



ANÁLISIS DEL SENTIMIENTO SOCIAL Y RENDIMIENTO BURSÁTIL MEDIANTE MODELOS TRANSFORMER Y GRAFOS

Kevin David Farinango Cinilin¹
ORCID: 0000000320390248

¹ Investigador, Asuskf.. Correo: kfarinango@protonmail.com

RESUMEN

El crecimiento de las redes sociales ha transformado la manera en que los inversionistas reaccionan ante la información financiera difundida en plataformas como X (Twitter), impulsando nuevas metodologías para el análisis bursátil. En este contexto, la presente investigación analizó la relación entre el sentimiento social y el rendimiento bursátil mediante modelos Transformer y la base de datos de grafos en memoria Grafeo. Se empleó un enfoque cuantitativo y correlacional utilizando el conjunto de datos Stock Tweets for Sentiment Analysis and Prediction de Kaggle, correspondiente al periodo comprendido entre septiembre de 2021 y septiembre de 2022. La metodología integró procesamiento de lenguaje natural, clasificación automática de sentimiento y consultas Cypher sobre una infraestructura orientada a grafos. Los resultados evidenciaron una correlación positiva moderada entre el sentimiento optimista y las subidas bursátiles ($r = 0.3318$), así como una correlación inversa entre el sentimiento negativo y las caídas del mercado ($r = -0.3048$). Durante escenarios de alta volatilidad superiores al 2.0 %, dichas correlaciones aumentaron hasta $r = 0.4025$ y $r = -0.3926$, respectivamente. Además, el sentimiento negativo presentó una persistencia temporal 51.3 % mayor que el optimismo. En el análisis computacional, Grafeo resolvió las relaciones complejas en 2 minutos con 58 segundos, frente a los 40 y 30 minutos registrados por Pandas y Polars, reduciendo el tiempo de ejecución en más de un 90 % respecto a Pandas. Se concluye que la integración de modelos Transformer y grafos en memoria permite analizar eficientemente relaciones complejas entre sentimiento social y comportamiento bursátil.

Palabras clave: Análisis de Sentimiento, Bases de Datos de Grafos, Modelos Transformer

ABSTRACT

The growth of social media has transformed the way investors react to financial information disseminated on platforms such as X (Twitter), driving the development of new methodologies for stock market analysis. In this context, the present study analyzed the relationship between social sentiment and stock market performance using Transformer models and the in-memory graph database Grafeo. A quantitative and correlational approach was applied using the Stock Tweets for Sentiment Analysis and Prediction dataset from Kaggle, covering the period from September 2021 to September 2022. The methodology integrated natural language processing, automated sentiment classification, and Cypher queries on a graph-oriented infrastructure. The results revealed a moderate positive correlation between optimistic sentiment and stock market increases ($r = 0.3318$), as well as an inverse correlation between negative sentiment and market declines ($r = -0.3048$). During high-volatility scenarios exceeding 2.0%, these correlations increased to $r = 0.4025$ and $r = -0.3926$, respectively. Furthermore, negative sentiment showed a temporal persistence 51.3% greater than optimism. In the computational analysis, Grafeo resolved complex relationships in 2 minutes and 58 seconds, compared to the 40 and 30 minutes recorded by Pandas and Polars, reducing execution time by more than 90% relative to Pandas. It is concluded that the integration of Transformer models and in-memory graphs enables efficient analysis of complex relationships between social sentiment and stock market behavior.

Keywords: Graph Databases, Sentiment Analysis, Transformer Models.

INTRODUCCIÓN

El crecimiento de las redes sociales ha transformado la manera en que los inversionistas acceden, interpretan y reaccionan a la información financiera. Plataformas como Twitter (actualmente X) se han convertido en espacios donde usuarios, analistas y medios especializados publican opiniones capaces de influir en la percepción colectiva del mercado y en la toma de decisiones bursátiles. Diversos estudios demuestran que el sentimiento expresado en redes sociales mantiene una relación directa con las fluctuaciones financieras y el comportamiento de los inversionistas (Chauhan et al., 2025, p. 02). En este contexto, el análisis de sentimiento adquiere relevancia como herramienta para identificar patrones emocionales asociados al comportamiento del mercado.

No obstante, gran parte de los modelos tradicionales de análisis financiero se centra únicamente en variables económicas y estadísticas, dejando de lado las relaciones dinámicas entre el sentimiento social, la temporalidad y el comportamiento bursátil. Asimismo, los modelos relacionales convencionales presentan limitaciones para representar conexiones complejas entre publicaciones, empresas, fechas y movimientos financieros. Según (Mohammed et al., 2025, p. 02), las bases de datos orientadas a grafos permiten modelar estas estructuras relacionales complejas mediante nodos y aristas, favoreciendo consultas más eficientes y el análisis de patrones conectivos mediante grafos de conocimiento.

