Wang, J. Yu, Crecimiento esperado de la inversión agregada y retornos del mercado de valores, *Journal of Monetary Economics* 117 (2021) 618–638.
- [239] HK Sul, AR Dennis, L. Yuan, Trading en Twitter: uso del sentimiento de las redes sociales para predecir el retorno de las acciones, *Decision Sciences* 48 (3) (2017) 454–488.
- [240] PD Azar, AW Lo, La sabiduría de las multitudes de Twitter: predecir las reacciones del mercado de valores a las reuniones del FOMC a través de los feeds de Twitter, *The Journal of Portfolio Management* 42 (5) (2016) 123–134.
- [241] DM Cutler, JM Poterba, LH Summers, ¿Qué mueve los precios de las acciones?, *The Journal of Portfolio Management* 15 (1989) 4–2.
- [242] X. Zhang, H. Fuehres, PA Gloor, Predicción de indicadores del mercado de valores a través de Twitter “espero que no sea tan malo como temo”, *Procedia-Social and Behavioral Sciences* 26 (2011) 55–62.

- [243] P. Zarowin, Tamaño, estacionalidad y reacción exagerada del mercado de valores, *Journal of Financial and Quantitative Analysis* (1990) 113–125.
- [244] GW Brown, MT Cliff, El sentimiento de los inversores y el mercado de valores a corto plazo, *Journal of Empirical Finance* 11 (1) (2004) 1–27.
- [245] M. Cremers, A. Fodor, D. Weinbaum, ¿Dónde negocian primero los traders informados?, *Actividad de negociación de opciones, comunicados de prensa y previsibilidad del retorno de las acciones* (2015).
- [246] MF Osborne, Movimiento browniano en el mercado de valores, *Operations Research* 7 (2) (1959) 145–173.
- [247] MF Osborne, Estructura periódica en el movimiento browniano de los precios de las acciones, *Investigación de Operaciones* 10 (3) (1962) 345–379.
- [248] A. Dutta, G. Bandopadhyay, S. Sengupta, Predicción del rendimiento de las acciones en el mercado de valores indio utilizando regresión logística, *International Journal of Business and Information* 7 (1) (2012) 105.
- [249] L. Khaidem, S. Saha, SR Dey, Predicción de la dirección de los precios del mercado de valores utilizando un bosque aleatorio, preimpresión de arXiv arXiv:1605.00003 (2016).
- [250] AK Nassirtoussi, S. Aghabozorgi, TY Wah, DCL Ngo, Minería de texto de titulares de noticias para la predicción del mercado FOREX: Un algoritmo de reducción de dimensión de múltiples capas con semántica y sentimiento, *Expert Systems with Applications* 42 (1) (2015) 306–324.
- [251] Y. Guo, S. Han, C. Shen, Y. Li, X. Yin, Y. Bai, Un svr adaptativo para pronóstico de precios de acciones de alta frecuencia, *IEEE Access* 6 (2018) 11397–11404.
- [252] Z. Guoying, C. Ping, Pronóstico de retornos anuales de acciones basado en el algoritmo de integración adaboost, en: *Conferencia internacional IEEE 2017 sobre Smart Cloud*, IEEE, 2017, págs. 263-267.
- [253] S. Dey, Y. Kumar, S. Saha, S. Basak, Pronóstico para clasificación: predicción de la dirección del precio del mercado de valores utilizando el aumento de gradiente extremo, *PESIT South Campus* (2016) 1–10.
- [254] L. Borrajo, R. Romero, EL Iglesias, CR Marey, Mejora de la clasificación de textos científicos desequilibrados utilizando estrategias de muestreo y diccionarios, *Journal of integrative bioinformatics* 8 (3) (2011) 90–104.

- [255] T. Vo-Van, H. Che-Ngoc, N. Le-Dai, T. Nguyen-Trang, Una nueva estrategia para la inversión en acciones a corto plazo utilizando el enfoque bayesiano, *Computational Economics* (2021) 1–25.
- [256] A. Phongmekin, P. Jarumaneeroj, Modelos de clasificación para la predicción del rendimiento de las acciones: un estudio de caso del sector financiero en la bolsa de valores de Tailandia, en: Conferencia internacional de 2018 sobre ingeniería, ciencias aplicadas y tecnología (ICEAST), IEEE, 2018, págs. 1–4.
- [257] S. Basak, S. Kar, S. Saha, L. Khaidem, SR Dey, Predicción de la dirección de los precios del mercado de valores utilizando clasificadores basados en árboles, *The North American Journal of Economics and Finance* 47 (2019) 552–567.
- [258] MR Toocheai, F. Moeini, Evaluación del desempeño de los clasificadores de conjunto en la predicción de retornos de acciones usando características efectivas, *Expert Systems with Applications* 213 (2023) 119186.
- [259] P.-F. Pai, C.-S. Lin, Un modelo híbrido de arima y máquinas de vectores de soporte en la previsión de precios de acciones, *Omega* 33 (6) (2005) 497–505.
- [260] Y. Kara, MA Boyacioglu, OK Baykan, Predicción de la dirección del movimiento del índice de precios de acciones utilizando redes neuronales artificiales y máquinas de vectores de soporte: La muestra de la Bolsa de Valores de Estambul, *Sistemas expertos con aplicaciones* 38 (5) (2011) 5311–5319.
- [261] E. Guresen, G. Kayakutlu, TU Daim, Uso de modelos de redes neuronales artificiales en la predicción del índice del mercado de valores, *Sistemas expertos con aplicaciones* 38 (8) (2011) 10389–10397.
- [262] K.-j. Kim, I. Han, Enfoque de algoritmos genéticos para la discretización de características en redes neuronales artificiales para la predicción del índice de precios de acciones, *Expert Systems with Applications* 19 (2) (2000) 125–132.
- [263] A.-S. Chen, MT Leung, H. Daouk, Aplicación de redes neuronales a un mercado financiero emergente: previsión y negociación del índice bursátil de Taiwán, *Computers & Operations Research* 30 (6) (2003) 901–923.
- [264] E. Hadavandi, H. Shavandi, A. Ghanbari, Integración de sistemas genéticos difusos y redes neuronales artificiales para la predicción de precios de acciones, *Knowledge-Based Systems* 23 (8) (2010) 800–808.

