

UNIVERSIDAD NACIONAL JORGE BASADRE GROHMANN

Escuela de Posgrado

MAESTRÍA EN GESTIÓN EMPRESARIAL

**SENTIMIENTO MEDIÁTICO Y RENDIMIENTO DE LA BOLSA
DE VALORES DE LIMA, PERIODO 2019 - 2024**

TESIS

PRESENTADA POR:

TELMA RAQUEL SARA VIA TICONA

Para optar el Grado Académico de:

**MAESTRO EN CIENCIAS (*MAGISTER SCIENTIAE*) CON
MENCIÓN EN GESTIÓN EMPRESARIAL**

**TACNA – PERÚ
2026**

UNIVERSIDAD NACIONAL JORGE BASADRE GROHMANN

Escuela de Posgrado

MAESTRÍA EN GESTIÓN EMPRESARIAL

**SENTIMIENTO MEDIÁTICO Y RENDIMIENTO DE LA
BOLSA DE VALORES DE LIMA,
PERIODO 2019 - 2024**

Tesis sustentada y aprobada el 12 de marzo del 2026; estando el jurado calificador integrado por:


PRESIDENTE


.....
Mgr. Evelyn Priscila Fajardo Espinoza


SECRETARIO


.....
Mgr. Juan Fernando Pérez Pérez

MIEMBRO


.....
Dr. Pedro Pablo Chambi Condori

ASESOR


.....
Dr. Pedro Pablo Chambi Condori

CERTIFICADO DE SIMILITUD

Yo, Pedro Pablo Chambi Condori, en mi condición de ASESOR acreditada con la Resolución de Escuela de Posgrado N° 14645-2024-ESPG/UNJBG del 18 de octubre del 2024, según el informe de tesis: "**SENTIMIENTO MEDIÁTICO Y RENDIMIENTO DE LA BOLSA DE VALORES DE LIMA, PERIODO 2019 -2024**".

Presentado por la Sra. Telma Raquel Saravia Ticona. Para optar por el Grado Académico de Maestro en ciencias (Magister Scientiae) con mención en Gestión Empresarial.

Habiendo cumplido con lo establecido en el reglamento de originalidad y de similitud de trabajos de investigación y producción intelectual de la UNJBG, considerando que según la revisión, evaluación y análisis realizado a través del software de similitud textual TURNITIN, cuenta con el nivel de similitud permitido con un porcentaje de **5%**. Por lo que **CERTIFICO LA SIMILITUD** de la tesis enunciada líneas arriba, cumple con el nivel de permitido, para continuar con los trámites correspondientes y para su publicación en el repositorio Institucional.


Se emite el presente certificado para continuar con los trámites de obtención del Grado Académico.

Tacna, 3 de marzo de 2026

FIRMA ASESOR

Nombres y apellidos: PEDRO PABLO CHAMBI CONDORI

DNI: 00510839



FIRMA AUTOR

Nombres y apellidos: TELMA RAQUEL SARA VIA TICONA

DNI: 71223863



DEDICATORIA

Desde el remoto, arcaico e inexplorado confín del Brazo de Orión, en la Vía Láctea; desde el tercer planeta del Sistema Solar.

A la vida sea terrícola o extraterrestre.

A la voluntad, a la música, a la fortuna, al deporte, y a la salud de curiosos y tesistas que quieran ponerme como referencia.

AGRADECIMIENTOS

A mis padres Telma Ticona y Alberto Saravia, a mis docentes de unidad de Postgrado de la FCJE y a mis docentes de ESCO.

Un agradecimiento a mi asesor de tesis, el Dr. Pedro Pablo Chambi siempre presto, siempre dispuesto para la investigación.

Y obviamente a mí, Telmis, por tanta paciencia ha tomado muchos días terrícolas este trámite más de los necesarios.

Os prometo, espectadores de la Osa Mayor que este tema es muy innovador en mi planeta especialmente por estos instantes del tiempo.