Paralelamente, el desarrollo de técnicas de procesamiento de lenguaje natural (PLN) basadas en arquitectura transformer ha mejorado significativamente la precisión en tareas de clasificación de texto y análisis de sentimiento (Nasiopoulos et al., 2025, p. 02). Modelos derivados de RoBERTa y BERT han mostrado un alto desempeño en la clasificación contextual de publicaciones financieras y el lenguaje ruidoso propio de las redes sociales (Semary et al., 2023). Estas tecnologías permiten automatizar la categorización de publicaciones en métricas positivas, negativas y neutrales, facilitando el procesamiento masivo de información textual.

Ante este panorama, la presente investigación resulta relevante debido al creciente impacto que las redes sociales ejercen sobre los mercados financieros y la necesidad de integrar herramientas analíticas capaces de representar dichas interacciones. El estudio utiliza el conjunto de datos Stock Tweets for Sentiment Analysis and Prediction (Yukhymenko, 2023), correspondiente al periodo comprendido entre el 30 de septiembre de 2021 y el 29 de septiembre de 2022. Para el análisis, se implementa una base de datos orientada a grafos en memoria y consultas mediante el lenguaje Cypher, con el fin de representar las relaciones entre publicaciones, empresas y comportamiento bursátil.

El objetivo general de esta investigación consiste en analizar la relación entre el sentimiento social expresado en publicaciones financieras y el rendimiento bursátil de empresas tecnológicas mediante bases de datos de grafos. Como objetivos específicos se plantea:

- Construir una base de datos orientada a grafos que integre datos bursátiles y publicaciones financieras de la red social X.
- Clasificar automáticamente el sentimiento de las publicaciones utilizando modelos transformer,
- Analizar las correlaciones entre el sentimiento social y las variaciones bursátiles
- Evaluar las relaciones temporales entre el comportamiento emocional y el mercado financiero.

La hipótesis de investigación establece que existe una relación significativa entre el sentimiento social expresado en publicaciones financieras y las variaciones del rendimiento bursátil de empresas tecnológicas, especialmente durante periodos de alta volatilidad. Además, se postula que es posible representar dichas relaciones de manera eficiente mediante bases de datos de grafos y consultas relacionales utilizando Cypher.

ESTADO DEL ARTE

Avances y limitaciones en el procesamiento de lenguaje natural y análisis topológico

La literatura técnica actual evidencia que el análisis de sentimiento bursátil requiere arquitecturas capaces de capturar dependencias a largo plazo y la semántica implícita del vocabulario financiero. (Kaur et al., 2025, p. 13) demuestran que los modelos derivados de BERT y RoBERTa superan a los enfoques tradicionales gracias a sus mecanismos de autoatención bidireccional (bidirectional selfattention), los cuales ponderan dinámicamente el contexto de cada token en secuencias de texto ruidosas, como las provenientes de redes sociales. Adicionalmente, investigaciones recientes exploran la implementación de estructuras de Mezcla de Expertos (Mixture of Experts, MoE) en el dominio financiero, permitiendo que subredes especializadas procesen diferentes tipos de jerga bursátil sin incrementar el costo computacional de inferencia de manera lineal (Ding et al., 2025, p. 04). Sin embargo, al contrastar estos estudios, se observa una limitación metodológica recurrente: aunque estos modelos logran alta precisión en la clasificación textual aislada, la mayoría presenta deficiencias al intentar modelar computacionalmente cómo este sentimiento se propaga espacial y temporalmente entre los distintos actores del mercado. Para representar la complejidad de las interacciones bursátiles y sociales, el paradigma analítico actual exige infraestructuras que superen las limitaciones algebraicas de los modelos relacionales. (Besta et al., 2024) establecen que el diseño computacional óptimo recae en las bases de datos orientadas a grafos. La integración del análisis de sentimiento profundo con topologías de red conforma el enfoque grafos de conocimiento que domina la ciencia de datos actual. (Pan et al., 2024, p. 11) evidencian que los grafos actúan como una infraestructura simbólica que fundamenta empíricamente las inferencias de los modelos transformer, mitigando deficiencias lógicas frente a correlaciones espaciotemporales complejas. No obstante, gran parte de la investigación contemporánea aplica estos ecosistemas de manera desconectada o sobre infraestructuras persistidas en disco físico. Al prescindir de arquitecturas en memoria (in-memory) como Grafeo, que garantizan el recorrido analítico de millones de nodos y aristas al eliminar los cuellos de botella de acceso a disco físico (West, 2026, párr. 7), los estudios previos enfrentan severas limitaciones de latencia para evaluar la dinámica financiera en tiempo real.

Vacío de conocimiento

Al analizar la literatura expuesta, se evidencia que los estudios previos abordan la precisión del procesamiento textual y la representación topológica como retos aislados, o bien carecen de la infraestructura computacional para procesarlos de manera concurrente y eficiente. El vacío de conocimiento que esta investigación pretende cubrir es la falta de marcos analíticos que integren directamente modelos transformer de clasificación ternaria con bases de datos de grafos en memoria pura. Esta convergencia metodológica busca superar las limitaciones analíticas de los enfoques convencionales, permitiendo cuantificar sin cuellos de botella computacionales las relaciones complejas, la asimetría y la persistencia temporal del sentimiento social frente a las variaciones bursátiles, específicamente en escenarios de alta volatilidad.