- [265] W. Shen, X. Guo, C. Wu, D. Wu, Pronóstico de índices bursátiles utilizando redes neuronales con funciones de base radial optimizadas por un algoritmo de enjambre de peces artificiales, *Knowledge-Based Systems* 24 (3) (2011) 378–385.
- [266] M. Hagenau, M. Liebmann, D. Neumann, Lectura automatizada de noticias: predicción del precio de las acciones basada en noticias financieras utilizando funciones de captura de contexto, *Decision Support Systems* 55 (3) (2013) 685–697.
- [267] RP Schumaker, Y. Zhang, C.-N. Huang, H. Chen, Evaluación del sentimiento en artículos de noticias financieras, *Decision Support Systems* 53 (3) (2012) 458–464.
- [268] Q. Cao, KB Leggio, MJ Schniederjans, Una comparación entre el modelo de Fama y French y las redes neuronales artificiales para predecir el mercado de valores chino, *Computers & Operations Research* 32 (10) (2005) 2499–2512.
- [269] S.-H. Hsu, JP-A. Hsieh, T.-C. Chih, K.-C. Hsu, Una arquitectura de dos etapas para la previsión de precios de acciones mediante la integración de mapas autoorganizados y regresión de vectores de soporte, *Expert Systems with Applications* 36 (4) (2009) 7947–7951.
- [270] P.-C. Chang, C.-H. Liu, J.-L. Lin, C.-Y. Fan, CS Ng, Una red neuronal con una ventana dinámica basada en casos para la predicción de operaciones bursátiles, *Expert Systems with Applications* 36 (3) (2009) 6889–6898.
- [271] H. Ince, TB Trafalis, Análisis de componentes principales del núcleo y máquinas de vectores de soporte para la predicción del precio de las acciones, *IEEE Transactions* 39 (6) (2007) 629–637.
- [272] J. Patel, S. Shah, P. Thakkar, K. Kotecha, Predicción del movimiento de acciones e índices de precios de acciones utilizando preparación de datos deterministas de tendencias y técnicas de aprendizaje automático, *Expert Systems with Applications* 42 (1) (2015) 259–268.
- [273] M. Ballings, D. Van den Poel, N. Hespeels, R. Gryp, Evaluación de múltiples clasificadores para la predicción de la dirección del precio de las acciones, *Expert Systems with Applications* 42 (20) (2015) 7046–7056.
- [274] AA Adebiyi, AO Adewumi, CK Ayo, Comparación de modelos de redes neuronales artificiales y arima para la predicción del precio de las acciones, *Journal of Applied Mathematics* 2014 (2014) 1–7.
- [275] X. Li, H. Xie, L. Chen, J. Wang, X. Deng, Impacto de las noticias en el retorno del precio de las acciones a través del análisis de sentimientos, *Knowledge-Based Systems* 69 (2014) 14–23.

- [276] TH Nguyen, K. Shirai, Análisis de sentimientos basado en modelos de temas en las redes sociales para la predicción del mercado de valores, en: Actas de la 53.^a Reunión Anual de la Asociación de Lingüística Computacional y la 7.^a Conferencia Conjunta Internacional sobre Procesamiento del Lenguaje Natural (Volumen 1: Documentos largos), 2015, págs. 1354-1364.
- [277] BM Henrique, VA Sobreiro, H. Kimura, Predicción del precio de las acciones usando regresión de vectores de soporte en precios diarios y actualizados al minuto, *The Journal of finance and data science* 4 (3) (2018) 183–201.
- [278] W. Khan, MA Ghazanfar, MA Azam, A. Karami, KH Alyoubi, AS Alfakeeh, Predicción del mercado de valores utilizando clasificadores de aprendizaje automático y redes sociales, noticias, *Journal of Ambient Intelligence and Humanized Computing* (2020) 1–24.
- [279] F. Zhou, H.-m. Zhou, Z. Yang, L. Yang, Emd2fnn: Una estrategia que combina la descomposición de modos empíricos y una red neuronal basada en una máquina de factorización para la predicción de tendencias del mercado de valores, *Expert Systems with Applications* 115 (2019) 136–151.
- [280] Y. Shynkevich, T. McGinnity, SA Coleman, A. Belatreche, Pronóstico de movimientos de precios de acciones de atención médica basados en diferentes categorías de artículos de noticias utilizando aprendizaje de núcleos múltiples, *Decision Support Systems* 85 (2016) 74–83.
- [281] L. Lei, Método de predicción de la tendencia del precio de las acciones mediante redes neuronales wavelet basado en la reducción aproximada de atributos del conjunto, *Applied Soft Computing* 62 (2018) 923–932.
- [282] Q. Li, L. Jiang, P. Li, H. Chen, Aprendizaje basado en tensores para predecir movimientos de acciones, en: Actas de la Conferencia AAAI sobre Inteligencia Artificial (AAAI), Vol. 29, 2015, págs. 1784-1790.
- [283] B. Luo, J. Zeng, J. Duan, Modelo de espacio de emociones para clasificar opiniones en un foro de mensajes bursátiles, *Expert Systems with Applications* 44 (2016) 138–146.
- [284] L. Liu, J. Wu, P. Li, Q. Li, Un enfoque basado en las redes sociales para predecir el comovimiento de acciones, *Expert Systems with Applications* 42 (8) (2015) 3893–3901.
- [285] TH Nguyen, K. Shirai, J. Velcin, Análisis de sentimientos en las redes sociales para la predicción del movimiento de acciones, *Expert Systems with Applications* 42 (24) (2015) 9603–9611.