ÍNDICE GENERAL

DEDICATORIA	iv
AGRADECIMIENTOS	v
RESUMEN	xiii
ABSTRACT	xiv
INTRODUCCIÓN	1
CAPÍTULO I: PLANTEAMIENTO DEL PROBLEMA	2
1.1 Descripción de la realidad problemática	2
1.1.1 Problema general	3
1.1.2 Problemas específicos	3
1.2 Antecedentes	3
1.3 Justificación de la investigación.....	4
1.3.1 Justificación teórica	4
1.3.2 Justificación social	5
1.3.3 Justificación metodológica.....	5
1.4 Objetivos	5
1.4.1 Objetivo General	5

1.4.2	Objetivo Específico.....	6
1.5	Hipótesis.....	6
1.5.1	Hipótesis general.....	6
1.5.2	Hipótesis específicas.....	6
1.6	Operacionalización de las variables.....	7
1.7	Limitaciones de la investigación.....	8
1.8	Tipos y nivel de la investigación.....	8
1.8.1	Tipo de la Investigación.....	8
1.8.2	Nivel de la Investigación.....	8
CAPÍTULO II: MARCO TEÓRICO		9
2.1	Antecedentes del estudio.....	9
2.2	Bases teóricas.....	15
2.2.1	Finanzas del comportamiento.....	16
2.2.2	Sentimiento de mercado.....	16
2.2.3	Bolsa de Valores de Lima.....	16
2.2.4	Perfil del inversionista peruano.....	17
2.3	Definición de términos.....	18
2.3.1	Machine Learning.....	18
2.3.2	Procesamiento de lenguaje natural.....	18
2.3.3	Sentiment análisis.....	18

2.3.4	Finanzas del comportamiento	18
2.3.5	Prensa escrita	18
2.3.6	Mercados financieros	19
2.3.7	Sentimiento de los inversores	19
CAPÍTULO III: MARCO METODOLÓGICO		20
3.1	Diseño de la investigación.....	20
3.2	Acciones y actividades para la ejecución del estudio	20
3.3	Población y muestra de estudio.....	21
3.3.1	Población.....	21
3.3.2	Muestra	21
3.4	Materiales y técnicas para la toma de datos	22
3.5	Tratamiento de datos (análisis estadístico).....	22
3.5.1	Modelo Transformers.....	22
3.5.2	BERT	24
3.5.3	Rendimiento de las series de tiempo.....	24
3.5.4	Modelo VAR-X	25
3.5.5	Causalidad de Granger.....	26
3.5.6	Modelo ADCC-GARCH.....	26
CAPÍTULO IV: RESULTADOS		28
4.1	Análisis descriptivo de las variables	28

4.1.1 Sentimiento mediático	28
4.1.2 Rendimiento del IGBLV y principales acciones negociadas.....	38
4.2 Prueba de estacionariedad – ADF	42
4.3 Modelo del Vector AutoRegresivo con variables exógenas – VAR-X.....	45
4.4 Resultados de la prueba de la Causalidad de Granger	47
4.5 Impulso Respuesta en el IGBVL.....	51
4.6 Correlación Dinámica ADCC- GARCH del IGBVL	52
4.7 Contratación de hipótesis	53
4.7.1 Hipótesis Nula General	53
4.7.2 Contrastación de hipótesis específicas.....	53
CAPÍTULO V: DISCUSIÓN, CONCLUSIONES Y RECOMENDACIONES	55
5.1 Discusión.....	55
5.2 Conclusiones	56
5.3 Recomendaciones.....	57
REFERENCIAS BIBLIOGRÁFICAS.....	58
ANEXOS	63
Anexo 1: Matriz de Consistencia	64
Anexo 2: Pruebas de raíz unitaria para los 08 índices más negociados en la IGBVL	65
Anexo 3: Resultados VARX para los 08 índices más negociados en la IGBVL	68

ÍNDICE DE TABLAS

Tabla 1	Cuadro de operacionalización de variables	7
Tabla 2	Distribución del sentimiento de las noticias por año	28
Tabla 3	15 Noticias con mayor 'Sentimiento Positivo'	35
Tabla 4	15 Noticias con mayor 'Sentimiento Negativo'	36
Tabla 5	Estadísticas descriptivas del IGBVL y (08) acciones más negociadas.....	38
Tabla 6	Prueba de estacionariedad ADF - 'Sentimiento mediático'	43
Tabla 7	Prueba de estacionariedad ADF - 'Índice General de la BVL'	44
Tabla 8	Ecuación del modelo VARX- IGBVL	45
Tabla 9	Matriz de Correlación Residual	47
Tabla 10	Causalidad de Granger - IGBVL vs. Sentimiento de las noticias.....	48
Tabla 11	Causalidad de Granger - IGBVL vs. Sentimiento Positivo en las noticias.....	49
Tabla 12	Causalidad de Granger - IGBVL vs. Sentimiento Negativo en las noticias	50
Tabla 13	Dinámica de la correlación ADCC-GARCH.....	52
Tabla 14	Prueba de estacionariedad ADF - 'Alicorp'	65
Tabla 15	Prueba de estacionariedad ADF - 'BAP'	65
Tabla 16	Prueba de estacionariedad ADF - 'BVN'.....	65
Tabla 17	Prueba de estacionariedad ADF - 'CVERDE'	66
Tabla 18	Prueba de estacionariedad ADF - 'Ferreyrc1'	66
Tabla 19	Prueba de estacionariedad ADF - 'IFS'	66
Tabla 20	Prueba de estacionariedad ADF - 'MINSUR'	67
Tabla 21	Prueba de estacionariedad ADF - 'VOLCAN'	67