MARCO TEÓRICO

Finanzas conductuales y sentimiento del mercado

El análisis del comportamiento bursátil se fundamenta en el contraste entre la teoría financiera clásica y las finanzas conductuales. La Hipótesis de los Mercados Eficientes (HME), propuesta tradicionalmente por Fama (1970), establece que los precios de las acciones reflejan toda la información pública disponible, asumiendo que los inversionistas actúan de manera estrictamente racional. Sin

embargo, las finanzas conductuales refutan este principio de racionalidad absoluta. Basándose en los postulados de la psicología cognitiva (Kahneman & Tversky, 1979), esta disciplina sostiene que los individuos toman decisiones financieras influenciados por sesgos cognitivos, heurísticas y emociones colectivas. En la actualidad, las redes sociales actúan como un sensor masivo de esta psicología colectiva. El análisis de sentimiento financiero parte del principio teórico de que el estado de ánimo agregado en plataformas como X (Twitter) genera señales emocionales cuantificables que anteceden y explican la volatilidad de los precios en el mercado, capturando el factor irracional que los modelos econométricos tradicionales ignoran.

Procesamiento de lenguaje natural y arquitectura transformer

El procesamiento de lenguaje natural (PLN) es la rama de la inteligencia artificial que modela la comprensión computacional del lenguaje humano. El sustento tecnológico contemporáneo del PLN radica en la arquitectura transformer (Vaswani et al., 2023). Teóricamente, esta arquitectura abandona el procesamiento secuencial de las redes neuronales recurrentes para emplear un mecanismo de "autoatención" (self-attention). Este mecanismo pondera matemáticamente la importancia de cada palabra dentro de una oración, independientemente de su posición, permitiendo al modelo comprender el contexto bidireccional y las dependencias semánticas a largo plazo. En el contexto de esta investigación, modelos derivados de esta arquitectura (como BERT o RoBERTa) resultan fundamentales teóricamente porque tienen la capacidad de decodificar el lenguaje financiero no estructurado, interpretando correctamente el sarcasmo, la jerga bursátil y el ruido sintáctico propio de las publicaciones de microblogging para clasificarlas en polaridades (positiva, negativa o neutral).

Teoría de grafos y bases de datos en memoria

En el modelado de datos interconectados, la teoría de grafos supera las limitaciones computacionales del modelo relacional tradicional, el cual impone un alto costo al cruzar información mediante tablas (JOINS). Teóricamente, un grafo se define como un conjunto de vértices (nodos) y aristas (relaciones) que estructuran la información espacialmente. Esta topología trata las relaciones como entidades de primera clase, facilitando la representación natural de ecosistemas complejos como la propagación de un tuit y su impacto financiero en una empresa tecnológica.

Para gestionar redes de gran escala, la infraestructura de la base de datos resulta determinante. El modelo teórico se materializa mediante el uso de bases de datos en memoria (in-memory), como GrafeoDB. Esta arquitectura aloja la totalidad del grafo en la memoria principal (RAM), garantizando la propiedad matemática de adyacencia libre de índices (index-free adjacency). Al prescindir de las búsquedas en discos físicos, se elimina la latencia y se alcanza una complejidad algorítmica de recorrido de $O(1)$ por arista (Robinson et al., 2015, p. 17). Sobre esta infraestructura se ejecuta el análisis topológico, calculando métricas de centralidad e influencia. Finalmente, la articulación de este modelo se realiza a través de Cypher, un lenguaje declarativo que opera mediante la coincidencia de patrones espaciales (pattern matching), permitiendo evaluar interdependencias complejas de una acción de manera intuitiva y eficiente.

METODOLOGÍA

Diseño de la investigación y limitaciones

La investigación se desarrolló bajo un enfoque cuantitativo con un diseño experimental de tipo computacional. Para garantizar la reproducibilidad, el entorno de ejecución se configuró en Google Colab con aceleración por GPU (con aproximadamente 15 GB de VRAM disponible), empleando el framework PyTorch y almacenando la base de datos de grafos directamente en Google Drive. La recolección de

información se limitó de manera exclusiva a los registros secundarios del conjunto de datos Stock Tweets for Sentiment Analysis and Prediction (Yukhymenko, 2023), descargado directamente vía la librería kagglehub, comprendido entre el 30 de septiembre de 2021 y el 29 de septiembre de 2022. Este conjunto de datos integró dos dimensiones de análisis fundamentales: por un lado, una muestra social compuesta por 80,793 publicaciones financieras (tuits) asociadas a 25 empresas, con una marcada predominancia de la empresa Tesla (TSLA), la cual concentró el mayor volumen de interés con 37,422 interacciones y, por otro lado, una muestra financiera que consolidó 6,300 registros diarios de cotización bursátil a lo largo de 252 días hábiles para los mismos activos. Al no realizarse extracción de datos en tiempo real y utilizar un entorno de pruebas cerrado, los resultados del experimento quedaron estrictamente condicionados a este volumen específico de información, al contexto económico y a los sesgos textuales capturados dentro de dicho dataset.