- [286] P. Nizer, JC Nievola, Predicción del efecto de las noticias publicadas en el mercado accionario brasileño mercado, *Sistemas Expertos con Aplicaciones* 39 (12) (2012) 10674–10680.
- [287] C.-M. Hsu, Un procedimiento híbrido para la predicción del precio de las acciones mediante la integración de un mapa autoorganizado y programación genética, *Sistemas expertos con aplicaciones* 38 (11) (2011) 14026–14036.
- [288] C.-J. Lu, Integración de un esquema de eliminación de ruido basado en análisis de componentes independientes con redes neuronales para la predicción del precio de las acciones, *Expert Systems with Applications* 37 (10) (2010) 7056–7064.
- [289] MF Zarandi, B. Rezaee, I. Turksen, E. Neshat, Un modelo basado en reglas difusas de tipo 2 Modelo de sistema experto para el análisis de precios de acciones, *Sistemas expertos con aplicaciones* 36 (1) (2009) 139–154.
- [290] P.-C. Chang, C.-H. Liu, Un sistema basado en reglas difusas de tipo tsK para el precio de las acciones predicción, *Sistemas Expertos con Aplicaciones* 34 (1) (2008) 135–144.
- [291] S.-H. Chun, Y.-J. Park, Razonamiento dinámico adaptativo basado en casos: aplicación a la predicción del mercado de valores, *Sistemas expertos con aplicaciones* 28 (3) (2005) 435–443.
- [292] KJ Oh, K.-j. Kim, Análisis de datos de ticks del mercado de valores utilizando modelos no lineales por partes. modelo, *Sistemas Expertos con Aplicaciones* 22 (3) (2002) 249–255.
- [293] Y.-F. Wang, Predicción del precio de las acciones utilizando un sistema de predicción gris difuso, *Experto Sistemas con aplicaciones* 22 (1) (2002) 33–38.
- [294] B. Weng, MA Ahmed, FM Megahed, Predicción del movimiento del mercado de valores con un día de anticipación utilizando fuentes de datos dispares, *Expert Systems with Applications* 79 (2017) 153–163.
- [295] W. Jiang, Aplicaciones del aprendizaje profundo en la predicción del mercado de valores: estudios recientes progreso, *Sistemas Expertos con Aplicaciones* 184 (2021) 115537.
- [296] AE de Oliveira Carosia, GP Coelho, AEA da Silva, Estrategias de inversión Aplicado al mercado de valores brasileño: una metodología basada en análisis de sentimiento con aprendizaje profundo, *Expert Systems with Applications* 184 (2021) 115470.
- [297] H. Rezaei, H. Faaljoui, G. Mansourfar, Predicción del precio de las acciones mediante aprendizaje profundo y descomposición de frecuencias, *Sistemas expertos con aplicaciones* 169 (2021) 114332.

- [298] AU Haq, A. Zeb, Z. Lei, D. Zhang, Pronóstico de la tendencia bursátil diaria mediante selección de características de múltiples filtros y aprendizaje profundo, *Expert Systems with Applications* 168 (2021) 114444.
- [299] N. Jing, Z. Wu, H. Wang, Un modelo híbrido que integra el aprendizaje profundo con el análisis del sentimiento de los inversores para la predicción del precio de las acciones, *Expert Systems with Applications* 178 (2021) 115019.
- [300] Y. Han, J. Kim, D. Enke, Un sistema de comercio de aprendizaje automático para el mercado de valores basado en el etiquetado mínimo-máximo de n períodos utilizando xgboost, *Expert Systems with Applications* 211 (2023) 118581.
- [301] T. Xiong, Y. Bao, Z. Hu, Regresión de vectores de soporte de salida múltiple con un algoritmo Firefly para la predicción de índices de precios de acciones con valores de intervalo, *Knowledge-Based Systems* 55 (2014) 87–100.
- [302] Y. Pan, Z. Xiao, X. Wang, D. Yang, Un enfoque de máquina de vectores de soporte múltiple para la previsión de índices bursátiles con muestreo de frecuencia mixta, *Knowledge-Based Systems* 122 (2017) 90–102.
- [303] D. Wu, X. Wang, S. Wu, Construcción de carteras de acciones basadas en la agrupación de k -medias de características de tendencia continua, *Knowledge-Based Systems* 252 (2022) 109358.
- [304] H. Wang, S. Lu, J. Zhao, Agregación de múltiples tipos de datos complejos en la predicción del mercado de valores: un marco independiente del modelo, *Knowledge-Based Systems* 164 (2019) 193–204.
- [305] Y. Ruan, A. Durrresi, L. Alfantoukh, Uso de la red de confianza de Twitter para el análisis del mercado de valores, *Knowledge-Based Systems* 145 (2018) 207–218.
- [306] J. Ayala, M. García-Torres, JLV Noguera, F. Gómez-Vela, F. Divina, Optimización de la estrategia de análisis técnico utilizando un enfoque de aprendizaje automático en índices bursátiles, *Knowledge-Based Systems* 225 (2021) 107119.
- [307] Y. Yu, W. Duan, Q. Cao, El impacto de los medios sociales y convencionales en el valor patrimonial de las empresas: un enfoque de análisis de sentimientos, *Decision Support Systems* 55 (2013) 919–926.
- [308] K. Nam, N. Seong, Predicción del movimiento de acciones basada en noticias financieras utilizando el análisis de causalidad de la influencia en el mercado de valores de Corea, *Decision Support Systems* 117 (2019) 100–112.