Tabla 22	Ecuación del modelo VARX- Alicorp.....	68
Tabla 23	Ecuación del modelo VARX - BAP	69
Tabla 24	Ecuación del modelo VARX - BVN.....	70
Tabla 25	Ecuación del modelo VARX - CVERDE	71
Tabla 26	Ecuación del modelo VARX - FERREYC1	72
Tabla 27	Ecuación del modelo VARX - IFS	73
Tabla 28	Ecuación del modelo VARX - MINSUR	74
Tabla 29	Ecuación del modelo VARX - VOLCAN	75

ÍNDICE DE FIGURAS

Figura 1	Arquitectura del modelo de lenguaje Transformer	23
Figura 2	Nube de palabras de las noticias del año 2019.....	29
Figura 3	Nube de palabras de las noticias del año 2020.....	30
Figura 4	Nube de palabras de las noticias del año 2021	31
Figura 5	Nube de palabras de las noticias del año 2022.....	32
Figura 6	Nube de palabras de las noticias del año 2023.....	33
Figura 7	Nube de palabras de las noticias del año 2024.....	34
Figura 8	Promedio del sentimiento de las noticias del 2019 al 2024	37
Figura 9	Índice general de precios de la BVL, 2019 a 2024	39
Figura 10	Precios de las 8 acciones más negociadas en la BVL, 2019 a 2024.....	40
Figura 11	Rendimiento del Índice general de la BVL, 2019 a 2024	41
Figura 12	Rendimientos de las 8 acciones más negociadas en la BVL, 2019 a 2024	42
Figura 13	Función Impulso - Respuesta en el IGBVL	51

RESUMEN

Inspirado en la teoría de las finanzas comportamiento el presente estudio tuvo como objetivo evaluar si el sentimiento mediático derivado del procesamiento de las noticias del Diario Gestión, ejercía influencia sobre el rendimiento del Índice General de la Bolsa de Valores de Lima – IGBVL y ocho de los activos más negociados durante el periodo de análisis desde el año 2019 al 2024; de este modo se construyeron 1507 observaciones de días hábiles por cada serie de tiempo; para polarizar y darle una puntuación al sentimiento mediático se utilizó herramientas de procesamiento del lenguaje natural – PNL, específicamente el modelo BERT; el análisis multivariante del modelo VAR-X para modelar la media y un modelo ADCC-GARCH para modelar la volatilidad y posible correlación asimétrica dinámica, teniendo al sentimiento mediático como componente exógeno; los resultados mostraron que no existe una influencia estadísticamente significativa del sentimiento mediático positivo ni negativo sobre el rendimiento del IGBVL ni sobre las ocho empresas más negociadas dentro de este; el comportamiento del IGBVL es altamente interdependiente, con una memoria de larga duración; las compañías mineras como Buenaventura y Volcán impulsan fuertemente el comportamiento global del índice; por el comportamiento sistémico global del IGBVL y sus activo se sugiere que existe mínimamente un componente estructural subyacente en común, que dicte las dinámicas del rendimiento de los activos del mercado peruano.

Palabras Clave: Finanzas del comportamiento, análisis de sentimientos, noticias, PNL, riesgo sistémico, ADCC-GARCH, Bolsa de Valores de Lima.