Procesamiento de datos e infraestructura de grafos

El preprocesamiento de la información implicó la limpieza sintáctica de los textos (remoción de espacios en blanco y normalización de comillas) y la estandarización de las fechas eliminando las zonas horarias. Para asegurar la integridad relacional, se generaron identificadores únicos mediante funciones de hash MD5 que combinaron fechas, textos y tickers bursátiles. La base de datos orientada a grafos (GrafeoDB) se estructuró modelando nodos para Tweets, Empresas (Company), Datos de Mercado (MarketData) y Fechas de Transacción (TradingDate), interconectados mediante relaciones semánticas direccionales como MENTIONS, POSTED_ON, PRICED_FOR y NEXT_TRADING_DAY para mantener la cronología temporal.

Criterios de selección, hiperparámetros y evaluación de modelos de sentimiento

La primera fase del experimento se centró en el procesamiento de lenguaje natural. El criterio principal para la selección de los modelos evaluados, obtenidos desde el repositorio de Hugging Face, fue contrastar una arquitectura de clasificación binaria frente a una ajustada al dominio específico de redes sociales con dimensión neutral. En concreto, se implementaron los modelos siebert/sentiment-roberta-large-english y cardiffnlp/twitter-roberta-base-sentiment-latest. Para garantizar la reproducibilidad de la inferencia computacional, se establecieron los siguientes hiperparámetros: uso de precisión de media precisión (Half precision, torch_dtype=torch.float16) para optimizar el uso de memoria en la GPU, truncamiento de textos a un máximo de 512 caracteres (truncation=True), y tamaños de lote (batch sizes) ajustados entre 128 y 512 dependiendo del pipeline analítico ejecutado. Cada modelo procesó de manera independiente la muestra de publicaciones para categorizarlas en sentimiento positivo, negativo o neutral, en otro sólo modelo positivo, negativo.

Procedimiento de validación y métricas estadísticas

El procedimiento de validación consistió en un análisis de distribución categórica cruzada para detectar anomalías o sobreestimaciones algorítmicas, utilizando como métrica de éxito cualitativa la capacidad del modelo para aislar el ruido factual en la clase neutral. Cuantitativamente, para evaluar las relaciones financieras, se utilizó el Coeficiente de Correlación de Pearson (r) contrastando los porcentajes diarios de sentimiento (positivo/negativo) frente a la variación porcentual del mercado, calculada como la diferencia entre el precio de cierre y apertura respecto a la apertura $((\text{Close} - \text{Open}) / \text{Open} * 100)$. Las condiciones de estrés bursátil se determinaron aislando aquellas sesiones operativas cuya variación absoluta superó el umbral del 2.0 %. Por su parte, la persistencia temporal del sentimiento social se cuantificó estructurando las variables de polaridad con un rezago temporal de un día (t-1).

Análisis comparativo de rendimiento computacional

Como parte integral del diseño experimental, se ejecutó un análisis de rendimiento (benchmarking) para evaluar los tiempos de ejecución y la eficiencia en el manejo de relaciones complejas. Se comparó el tiempo de procesamiento de los datos utilizando tres tecnologías distintas: la librería Pandas (basada en procesamiento tradicional de un solo hilo), la librería Polars (optimizada para la manipulación tabular multihilo) y GrafeoDB. Esta métrica de tiempo permitió cuantificar empíricamente las diferencias de latencia entre el álgebra relacional de DataFrames y el recorrido de adyacencia libre de índices dentro del entorno de grafos.


RESULTADOS

Análisis comparativo de rendimiento computacional

El benchmarking ejecutado para medir la eficiencia en el procesamiento de la red y la gestión de relaciones complejas evidenció las limitaciones del álgebra relacional tabular frente a las estructuras topológicas. Al someter el conjunto de datos a las rutinas de correlación y cruce de variables, la librería Pandas (basada en un procesamiento de un solo hilo) registró un tiempo de ejecución de 40 minutos. Por su parte, la librería Polars, aprovechando su arquitectura multihilo, logró reducir este tiempo a 30 minutos. Sin embargo, la base de datos de grafos (Grafeo) superó ampliamente a ambas herramientas analíticas. Gracias a su procesamiento en memoria y su adyacencia libre de índices, el motor de grafos resolvió la misma carga relacional en apenas 2 minutos con 58 segundos. Esta drástica reducción en la latencia computacional se ilustra en la Figura 1.

Figura 1

Comparación de tiempos de ejecución entre tecnologías tabulares y la base de datos de grafos



Nota. El eje vertical representa el tiempo de procesamiento expresado en minutos. La arquitectura de


Grafeo demuestra una optimización significativa, reduciendo el tiempo de ejecución en más de un 90 % en comparación con la librería Pandas.