- [309] Z. Zhu, H. He, JA Starzyk, C. Tseng, Matriz de aprendizaje autoorganizada y su aplicación a problemas económicos y financieros, *Ciencias de la información* 177 (5) (2007) 1180–1192.
- [310] T.-T. Chen, S.-J. Lee, Un sistema de aprendizaje basado en ls-svm ponderado para series de tiempo pronóstico, *Ciencias de la Información* 299 (2015) 99–116.
- [311] G. Armano, M. Marchesi, A. Murru, Una arquitectura genética-neural híbrida para la predicción de índices bursátiles, *Information Sciences* 170 (1) (2005) 3–33.
- [312] R. Hafezi, J. Shahrabi, E. Hadavandi, Un sistema multiagente de red neuronal bat (bnnmas) para la predicción del precio de las acciones: estudio de caso del precio de las acciones de DAX, *Applied Soft Computing* 29 (2015) 196–210.
- [313] H. He, S. Gao, T. Jin, S. Sato, X. Zhang, Un modelo de neuronas dendríticas basado en la descomposición de tendencias estacionales para la predicción de series de tiempo financieras, *Applied Soft Computing* 108 (2021) 107488.
- [314] S. Deng, C. Xiao, Y. Zhu, Y. Tian, Z. Liu, T. Yang, Pronóstico dinámico del movimiento del índice de la Bolsa de Valores de Shanghai utilizando múltiples tipos de sentimiento de los inversores, *Applied Soft Computing* 125 (2022) 109132.
- [315] G. Liu, X. Wang, Una nueva métrica para la predicción de tendencias de acciones individuales, *Aplicaciones de ingeniería de inteligencia artificial* 82 (2019) 1–12.
- [316] A. Dezhkam, MT Manzuri, Pronóstico del mercado de valores para una cartera eficiente mediante la combinación de xgboost y la transformada de Hilbert-Huang, *Aplicaciones de ingeniería de inteligencia artificial* 118 (2023) 105626.
- [317] J. Behera, AK Pasayat, H. Behera, P. Kumar, Optimización de cartera de valor medio en riesgo basada en predicciones utilizando algoritmos de regresión de aprendizaje automático para mercados bursátiles multinacionales, *Aplicaciones de ingeniería de inteligencia artificial* 120 (2023) 105843.
- [318] J. Chen, Y. Wen, Y. Nanekaran, M. Suzauddola, W. Chen, D. Zhang, Técnicas de aprendizaje automático para la predicción de precios de acciones y reconocimiento de señales gráficas, *Aplicaciones de ingeniería de inteligencia artificial* 121 (2023) 106038.
- [319] X. Li, P. Wu, W. Wang, Incorporación de precios de acciones y sentimientos de noticias para la predicción del mercado de valores: un caso de Hong Kong, *Procesamiento de la información y gestión* 57 (5) (2020) 102212.

- [320] EJ De Fortuny, T. De Smedt, D. Martens, W. Daelemans, Evaluación y comprensión de modelos de predicción de precios de acciones basados en texto, *Procesamiento de la información y gestión* 50 (2) (2014) 426–441.
- [321] S. Chakraborty, A. Venkataraman, S. Jagabathula, L. Subramanian, Predicción de indicadores socioeconómicos utilizando eventos noticiosos, en: *Actas de la 22.ª Conferencia internacional ACM SIGKDD sobre descubrimiento de conocimiento y minería de datos (KDD)*, 2016, págs. 1455-1464.
- [322] L. Zhang, C. Aggarwal, G.-J. Qi, Predicción del precio de las acciones mediante el descubrimiento de patrones comerciales de múltiples frecuencias, en: *Actas de la 23.ª Conferencia internacional ACM SIGKDD sobre descubrimiento de conocimiento y minería de datos (KDD)*, 2017, págs. 2141-2149.
- [323] C. Chen, L. Zhao, J. Bian, C. Xing, T.-Y. Liu, Los comportamientos de inversión pueden revelar qué hay dentro: exploración de las propiedades intrínsecas de las acciones para la predicción de tendencias bursátiles, en: *Actas de la 25.ª Conferencia internacional ACM SIGKDD sobre descubrimiento de conocimiento y minería de datos (KDD)*, 2019, págs. 2376-2384.
- [324] MA Kaboudan, Predicción de precios de acciones mediante programación genética, *Computational Economics National* 16 (3) (2000) 207–236.
- [325] M. Maragoudakis, D. Serpanos, Explotación de noticias financieras y opiniones de redes sociales para el análisis del mercado de valores utilizando inferencia bayesiana mcmc, *Computational Economics* 47 (4) (2016) 589–622.
- [326] IR Parray, SS Khurana, M. Kumar, AA Altalbe, Análisis de datos de series temporales del movimiento del precio de las acciones utilizando técnicas de aprendizaje automático, *Soft Computing* 24 (2020) 16509–16517.
- [327] Y. Qiu, Z. Song, Z. Chen, Predicción de tendencias bursátiles a corto plazo basada en análisis de sentimientos y aprendizaje automático, *Soft Computing* 26 (5) (2022) 2209–2224.
- [328] RP Schumaker, H. Chen, Evaluación de un operador cuantitativo atento a las noticias: el efecto del impulso y las estrategias de selección de acciones contrarias, *Journal of the American Society for Information Science and Technology* 59 (2) (2008) 247– 255.
- [329] RP Schumaker, H. Chen, Un motor de predicción de precios de acciones discreto basado en noticias financieras, *Computer* 43 (1) (2010) 51–56.