ABSTRACT

Inspired by the theory of Behavioral Finance, the present study aimed to evaluate whether media sentiment, derived from processing news from the Diario Gestión newspaper, influenced the return of the Lima Stock Exchange General Index - IGBVL and eight of its most actively traded assets during the analysis period from year 2019 to 2024. A total of 1,507 daily observations were constructed for each time series. Natural Language Processing- NLP tools, specifically the BERT model, were used to polarize and score the media sentiment. The multivariate analysis employed the VAR-X model to model the mean and an ADCC-GARCH model to model the volatility and potential dynamic asymmetric correlation, with media sentiment as the exogenous component. The results showed that there is no statistically significant influence of either positive or negative media sentiment on the return of the IGBVL or its eight most traded companies. The IGBVL's behavior is highly interdependent, exhibiting long-term memory (or long memory). Mining companies such as Buenaventura and Volcán strongly drive the index's overall behavior. Given the global systemic behavior of the IGBVL and its assets, it is suggested that there is at least a common underlying structural component dictating the return dynamics of the Peruvian market assets.

Keywords: Behavioral finance, Sentiment analysis, News, NLP, Systemic risk, ADCC-GARCH, Lima Stock Exchange

INTRODUCCIÓN

La teoría de las finanzas comportamiento sostiene que la emoción y el sentimiento colectivo actúan como variables exógenas que sesgan la formación de precios. En este contexto, el periodo de análisis 2019-2024 en el Perú constituye un escenario único, marcado por la inestabilidad política e institucional evidenciada por el cierre del Congreso y seis cambios presidenciales, lo que generó un ambiente de alta incertidumbre y proliferación de noticias especulativas. Esta turbulencia contrasta con una notable paradoja financiera: a pesar de la crisis política, el sol peruano exhibió periodos de excepcional estabilidad.

La presente investigación nace de la necesidad de capturar y contrastar esta anomalía, preguntando si el mercado peruano actúa con independencia a las narrativas mediáticas que se difunden o si, por el contrario, el sentimiento influye en el comportamiento de sus activos.

Para abordar esta complejidad, el estudio se enfoca en evaluar si el sentimiento mediático, derivado del procesamiento de las noticias del Diario Gestión, un diario peruano de publicación regular, ejerce una influencia estadísticamente significativa sobre el rendimiento del Índice General de la Bolsa de Valores de Lima – IGBVL y sus ocho activos más negociados; para alcanzar estos objetivos nos valimos de herramientas de Procesamiento de Lenguaje Natural y así como de modelos econométricos ya establecidos que nos muestren el comportamiento de la media, la volatilidad y la causalidad.

CAPÍTULO I: PLANTEAMIENTO DEL PROBLEMA

1.1 Descripción de la realidad problemática

El análisis de sentimiento es un tratamiento computacional y una herramienta fundamental del procesamiento de lenguaje natural (PLN), tiene como objetivo principal clasificar la orientación predominante del sentimiento expresado en un texto. Cedeno-Moreno y Vargas-Lombardo, (2020)

En el entorno financiero los medios de comunicación digitales juegan un rol crucial al generar y difundir percepciones que afectan el sentimiento de los inversionistas; es revelador considerar que los mercados de valores no solo se mueven impulsados por factores económicos sino también por factores emocionales como el optimismo o pesimismo sobre contexto en particular.

Este optimismo o pesimismo percibido por los inversionistas puede reflejarse en rendimiento del mercado de valores; estudios internacionales, como los de Wan et al. (2021) y Li et al. (2020), demuestran que el análisis de sentimiento aplicado a noticias financieras permite predecir movimientos en índices bursátiles y volatilidad.

En el contexto financiero el rendimiento es la ganancia o pérdida obtenida de un capital invertido producido por los movimientos de precio de las acciones durante un periodo de tiempo determinado. (Bravo, 2022)

Brasil es el mercado financiero más grande de América Latina, Ferraz, et al., (2023) mencionan que el caso más grande de análisis de sentimiento en noticias y cómo se ha vinculado a su mercado bursatil fueron los titulares negativos sobre el escándalo de Petrobras y el caso Lava Jato comprendido entre los años 2014 – 2019, lo cual explicó una volatilidad del 22% en el índice Ibovespa.

En el contexto peruano, este campo no ha sido explorado de manera sistemática, a pesar de que la Bolsa de Valores de Lima refleja dinámicas económicas únicas, como su exposición a sectores primarios como la minería.

Según Alvarado & Rodriguez, (2024) la incertidumbre financiera producto de las crisis políticas o conflictos sociales reducen la inversión privada en un hasta en un 1.5% en el largo plazo, debido a que las empresas optan por estrategias de espera conocidas como ‘wait-and-see’.