Análisis y selección del modelo de clasificación textual

Como parte del diseño experimental, y considerando que la empresa Tesla (TSLA) concentró la mayor proporción de interacciones dentro del conjunto de datos, se seleccionó a este activo como caso de estudio representativo para acotar la fase de pruebas algorítmicas. Sobre este volumen mayoritario de publicaciones, se ejecutó una evaluación comparativa entre dos arquitecturas de procesamiento de lenguaje natural para determinar su idoneidad en la captura de señales financieras. Específicamente, se contrastó el modelo siebert/sentiment-roberta-large-english, ajustado para una clasificación binaria general, frente al modelo cardiffnlp/twitter-roberta-base-sentiment-latest, entrenado sobre el corpus TweetEval con una estructura de clasificación ternaria. Los resultados empíricos evidenciaron divergencias críticas derivadas de la dimensionalidad de sus etiquetas, fenómeno que se ilustra en la Figura 2.

Figura 2

Comparación de la Distribución de Sentimientos y Evolución Temporal entre Modelos



Nota. El panel izquierdo muestra la distribución porcentual de las categorías de sentimiento identificadas por cada modelo sobre el total de la muestra. El panel derecho ilustra la tendencia del sentimiento positivo a lo largo del periodo bursátil, suavizada mediante una media móvil de 10 días. Se evidencia cómo el modelo binario (Siebert) sobreestima la proporción de sentimiento positivo al carecer de una dimensión neutral que filtre el ruido informativo factual, a diferencia del modelo ternario (CardiffNLP).

El modelo binario (**Siebert**) forzó la categorización de la totalidad de la muestra en polaridades extremas, arrojando un promedio global de 65.63 % de sentimiento positivo y 34.37 % de sentimiento negativo, con nulo reconocimiento de la neutralidad. Esta restricción algorítmica generó un fenómeno de polarización artificial. En plataformas de microblogging, una gran proporción de los textos bursátiles corresponde a titulares de noticias, cotizaciones factuales o reportes de volumen que carecen de sesgo emocional implícito. Al no disponer de una dimensión neutral, el modelo Siebert sobreestimó drásticamente el optimismo del mercado, asimilando el ruido informativo dentro de la categoría positiva. En contraste, la implementación del modelo ternario especializado (**CardiffNLP**) mitigó esta distorsión al emplear la categoría neutral como un mecanismo de filtrado analítico. Bajo esta arquitectura, el 47.24 % de las publicaciones fue clasificado como información neutra, lo que sinceró el sentimiento positivo a un 37.46 % y el negativo a un 15.30 %. Esta distribución ternaria demostró ser computacional y

conceptualmente superior para el experimento. Al aislar la información puramente factual (ruido sistémico), el modelo logró discriminar las verdaderas señales de euforia o pánico (polaridades puras) de los inversionistas, garantizando que la topología de la red evaluada posteriormente en la base de datos de grafos estuviera fundamentada en un contagio emocional legítimo y no en interacciones informativas genéricas.

Análisis topológico y correlación bursátil


Tras la consolidación de la topología espacial en la base de datos de grafos y la asignación del indicador de estado de ánimo diario mediante el modelo ternario (CardiffNLP), se ejecutó un análisis estadístico para medir la fuerza de la relación lineal entre el sentimiento social de la red y los retornos del mercado. Para evaluar la significancia de los hallazgos y someter a prueba la hipótesis de investigación, se calculó el coeficiente de correlación de Pearson (r) junto con su respectivo valor de probabilidad (p) y un intervalo de confianza (IC) del 95%.

para evaluar la correspondencia entre el porcentaje de tuits polarizados y la variación porcentual diaria entre el precio de apertura y cierre del activo (TSLA), arrojando resultados que respaldan empíricamente la hipótesis de la investigación.

Los hallazgos cuantitativos demostraron la existencia de una relación positiva moderada entre el volumen de publicaciones optimistas y las subidas del precio de la acción, registrando un coeficiente de $r = 0.3318$ ($p < 0.01$), IC 95% [0.22, 0.43]. Al ser el valor p inferior al nivel de significancia alfa de 0.05, se rechaza la hipótesis nula de ausencia de correlación. De manera análoga, el análisis topológico evidenció una relación inversa clara respecto al pesimismo colectivo; la acumulación algorítmica de aristas de sentimiento negativo correlacionó directamente con las caídas bursátiles del activo, obteniendo un coeficiente de $r = -0.3048$ ($p < 0.01$, IC 95% [-0.41, -0.19]). Estos resultados confirman que tanto la euforia como el pánico social capturados en la red mantienen una correspondencia cuantificable y estadísticamente sólida con las fluctuaciones direccionales del mercado. La dispersión de las observaciones diarias y sus respectivas líneas de tendencia geométrica se ilustran en la Figura 3.