- [330] Q. Li, J. Wang, F. Wang, P. Li, L. Liu, Y. Chen, El papel del sentimiento social en los mercados de valores: una visión desde los efectos conjuntos de múltiples fuentes de información, *Multimedia Tools and Applications* (2016) 1–31.
- [331] X. Li, X. Deng, F. Wang, K. Dong, Análisis empírico: Impacto de las noticias en los precios de las acciones según la densidad de noticias, en: *Talleres de la Conferencia Internacional IEEE sobre Minería de Datos de 2010*, IEEE, 2010, págs. 585-592.
- [332] X. Li, C. Wang, J. Dong, F. Wang, X. Deng, S. Zhu, Mejorar la predicción del mercado de valores mediante la integración de noticias del mercado y precios de las acciones, en: *Aplicaciones de bases de datos y sistemas expertos: 22.ª conferencia internacional, DEXA 2011, Toulouse, Francia, 29 de agosto-2 de septiembre de 2011, Actas, Parte II 22*, Springer, 2011, págs. 279-293.
- [333] X. Li, H. Xie, Y. Song, S. Zhu, Q. Li, FL Wang, ¿Ayuda el resumen a la predicción de acciones? Un análisis del impacto de las noticias, *IEEE Intelligent Systems* 30 (3) (2015) 26–34.
- [334] X. Tang, C. Yang, J. Zhou, Pronóstico del precio de las acciones mediante la combinación de minería de noticias y análisis de series temporales, en: *Conferencia conjunta internacional IEEE/WIC/ACM de 2009 sobre inteligencia web y tecnología de agentes inteligentes (WI-IATW)*, vol. 1, IEEE, 2009, págs. 279-282.
- [335] Y. Gao, L. Zhou, Y. Zhang, C. Xing, Y. Sun, X. Zhu, Clasificación de sentimientos para noticias bursátiles, en: *5.ª Conferencia internacional sobre computación generalizada y aplicaciones*, IEEE, 2010, págs. 99-104.
- [336] T. Gao, Y. Chai, Mejora de la predicción del precio de cierre de acciones utilizando redes neuronales recurrentes e indicadores técnicos, *Neural computation* 30 (10) (2018) 2833– 2854.
- [337] M.-C. Lin, AJ Lee, R.-T. Kao, K.-T. Chen, Predicción del movimiento del precio de las acciones utilizando prototipos representativos de informes financieros, *ACM Transactions on Management Information Systems (TMIS)* 2 (3) (2011) 1–18.
- [338] B. Wang, H. Huang, X. Wang, Un nuevo enfoque de minería de texto para la previsión de series temporales financieras, *Neurocomputing* 83 (2012) 136–145.
- [339] J.-S. Chen, H.-M. Lu, Predicción de acciones a través del sentimiento y el estado social en línea, en: *Conferencia de Asia Pacífico sobre Sistemas de Información*, 2016, pág. 26.

- [340] P.-C. Chang, C.-Y. Fan, Un sistema híbrido que integra un wavelet y reglas difusas ts-k para la previsión de precios de acciones, *IEEE Transactions on Systems, Man, and Cybernetics, Parte C (Aplicaciones y revisiones)* 38 (6) (2008) 802–815.
- [341] M. Hagenau, M. Hauser, M. Liebmann, D. Neumann, Leyendo todas las noticias al mismo tiempo: Predicción de desarrollos de precios de acciones a mediano plazo basados en el impulso de las noticias, en: *2013 46th Hawaii International Conference on System Sciences*, IEEE, 2013, págs. 1279-1288.
- [342] Y. Chen, Z. Wei, X. Huang, Incorporación de la relación corporativa a través de redes neuronales convolucionales de gráficos para la predicción del precio de las acciones, en: *Actas de la 27.ª Conferencia internacional de la ACM sobre gestión de la información y el conocimiento*, 2018, págs. 1655-1658.
- [343] G. Tsibouris, M. Zeidenberg, Prueba de la hipótesis de los mercados eficientes con algoritmos de descenso de gradiente, en: *Redes neuronales en los mercados de capital*, Vol. 8, Wiley Chichester, Reino Unido, 1995, págs. 127-136.
- [344] G. Tsibouris, M. Zeidenberg, Retropropagación como prueba de la hipótesis de los mercados eficientes, en: *Actas de la vigésimo quinta Conferencia Internacional de Hawái*, 1992, págs. 523-532.
- [345] J. Xiao, X. Zhu, C. Huang, X. Yang, F. Wen, M. Zhong, Un nuevo enfoque para el análisis y predicción de precios de acciones basado en ssa y svm, *Revista internacional de tecnología de la información y toma de decisiones* 18 (01) (2019) 287–310.
- [346] X.-Q. Sun, H.-W. Shen, X.-Q. Cheng, La red comercial predice el precio de las acciones, *Informes científicos* 4 (1) (2014) 3711.
- [347] D. Yan, G. Zhou, X. Zhao, Y. Tian, F. Yang, Predicción de acciones usando estados de ánimo de microblogs, *China Communications* 13 (8) (2016) 244–257.
- [348] GE Hinton, RR Salakhutdinov, Reducción de la dimensionalidad de los datos con redes neuronales, *ciencia* 313 (5786) (2006) 504–507.
- [349] X. Ding, Y. Zhang, T. Liu, J. Duan, Aprendizaje profundo para predicción de acciones basada en eventos, en: *Actas de la vigésimo cuarta conferencia conjunta internacional sobre inteligencia artificial (IJCAI)*, 2015, págs. 2327-2333.
- [350] D. Araci, Finbert: Análisis del sentimiento financiero con un modelo de lenguaje pre-entrenado els, preimpresión de arXiv arXiv:1908.10063 (2019).