Esta investigación busca determinar si los sentimientos positivos o negativos reflejados en la prensa digital actúan como indicadores o causantes de variaciones significativas en el mercado bursátil, lo que permitiría comprender mejor el proceso de toma de decisiones de los inversionistas y la formación de expectativas en un contexto de mercado emergente.

Expuestos los grupos de interés y su interacción nos planteamos las siguiente interrogantes.

1.1.1 Problema general

- ¿Influye el sentimiento mediático de las noticias en el rendimiento de la Bolsa de Valores de Lima, periodo 2019 – 2024?

1.1.2 Problemas específicos

- ¿Influye el sentimiento positivo de las noticias en el rendimiento de la Bolsa de Valores de Lima, periodo 2019 – 2024
- ¿Influye el sentimiento negativo de las noticias en el rendimiento de la Bolsa de Valores de Lima, periodo 2019 – 2024?

1.2 Antecedentes

Wan, et al. (2021) “Sentiment correlation in financial news networks and associated market movements” [“Correlación de sentimiento en las redes de noticias financieras y movimientos de mercado asociados”] En esta investigación se realizaron técnicas de procesamiento de lenguaje natural (PNL) para analizar cómo se sentían las noticias sobre 87

empresas de diferentes sectores mencionadas en Reuters durante un periodo de 7 años, el objetivo fue averiguar cómo un sentimiento se propaga en redes de empresas relacionadas, cómo afecta al mercado en términos de cambios de precio de acciones y volatilidad.

Los resultados mostraron que en ciertos sectores si los medios muestran un sentimiento fuerte (positivo o negativo) hacia una empresa, esto puede predecir un cambio similar en el sentimiento hacia empresas relacionadas, es decir empresas que están conectadas en una red financiera basada en noticias compartidas.

Aunque la relación encontrada no fue muy fuerte, se halló que cuando el sentimiento de los medios es intenso, puede haber un impacto notable en el rendimiento de las acciones de una empresa y la volatilidad. Es relación resulta más evidente cuando se evalúan empresas individuales, y se nota la relación en menor grado cuando se analizan sectores o grupos de empresas.

1.3 Justificación de la investigación

1.3.1 Justificación teórica

Esta investigación se fundamenta en el marco de la teoría de las finanzas del comportamiento, el sentimiento mediático emerge como un elemento clave el cual puede ampliar o mitigar emociones colectivas, afectando decisiones de compra y venta en el mercado bursátil; los medios de comunicación actúan como canales de transmisión del sentimiento, incidiendo en la volatilidad de mercados; en el caso del Perú, específicamente en el caso de la Bolsa de Valores de Lima, aún no se ha desarrollado un cuerpo teórico que explore esta relación, por ello, esta investigación busca aportar a la construcción de conocimiento en el campo financiero local.

1.3.2 Justificación social

Desde una perspectiva social, esta investigación contribuye al fortalecimiento de la transparencia y el entendimiento del mercado financiero peruano, al analizar cómo el sentimiento expresado en los medios de comunicación puede influir en las decisiones de inversión, se promueve una mayor conciencia sobre el papel que juegan las emociones colectivas en la economía, resulta particularmente importante para los pequeños inversionistas quienes muchas veces actúan guiados por percepciones en lugar de información técnica; los resultados evidenciarían el impacto que tienen las narrativas en el comportamiento de mercado, de modo que se beneficia la sociedad al generar un conocimiento que promueve decisiones económicas más informadas y conscientes.

1.3.3 Justificación metodológica

Esta investigación ocupará herramientas de procesamiento de lenguaje natural y análisis de sentimientos, las cuales son altamente efectivas para la clasificación, interpretación y cuantificación de emociones transmitidas en textos, el uso de esta metodología permite extraer de manera automatizada y objetiva el sentimiento predominante en noticias económicas, para luego correlacionarlo con el rendimiento del mercado bursátil; de este modo este enfoque garantiza un tratamiento riguroso y reproducible de los datos textuales, la integración de estas herramientas de machine Learning con finanzas conductuales, abre nuevas posibilidades para nuevas investigaciones en mercados emergentes.