Figura 3

Correlación de Pearson entre sentimiento social y retorno de mercado bursátil



Nota. Gráficos de dispersión que evalúan la relación lineal entre el estado de ánimo diario y el retorno financiero. El panel izquierdo ilustra la correlación positiva moderada ($r = 0.33$) del sentimiento positivo, indicando que, a mayor optimismo social, la tendencia del precio es al alza. El panel derecho refleja la


correlación inversa ($r = -0.30$) del sentimiento negativo respecto a las variaciones de la acción, demostrando que picos de negatividad en la red coinciden con retrocesos en la cotización.

Intensificación de la correlación bajo estrés de mercado

Para evaluar el impacto de la volatilidad en la dinámica analizada, se ejecutó un análisis comparativo que contrasta la muestra global operativa frente a eventos de estrés bursátil (días con volatilidad $> 2.0\%$). Los hallazgos cuantitativos demuestran que la correspondencia lineal entre el estado de ánimo de la red y los retornos financieros se intensifica significativamente bajo condiciones de incertidumbre. En la muestra global, la relación entre el sentimiento positivo y las subidas del mercado registró un coeficiente de $r = 0.3318$, mientras que el pesimismo y las caídas mostraron una relación inversa de $r = -0.3048$. Sin embargo, al aislar los eventos de alta volatilidad, la magnitud absoluta de estas correlaciones ($|r|$) se fortaleció notablemente: la correlación alcista escaló a $r = 0.4025$ ($p < 0.001$) y la bajista se profundizó hasta un $r = -0.3926$ ($p < 0.001$). Estos resultados (Figura 4) respaldan empíricamente que, durante los periodos de turbulencia financiera, la euforia y el pánico social se acoplan con mayor intensidad a la direccionalidad del mercado.

Figura 4

Correlación de Pearson entre sentimiento social y retorno de mercado bursátil




Nota. Gráfico de barras que ilustra la magnitud de la correlación de Pearson ($|r|$) según el régimen de volatilidad. Se evidencia que el estrés de mercado (volatilidad $> 2.0\%$) actúa como catalizador, fortaleciendo la relación entre el sentimiento social y las variaciones de la acción tanto en escenarios alcistas (panel izquierdo) como bajistas (panel derecho).

Persistencia temporal y asimetría del sentimiento social

Para evaluar la memoria temporal de los estados de ánimo en la red y su relación con el activo, se construyó una matriz de correlación cruzada incorporando variables rezagadas un periodo ($t - 1$). Este análisis permitió contrastar la influencia del sentimiento previo frente al comportamiento del mercado en el tiempo actual (t). Los resultados revelan una asimetría significativa en la autocorrelación de las emociones sociales. Cuantitativamente, el pesimismo demuestra una mayor memoria temporal ($r = 0.392$) en comparación con el optimismo ($r = 0.259$). Esta diferencia indica empíricamente que el sentimiento negativo es un 51.3% más persistente de un día para otro, sugiriendo que las "olas de pánico" o incertidumbre tienden a prolongarse con mayor intensidad en la red. Por otro lado, respecto a la interacción con el activo, la matriz evidencia que los estados de ánimo rezagados ($t - 1$) carecen de una correlación lineal significativa con el retorno del mercado del día actual ($r = -0.005$ para el optimismo previo y $r = -0.016$ para el pesimismo previo). Este hallazgo sugiere que el precio de la acción absorbe la información social de manera eficiente e inmediata, reaccionando predominantemente al sentimiento concurrente (Figura 5).

Figura 5

Matriz de Correlación Cruzada y Persistencia del Sentimiento.



Nota. Mapa de calor (heatmap) que ilustra los coeficientes de correlación de Pearson entre las polaridades de sentimiento concurrente (t), sus variables rezagadas ($t - 1$) y el retorno del mercado actual. Las celdas en tonos verdes denotan correlaciones positivas, mientras que los cálidos reflejan relaciones inversas. El gráfico destaca la mayor inercia temporal del sentimiento negativo (0.392) frente al positivo (0.259), así

como la nula capacidad de arrastre del sentimiento del día anterior sobre las fluctuaciones bursátiles presentes.

DISCUSIÓN

Los resultados empíricos de esta investigación demuestran que el estado de ánimo agregado en redes sociales genera señales emocionales cuantificables que explican el comportamiento direccional del mercado. Estos hallazgos respaldan los postulados de las finanzas conductuales frente a la Hipótesis de los Mercados Eficientes, evidenciando que factores irracionales como la psicología colectiva influyen directamente en la toma de decisiones financieras.

Al profundizar el diálogo con la literatura científica internacional, los resultados de este estudio presentan divergencias importantes respecto a investigaciones previas. Mientras trabajos recientes como los de (Chauhan et al., 2025, p. 02) reportan altas precisiones predictivas utilizando datos extraídos de sitios web financieros autorizados u oficiales, esta investigación revela que en redes de microblogging (como X), la correlación lineal general con los retornos bursátiles es moderada. Esta diferencia se atribuye a la alta densidad de "ruido sistémico" (titulares de noticias, bots y cotizaciones factuales) presente en plataformas sociales abiertas, lo que diluye la fuerza de la señal emocional pura. Esto subraya la necesidad de implementar filtros previos rigurosos antes de asumir causalidad.