- [351] Q. Ding, S. Wu, H. Sun, J. Guo, J. Guo, Transformador gaussiano multiescala jerárquico para la predicción del movimiento de acciones., en: Actas de la 29.ª Conferencia Conjunta Internacional sobre Inteligencia Artificial (IJCAI), 2020, págs. 4640–4646.
- [352] A. Lopez-Lira, Y. Tang, ¿Puede chatgpt predecir los movimientos de precios de las acciones? Predicción de retorno y modelos de lenguaje grandes, preimpresión de arXiv arXiv:2304.07619 (2023).
- [353] S. Gao, Y. Wang, X. Yang, Stockformer: Aprendizaje de máquinas comerciales híbridas con codificación predictiva, en: Actas de la trigésima segunda conferencia conjunta internacional sobre inteligencia artificial, IJCAI-23, 2023, págs. 4766–4774.
- [354] J. Huang, R. Xing, Q. Li, Fijación de precios de activos mediante aprendizaje de gráficos profundos para incorporar predictores heterogéneos, International Journal of Intelligent Systems 37 (11) (2022) 8462–8489.
- [355] W. Chen, M. Jiang, W.-G. Zhang, Z. Chen, Una nueva red neuronal convolucional basada en características convolucionales de gráficos para la predicción de tendencias bursátiles, Information Sciences 556 (2021) 67–94.
- [356] R. Sawhney, S. Agarwal, A. Wadhwa, T. Derr, RR Shah, Selección de acciones a través de una red de atención hipergráfica espaciotemporal: un enfoque de aprendizaje para clasificar, en: Actas de la Conferencia AAAI sobre Inteligencia Artificial (AAAI), Vol. 35, 2021, págs. 497–504.
- [357] H. Wang, T. Wang, Y. Li, Incorporación de señales de opinión de inversión basadas en expertos en la predicción de acciones: un marco de aprendizaje profundo, en: Actas de la Conferencia AAAI sobre Inteligencia Artificial (AAAI), Vol. 34, 2020, págs. 971–978.
- [358] Z. Wang, B. Huang, S. Tu, K. Zhang, L. Xu, Deeprader: Un enfoque de aprendizaje de refuerzo profundo para la gestión de carteras equilibradas riesgo-retorno con integración de condiciones de mercado, en: Actas de la Conferencia AAAI sobre Inteligencia Artificial (AAAI), Vol. 35, 2021, págs. 643–650.
- [359] G. Wang, L. Cao, H. Zhao, Q. Liu, E. Chen, Acoplar indicadores financieros macrosectoriales y micro para aprender representaciones de acciones con menos incertidumbre, Actas de la Conferencia AAAI sobre Inteligencia Artificial (AAAI) 35 (5) (2021) 4418–4426.