1.4 Objetivos

1.4.1 Objetivo General

- Analizar cómo influye el sentimiento mediático de las noticias en el rendimiento de la Bolsa de Valores de Lima, periodo 2019 – 2024

1.4.2 Objetivo Específico

- Evaluar la influencia del sentimiento positivo de las noticias en el rendimiento de la Bolsa de Valores de Lima, durante el periodo 2019 – 2024
- Analizar cómo el sentimiento negativo de las noticias afecta el rendimiento de la Bolsa de Valores de Lima, periodo 2019 -2024

1.5 Hipótesis

Se plantean las hipótesis nula y alternativa para cada uno de los objetivos planteados

1.5.1 Hipótesis general

Hipótesis nula general o H_0 :

- No existe una influencia significativa entre el sentimiento mediático de las noticias y el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 - 2024

Hipótesis alternativa general o H_1 :

- Existe una influencia significativa entre el sentimiento mediático de las noticias y el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024

1.5.2 Hipótesis específicas

Hipótesis nula específicas:

- El sentimiento positivo de las noticias no tiene un impacto positivo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024
- El sentimiento negativo de las noticias no tiene un impacto negativo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024

Hipótesis alternativa específicas:

- El sentimiento positivo de las noticias tiene un impacto positivo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024
- El sentimiento negativo de las noticias tiene un impacto negativo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024

1.6 Operacionalización de las variables

Tabla 1

Cuadro de operacionalización de variables

Variable	Dimensión	Indicador	Instrumento	Escala
Variable independiente: Sentimiento mediático	-Popularidad del sentimiento -Intensidad del sentimiento	- Porcentaje de noticias con sentimiento positivo, negativo o neutral - Escala de intensidad del sentimiento de las noticias diarias	Procesamiento de lenguaje Natural, lenguaje de código abierto en Python aplicando la librería BERT	-Escala de porcentaje -Escala de intensidad [-1, +1]
Variable dependiente: Rendimiento bursátil	Variación del índice bursátil	- Rendimiento diario del índice general de la BVL, y de las ocho empresas más negociadas en su plataforma	Análisis de series de tiempo	-Variación porcentual diaria

Nota. Elaboración propia

1.7 Limitaciones de la investigación

Una limitación es la potencial influencia de los factores no evaluados a lo largo del tiempo como factores externos no controlados, como cambios en políticas nacionales, desastres económicos o sociales, lo que puede distorsionar los resultados; la disposición de los datos históricos sobre el sentimiento mediático puede afectar la precisión de las conclusiones; además hay que considerar que el procesamiento de lenguaje natural puede presentar algunas dificultades para captar matices culturales, o lingüísticos específicos de Perú.

1.8 Tipos y nivel de la investigación

1.8.1 Tipo de la Investigación

Aplicada, ya que no se propone ninguna nueva metodología, se sirve de métodos estadísticos ya probados, y se caracteriza por la aplicación, y utilización de los conocimientos; busca aprender para hacer, para tomar acción, para crear, para transformar.

1.8.2 Nivel de la Investigación

Explicativo, desde de la observación, pues tiene como objetivo el entendimiento de un fenómeno enfocándose en las causas físicas o sociales.

CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes del estudio

Mino & Williamson, (2025) “Sentimiento y Volatilidad en los mercados financieros: Una revisión de las aplicaciones BERT y GARCH durante crisis geopolíticas”, se propusieron investigar la relación entre el sentimiento (positivo, negativo o neutral) de las noticias sobre la guerra Rusia-Ucrania en los medios estadounidenses y la volatilidad del mercado de valores; para ello analizó 10 000 titulares de noticias de entre enero y julio de 2024, el sentimiento fue analizado con el modelo de lenguaje avanzado BERT, y la volatilidad de S&P 500 se modeló económicamente con el modelo GARCH con una distribución Student-t; las conclusiones muestran una relación negativa y significativa estadísticamente entre el sentimiento negativo de las noticias y la estabilidad del mercado ; lo que sugiere que un aumento en la cobertura periodística pesimista esta asociada a un aumento de la volatilidad en el S&P 500 durante las crisis geopolíticas, se destaca la utilidad de integrar el modelo BERT para el analisis de riesgo.