Al contrastar las infraestructuras de procesamiento, se evidencia que la base de datos de grafos en memoria (Grafeo) supera ampliamente a las tecnologías tabulares tradicionales, logrando resolver cargas relacionales con una reducción del tiempo de ejecución superior al 90% respecto a librerías como Pandas. Este rendimiento confirma lo expuesto en la literatura técnica por Besta et al. (2024) y West (2026), ratificando que la adyacencia libre de índices es la arquitectura óptima para eliminar los cuellos de botella al analizar topologías interconectadas.

En el ámbito del procesamiento de lenguaje natural, la selección de modelos transformer demuestra ser decisiva. El estudio revela que los modelos de clasificación binaria (como Siebert) sobreestiman drásticamente el optimismo al forzar polaridades extremas y no filtrar el ruido informativo factual. En contraste, el uso de arquitecturas especializadas con clasificación ternaria (CardiffNLP) mitiga esta distorsión al clasificar el 47.24% de las publicaciones como información neutral. Este hallazgo contrasta con la tendencia de algunos estudios actuales (Nasiopoulos et al., 2025, p. 20), los cuales advierten que el sentimiento neutral es la categoría más difícil de clasificar con precisión, ya que el lenguaje financiero suele difuminar la línea entre la neutralidad y la polaridad leve. Esto demuestra que omitir la dimensión neutral para forzar polaridades extremas compromete severamente la validez de las inferencias espaciales en el grafo, reafirmando la necesidad de utilizar la neutralidad como un mecanismo indispensable para filtrar el ruido informativo.

Se destaca como un hallazgo fundamental la intensificación de las correlaciones durante periodos de estrés de mercado. Al superar el 2.0% de volatilidad, la correlación entre el sentimiento positivo y el alza bursátil escala a $r = 0.4025$, mientras que la relación inversa del pesimismo se profundiza a $r = -0.3926$. A esto se suma el descubrimiento de una marcada asimetría temporal: el sentimiento negativo demuestra una persistencia de un día para otro 51.3% mayor que el optimismo en la red social. Sin embargo, la matriz de correlación cruzada expone que el precio de la acción absorbe esta información de manera inmediata, ya que el sentimiento rezagado carece de una correlación lineal significativa con el retorno del mercado del día actual.

Las implicaciones de estos hallazgos para futuras investigaciones en inteligencia artificial financiera son sustanciales. Los resultados sugieren que el desarrollo de estrategias algorítmicas no debe depender del análisis de sentimiento aislado o rezagado. Por el contrario, el estado del arte debe evolucionar hacia la

implementación de arquitecturas GraphRAG (Retrieval-Augmented Generation apoyado en grafos) y flujos de trabajo agénticos (agentic workflows). La integración de estas topologías de conocimiento en memoria pura permitiría a futuros sistemas de IA razonar y contextualizar en tiempo real el nivel de contagio emocional del mercado, optimizando la toma de decisiones financieras especialmente durante periodos críticos de alta volatilidad.

A pesar de la solidez analítica, este estudio presenta limitaciones inherentes a su diseño experimental computacional. Los resultados están estrictamente condicionados al entorno de pruebas cerrado y a los sesgos del conjunto de datos específico analizado, comprendido entre septiembre de 2021 y septiembre de 2022. Además, la muestra social analizada presenta una marcada predominancia hacia una única empresa (Tesla, con 37,422 interacciones), lo que restringe la capacidad de generalizar estos patrones de contagio emocional a activos menos mediáticos o pertenecientes a otros sectores industriales.

CONCLUSIONES

Se determina que, si bien existe una correspondencia lineal y cuantificable entre el sentimiento social expresado en plataformas de microblogging y las variaciones del rendimiento bursátil, esta relación es de carácter moderado y no resulta estadísticamente significativa para predecir el comportamiento del mercado de forma aislada.

Aunque la influencia emocional sobre los activos financieros no es significativa en el espectro general, la métrica no es estática. Se observa que durante condiciones de estrés y alta volatilidad (superiores al 2.0%), la correspondencia se intensifica, lo que sugiere un mayor acoplamiento temporal entre el pánico o la euforia social y la direccionalidad del mercado bajo escenarios de incertidumbre.

Las bases de datos orientadas a grafos, operando en memoria, constituyen la infraestructura computacional más eficiente para representar y procesar estas relaciones financieras complejas. Esta arquitectura permite superar las limitaciones de latencia del álgebra relacional tabular, facilitando el recorrido ágil de millones de nodos.

En el campo del procesamiento de lenguaje natural aplicado a las finanzas, la implementación de modelos transformer con dimensiones de clasificación ternaria es indispensable. La categoría neutral funciona como un mecanismo de filtrado crítico para aislar el ruido sistémico (información factual) y evitar la sobreestimación algorítmica de las emociones.