- [360] R. Wang, H. Wei, B. An, Z. Feng, J. Yao, La tarifa de comisión no es suficiente: un marco jerárquico reforzado para la gestión de cartera, en: Actas de la Conferencia AAAI sobre Inteligencia Artificial (AAAI), Vol. 35, 2021, págs. 626–633.
- [361] Y. Duan, L. Wang, Q. Zhang, J. Li, Factorvae: Un modelo factorial dinámico probabilístico basado en un autocodificador variacional para predecir retornos de acciones transversales, en: Actas de la Conferencia AAAI sobre Inteligencia Artificial (AAAI), Vol. 36, 2022, págs. 4468–4476.
- [362] Z. Shi, Y. Chen, J. Cartlidge, El modelo de recreación lob: predicción del libro de órdenes límite a partir del historial taq utilizando una red neuronal recurrente de ecuaciones diferenciales ordinarias, en: Actas de la Conferencia AAAI sobre Inteligencia Artificial, vol. 35, 2021, págs. 548–556.
- [363] J. Sen, S. Mehtab, Pronóstico preciso del precio de las acciones utilizando modelos de aprendizaje profundo robustos y optimizados, en: Conferencia Internacional sobre Tecnologías Inteligentes (CONIT) de 2021, IEEE, 2021, págs. 1-9.
- [364] H. Qian, H. Zhou, Q. Zhao, H. Chen, H. Yao, J. Wang, Z. Liu, F. Yu, Z. Zhang, J. Zhou, Mdgnn: Red neuronal gráfica dinámica multirrelacional para predicción integral y dinámica de inversiones en acciones, en: Actas de la Conferencia AAAI sobre Inteligencia Artificial (AAAI), 2024, págs. 1–9.
- [365] S. Li, W. Liao, Y. Chen, R. Yan, Pen: red de predicción-explicación para pronosticar el movimiento del precio de las acciones con mejor explicabilidad, en: Actas de la Conferencia AAAI sobre Inteligencia Artificial, Vol. 37, 2023, págs. 5187–5194.
- [366] W. Li, R. Bao, K. Harimoto, D. Chen, J. Xu, Q. Su, Modelado de la relación de acciones con una red gráfica para la predicción del movimiento de acciones durante la noche, en: Actas de la vigésimo novena conferencia internacional sobre conferencias conjuntas internacionales sobre inteligencia artificial (IJCAI), 2021, págs. 4541–4547.
- [367] H. Wang, S. Li, T. Wang, J. Zheng, Modelado temporal-relacional adaptativo jerárquico para la predicción de tendencias bursátiles., en: Actas de la trigésima Conferencia Conjunta Internacional sobre Inteligencia Artificial (IJCAI), 2021, págs. 3691–3698.
- [368] L. Bai, L. Cui, Y. Wang, Y. Jiao, ER Hancock, Un núcleo entrópico de inspiración cuántica para el análisis de múltiples series temporales financieras, en: Actas de la Vigésimo Novena Conferencia Conjunta Internacional sobre Inteligencia Artificial (IJCAI), 2020, págs. 4453–4460.

- [369] R. Cheng, Q. Li, Red de enrutamiento de gráficos basada en subsecuencias para capturar múltiples procesos de propagación de riesgos, en: Actas de la trigésima primera conferencia conjunta internacional sobre inteligencia artificial (IJCAI), 2022, págs. 3810-3816.
- [370] CS Pun, L. Wang, HY Wong, Experimento mental financiero: Un enfoque basado en gan para la selección de carteras amplias y robustas, en: Actas de la 29.^a Conferencia Conjunta Internacional sobre Inteligencia Artificial (IJCAI), 2020, págs. 4619-4625.
- [371] L. Shi, Z. Teng, L. Wang, Y. Zhang, A. Binder, Deepclue: Interpretación visual de la predicción de stock profundo basada en texto, IEEE Transactions on Knowledge and Data Engineering 31 (6) (2018) 1094–1108.
- [372] Y. Zhao, H. Du, Y. Liu, S. Wei, X. Chen, F. Zhuang, Q. Li, G. Kou, Predicción del movimiento de acciones basada en un gráfico de conocimiento de mercado híbrido-relacional bitipado a través de redes de atención dual, IEEE Transactions on Knowledge and Data Engineering (2022).
- [373] H. Wang, T. Wang, S. Li, S. Guan, Hatr-i: Interacción relacional temporal adaptativa jerárquica para la predicción de tendencias bursátiles, IEEE Transactions on Knowledge and Data Engineering 35 (7) (2023) 6988–7002. doi:10.1109/TKDE.2022.3188320 .
- [374] R. Xing, R. Cheng, J. Huang, Q. Li, J. Zhao, Aprendiendo a comprender el gráfico vago para la predicción de acciones con derrames de impulso, IEEE Transactions on Knowledge and Data Engineering (2023).
- [375] H. Wang, T. Wang, S. Li, J. Zheng, W. Chen, W. Chen, De acuerdo en estar en desacuerdo: Integración y enrutamiento temporal personalizado para pronóstico de acciones, IEEE Transactions on Knowledge and Data Engineering (2024).
- [376] J. Long, Z. Chen, W. He, T. Wu, J. Ren, Un marco integrado de aprendizaje profundo y gráficos de conocimiento para la predicción de la tendencia del precio de las acciones: una aplicación en el mercado de valores chino, Applied Soft Computing 91 (2020) 106205.
- [377] HJ Park, Y. Kim, HY Kim, Pronóstico del mercado de valores utilizando un enfoque multitarea que integra la memoria a corto y largo plazo y el marco del bosque aleatorio, Applied Soft Computing 114 (2022) 108106.
- [378] Y. Zhao, G. Yang, Marco integrado basado en aprendizaje profundo para la predicción del movimiento del precio de las acciones, Applied Soft Computing 133 (2023) 109921.