Wen et al. (2024) “Predicción de precios de acciones con FinBERT- LSTM: Integración del análisis de sentimiento de las noticias”, proponen un modelo híbrido llamado Fin-BERT-LSTM, que combina el análisis de sentimientos de las noticias financieras con datos históricos de precios de acciones para predecir los movimientos del mercado bursátil, el modelo de lenguaje pre-entrenado FinBERT, lo integran con una red neuronal de memoria a corto y largo plazo (LSTM) para capturar patrones temporales en los datos; se tomaron datos del índice NASDAQ-100 y noticias del Benzinga, las métricas de evaluación fueron el Error Absoluto medio y el Error Porcentual Absoluto Medio; los resultados muestran que el modelo pre-entrenado es mejor que modelos con otros enfoques como el LSTM y las redes neuronales profundas en cuanto a precisión predictiva, destacando la importancia de

incorporar el análisis de sentimientos de noticias financieras para mejorar la predicción de precios de acciones, especialmente en mercados altamente volátiles.

De Oliveira, (2024) “ Predicción del mercado de valores Brasileño mediante análisis de sentimiento, indicadores técnicos y precios de acciones: Un enfoque de aprendizaje profundo” Proponen combinar el análisis de sentimiento y el análisis de los precios históricos ambas con herramientas de Deep Learning, lo que ha llevado a resultados vanguardistas en tareas de clasificación y regresión; el objetivo fue predecir el mercado de valores brasileiro combinado al uso de precios históricos de acciones, indicadores técnicos financieros y noticias financieras, considerando datos desde el 2010 al 2019, tomando el índice Bovespa, y cuatro empresas brasileñas como Banco do Brasil, Itaú, Gerdau y Ambev, las cuales contribuyen significativamente al índice Ibovespa, para la predicción del precio de mercado exploraron arquitecturas como Perceptrón multicapa - MLP, Memoria a largo plazo - LSTM y Memoria a largo plazo bidireccional Bi- LSTM y para el análisis de sentimientos una red neuronal convolucional; los resultados indican que la integración de precios de acciones, indicadores técnicos y noticias optimiza la predicción del mercado de valores, tomando en cuenta tanto el margen de error en las proyecciones como el rendimiento de la inversión.

Chatziloizos, G. et al., (2024) “ Aprendizaje profundo para la predicción del mercado de valores mediante el sentimiento y el análisis técnico” Investigadores de los campos de economía e informática aplicaron herramientas de aprendizaje automático y profundo para predecir las tendencias de los precios de las acciones; por lo que usaron datos numéricos, económicos tanto como textuales y sentimentales, se buscaba comprender cómo el análisis técnico de una acción podía fortalecerse mediante el uso del análisis de sentimiento; por ello recopilaban datos históricos financieros de cuatro tickets AAPL, GOOG, NVDA y el índice S&P 500 Information Technology además 10 tweets por día referidos a cada ticket, desde el 1 de enero de 2012 al 31 de diciembre del 2019 recopilando un total de 29 000 tweets; para el análisis léxico utilizaron el método Lexicon, compilando el promedio de tres técnicas VADER, Loughra- McDonald y léxico genérico para promediar los sentimientos de los tweets, el primer resultado del estudio muestra la rentabilidad comparativa que tiene el modelo LSTM sobre las Redes Neuronales Convolucionales, sin embargo sugieren que se

debe enriquecer la muestra con empresa de diferentes tamaños y sectores para establecer una declaración final del análisis de sentimientos para anteceder tendencias de mercado.

Swathi. T et al. (2022) “Un LSTM óptimo basado en aprendizaje profundo para la predicción del precio de las acciones mediante el análisis del sentimiento de Twitter” este estudio se centró en predecir el precio de las acciones, influenciada por factores económicos, sociales y políticos; los autores parten de la premisa que en el mercado actual, las opiniones positivas o negativas son claves para determinar el precio de las acciones; no se puede dejar de lado el crecimiento de las redes sociales donde la gente comparte sus opiniones sobre lo que creen sucederá con el futuro de las acciones, por ello utilizan este tipo de opiniones específicamente de Twitter para predecir el precio de las acciones; desarrollaron un modelo que combina una método de optimización llamado TLBO – optimización basada en la enseñanza y el aprendizaje- con una técnica llamada LSTM – memoria a largo y corto plazo – que se utilizó para analizar los sentimientos de los tweets en positivos o negativos para ver cómo se relacionan con los precios de las acciones; para mejorar la precisión del modelo utilización el optimizador Adam; los resultados mostraron que el modelo es muy efectivo alcanzando una precisión del 95,33%.