La dinámica temporal del contagio emocional en la red exhibe una asimetría estructural, donde el miedo o el pesimismo colectivo demuestran una persistencia temporal considerablemente mayor que el optimismo. A pesar de la inercia temporal del sentimiento negativo en las redes, el mercado descuenta la información emocional de forma altamente eficiente. Al no existir una correlación significativa con variables rezagadas, se concluye que el mercado reacciona predominantemente al estado de ánimo concurrente, anulando la capacidad de arrastre del sentimiento social de días anteriores.

Respecto al alcance y las limitaciones metodológicas, se concluye que los patrones de contagio emocional aquí descritos están intrínsecamente ligados a la muestra evaluada. Dado que el ecosistema analizado presenta un fuerte sesgo hacia el sector tecnológico (liderado por Tesla) y se restringe a una única plataforma (X), la generalización de estos resultados hacia otros sectores empresariales, mercados financieros emergentes o periodos macroeconómicos distintos debe realizarse con cautela, ya que la sensibilidad social varía según la naturaleza del activo.

Finalmente, se identifican amplias oportunidades para investigaciones futuras en la intersección de la IA y las finanzas. Resulta fundamental escalar este marco metodológico hacia un análisis multiactivo que consolide datos de múltiples redes sociales y foros financieros. Asimismo, la incorporación de modelos de lenguaje grande (LLM) de última generación, combinada con técnicas predictivas complementarias sobre

grafos temporales, permitirá transitar del mero análisis descriptivo hacia la predicción causal de la volatilidad del mercado.

REFERENCIAS

- Besta, M., Blach, N., Kubicek, A., Gerstenberger, R., Podstawski, M., Gianinazzi, L., Gajda, J., Lehmann, T., Niewiadomski, H., Nyczyk, P., & Hoeffler, T. (2024). Graph of Thoughts: Solving Elaborate Problems with Large Language Models. *Proceedings of the AAAI Conference on Artificial Intelligence*, 38(16), 10–10. <https://doi.org/10.1609/aaai.v38i16.29720>
- Chauhan, J. K., Ahmed, T., & Sinha, A. (2025). A novel deep learning model for stock market prediction using a sentiment analysis system from authoritative financial website's data. *Connection Science*, 37(1), 2–2. <https://doi.org/10.1080/09540091.2025.2455070>
- Ding, Q., Shi, H., Guo, J., & Liu, B. (2025). *TradExpert: Revolutionizing Trading with Mixture of Expert LLMs*. 4–4. <https://arxiv.org/pdf/2411.00782v1>
- Kahneman, D., & Tversky, A. (1979). *PROSPECT THEORY: AN ANALYSIS OF DECISION UNDER RISK*. 47, 19–20.
- Kaur, G., Haraldsson, · Saemundur, & Bracciali, A. (2025). Comparative analysis of transformer models for sentiment classification of UK CBDC discourse on X. *Discover Analytics 2025 3:1*, 3(1), 13–13. <https://doi.org/10.1007/S44257-025-00035-4>
- Mohammed, O., Jafari, F., & Jain, C. (2025). From News to Knowledge: Leveraging AI and Knowledge Graphs for Real-Time ESG Insights. *Sustainability 2025, Vol. 17, Page 11128*, 2–2. <https://doi.org/10.3390/SU172411128>
- Nasiopoulos, D. K., Roumeliotis, K. I., Sakas, D. P., Toudas, K., & Reklitis, P. (2025). Financial Sentiment Analysis and Classification: A Comparative Study of Fine-Tuned Deep Learning Models. *International Journal of Financial Studies 2025, Vol. 13, Page 75*, 2–2. <https://doi.org/10.3390/IJFS13020075>
- Pan, S., Luo, L., Wang, Y., Chen, C., Wang, J., & Wu, X. (2024). Unifying Large Language Models and Knowledge Graphs: A Roadmap. *IEEE Transactions on Knowledge and Data Engineering*, 11–11. <https://doi.org/10.1109/TKDE.2024.3352100>
- Robinson, Ian., Webber, James., & Eifrem, Emil. (2015). *Graph databases : new opportunities for connected data*. O'Reilly.
- Semary, N. A., Ahmed, W., Amin, K., Pławiak, P., & Hammad, M. (2023). Improving sentiment classification using a RoBERTa-based hybrid model. *Frontiers in Human Neuroscience*, 17, 9–9. <https://doi.org/10.3389/FNHUM.2023.1292010/TEXT>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2023, August 2). *Attention Is All You Need*. <https://arxiv.org/pdf/1706.03762>
- West, A. (2026, March 22). *Grafeo: An Embeddable Graph Database in Rust That Actually Makes Sense - DEV Community*. <https://dev.to/alanwest/grafeo-an-embeddable-graph-database-in-rust-that-actually-makes-sense-1nik>
- Yukhymenko, H. (2023). *Stock Tweets for Sentiment Analysis and Prediction*. <https://www.kaggle.com/datasets/equinxx/stock-tweets-for-sentiment-analysis-and-prediction>