- [379] T. Srivastava, I. Mullick, J. Bedi, Enfoque de aprendizaje profundo basado en minería de asociaciones para pronósticos de series temporales financieras, *Applied Soft Computing* (2024) 111469.
- [380] J. Yoo, Y. Soun, Y.-c. Park, U. Kang, Predicción precisa del movimiento de acciones multivariadas a través de un transformador de ejes de datos con contextos multinivel, en: *Actas de la 27.ª Conferencia ACM SIGKDD sobre descubrimiento de conocimiento y minería de datos (KDD)*, 2021, págs. 2037–2045.
- [381] L. Chauhan, J. Alberg, Z. Lipton, Modelos de factores de previsión conscientes de la incertidumbre para la inversión cuantitativa, en: *Conferencia internacional sobre aprendizaje automático, PMLR*, 2020, págs. 1489-1499.
- [382] J. Wang, Y. Hu, T.-X. Jiang, J. Tan, Q. Li, Aprendizaje tensorial esencial para la predicción del movimiento de existencias basada en información multimodal, *Knowledge-Based Systems* (2023) 110262.
- [383] J. Tan, Q. Li, J. Wang, J. Chen, Finhgnn: Un gráfico heterogéneo condicional que aprende a abordar atributos relacionales para predicciones de acciones, *Information Sciences* 618 (2022) 317–335.
- [384] B. Yang, T. Liang, J. Xiong, C. Zhong, Aprendizaje de refuerzo profundo basado en el marco de trabajo Transformer y U-Net para el comercio de acciones, *Knowledge-Based Systems* 262 (2023) 110211.
- [385] X. Yang, MA Loua, M. Wu, L. Huang, Q. Gao, Predicción de acciones de granularidad múltiple con decisiones secuenciales de tres vías, *Ciencias de la información* 621 (2023) 524–544.
- [386] Z. Hu, W. Liu, J. Bian, X. Liu, T.-Y. Liu, Escuchando susurros caóticos: un marco de aprendizaje profundo para la predicción de tendencias bursátiles orientadas a las noticias, en: *Actas de la undécima Conferencia Internacional de la ACM sobre Búsqueda Web y Minería de Datos (WSDM)*, 2018, págs. 261-269.
- [387] T. Ma, Y. Tan, Clasificación de acciones con aprendizaje multitarea, *Sistemas expertos con aplicaciones* 199 (2022) 116886.
- [388] P. Ghosh, A. Neufeld, JK Sahoo, Pronóstico de movimientos direccionales de precios de acciones para operaciones intradía utilizando lstm y bosques aleatorios, *Finance Research Letters* 46 (2022) 102280.

- [389] S. Sun, R. Wang, B. An, Aprendizaje de refuerzo para el comercio cuantitativo, *ACM Transactions on Intelligent Systems and Technology (TIST)* 14 (3) (2023) 1–29.
- [390] Z. Wang, Z. Hu, F. Li, S.-B. Ho, E. Cambria, Predicción de tendencias bursátiles basada en el aprendizaje mediante la incorporación de indicadores técnicos y sentimiento de las redes sociales, *Cognitive Computation* 15 (3) (2023) 1092–1102.
- [391] Y. Ma, R. Mao, Q. Lin, P. Wu, E. Cambria, Optimización cuantitativa de cartera de acciones mediante aprendizaje multitarea de riesgo y rendimiento, *Information Fusion* 104 (2024) 102165.
- [392] X. Ding, Y. Zhang, T. Liu, J. Duan, Uso de eventos estructurados para predecir el movimiento del precio de las acciones: una investigación empírica, en: *Actas de la conferencia de 2014 sobre métodos empíricos en el procesamiento del lenguaje natural (EMNLP)*, 2014, págs. 1415-1425.
- [393] X. Jin, N. Yang, Cómo la cobertura mediática afecta el rendimiento de las acciones de las empresas inmobiliarias que cotizan en bolsa en China, en: *2013 6ª Conferencia internacional sobre gestión de la información, gestión de la innovación e ingeniería industrial*, vol. 2, IEEE, 2013, págs. 240-243.
- [394] X. Ding, Y. Zhang, T. Liu, J. Duan, Integración de eventos basada en conocimiento para predicción de stock, en: *Actas de Coling 2016, la 26.ª conferencia internacional sobre lingüística computacional: Documentos técnicos*, 2016, págs. 2133-2142.
- [395] H. Li, Y. Shen, Y. Zhu, Predicción del precio de acciones utilizando lstm multientrada basado en atención, en: *Actas de la Conferencia asiática sobre aprendizaje automático*, PMLR, 2018, págs. 454-469.
- [396] T. Yin, C. Liu, F. Ding, Z. Feng, B. Yuan, N. Zhang, Correlación y predicción de acciones basada en gráficos para sistemas de comercio de alta frecuencia, *Pattern Recognition* 122 (2022) 108209.
- [397] J. Cao, J. Wang, Exploración del modelo de predicción de cambios en el índice bursátil basado en la combinación de análisis de componentes principales y redes neuronales artificiales, *Soft Computing* 24 (2020) 7851–7860.
- [398] AF Kamara, E. Chen, Z. Pan, Un conjunto de un híbrido potenciado de modelos de aprendizaje profundo y análisis técnico para pronosticar precios de acciones, *Information Sciences* 594 (2022) 1–19.

- [399] Y. Huang, X. Mao, Y. Deng, Codificación de visibilidad natural para series de tiempo y su aplicación en la predicción de tendencias bursátiles, *Knowledge-Based Systems* 232 (2021) 107478.
- [400] Y. Gu, D. Yan, S. Yan, Z. Jiang, Pronóstico de precios con datos financieros de alta frecuencia: un modelo de red neuronal recurrente autorregresiva con indicadores técnicos, en: *Actas de la 29.a Conferencia Internacional sobre Gestión de la Información y el Conocimiento (CIKM)*, ACM, 2020, págs. 2485-2492.
- [401] W. Tai, T. Zhong, Y. Mo, F. Zhou, Aprendizaje de señales sentimentales y financieras con flujos normalizadores para la predicción del movimiento de acciones, *IEEE Signal Processing Letters* 29 (2021) 414–418.
- [402] Y. Zheng, Y. Yang, B. Chen, Incorporación de conocimiento previo del dominio financiero en redes neuronales para la predicción de la superficie de volatilidad implícita, en: *Actas de la 27.ª Conferencia ACM SIGKDD sobre descubrimiento de conocimiento y minería de datos*, 2021, págs. 3968–3975.