Yasir, et al.2024 “Modelo de predicción de precios de acciones mediante gráficos temporales y análisis de sentimientos de mercado”, Indonesia, en su investigación desarrollaron un modelo para predecir el precio de las acciones combinando la teoría de grafos temporales con el análisis de sentimientos del mercado, apoyados del modelo de memoria a corto plazo; la teoría de grafos (estructura de los gráficos, nodos y aristas) ayuda a identificar patrones y tendencias que pueden no ser visibles en el análisis de datos lineal tradicional; como datos de entrada se emplearon datos históricos de los precios de las acciones y el volumen de sus operaciones de los últimos 30 días, junto al sentimiento expresado en redes especialmente de la API de Twitter de noticias financieras ; los resultados de la evaluación indicaron que el modelo LSTM optimizado tiene buenas capacidades de generalización, reflejados en valores bajos de MAE – Error absoluto medio y RMSE- Error cuadrático medio, la optimización de hiperparámetros mejoró con éxito la precisión y eficiencia del modelo en la predicción del precio de las acciones; el enfoque ofreció una

comprensión más profunda y una mayor adaptabilidad a los cambios del mercado en comparación con los métodos de predicción tradicionales.

Bin & Wohar, (2023) en su estudio "Respuestas heterogéneas de los mercados bursátiles a las noticias y los sentimientos relacionados con la COVID-19: Evidencia del primer año de pandemia", investigan el impacto de las noticias y sentimientos relacionados con el COVID-19 en los rendimientos del mercado bursátil del Reino Unido durante el primer año de la pandemia abarcado desde febrero de 2020 a diciembre del mismo año; se utilizaron datos diarios de los caso de COVID-19 y muerte por COVID-19, junto con índices de sentimiento derivados de las noticias y búsquedas de Google, para analizar como estas variables afectaban el índice FTSE 100; los resultados mostraron que el aumento en los casos diarios de COVID-19 tuvo un efecto negativo significativo en los rendimientos del mercado, mientras que el aumento en las muertes diarias tuvo un efecto positivo, posiblemente debido a las expectativas de políticas monetarias expansivas, el estudio resalta que la cobertura mediática y los sentimientos negativos como pánico y noticias falsas influyeron en la volatilidad del mercado; agregan que las respuestas del mercado bursátil a las noticias relacionadas con la pandemia son heterogéneas y dependen del contexto temporal, como la fase inicial de la pandemia versus la fase de recuperación.

Costola et al., (2023) "Análisis de sentimiento mediante aprendizaje automático, noticias sobre COVID-19 y reacciones del mercado de valores", analizaron el impacto de las noticias sobre el COVID-19 en el principal índice bursátil de Estados Unidos, el S&P 500, durante los primeros seis meses de la pandemia, de enero a junio de 2020, para ello procesaron 203 886 artículos de MarketWatch, NYTimes y Reuters utilizando el modelo FinBERT, un modelo BERT adaptado a finanzas, para extraer los sentimientos en las noticias como positivos, negativos o neutrales, además analizaron la varianza del sentimiento y el volumen de las noticias afectan los retornos, la volatilidad y el volumen de operaciones en el S&P 500; el estudio demostró que un sentimiento positivo tuvo una correlación con las alzas en el S&P 500, mientras que sentimientos negativos o de incertidumbre mostró una relación negativa, adicionalmente las noticias negativas de NYTimes aumentaron la volatilidad y el volumen de estos artículos amplificó el efecto; identificaron que las noticias

más influyentes fueron las noticias relacionadas a negocios y a ciencia mientras que las demás no tuvieron mayor relevancia estadística.

Zhang, et al .(2023) “Optimización del análisis del sentimiento financiero con modelos de lenguaje grande y recuperación aumentada” en este estudio identificaron dos limitaciones en los enfoques tradicionales en el análisis de sentimientos, a discrepancia entre el objetivo de preentrenamiento de los LLMs y la predicción de sentimientos financieros, y la falta de contexto de los textos breves como titulares o tuits, para ello se combinó un módulo de LLMs ajustado por instrucciones como un componente de recuperación -RAG- el cual extrae información relevante de fuentes como Bloomberg, Reuters y Twitter; los resultados mostraron una mejora de 15% a 48% en precisión de análisis, destacando que la incorporación del contexto externo permite clasificar correctamente sentimientos ambiguos, el autores resaltan que esta metodología resulta especialmente útil para noticias financieras concisas, donde el contexto externo hay que interpretarlo con matices.

Li et al. , (2020) “Incorporación de los precios de las acciones y las noticias para la predicción del mercado de valores: Un caso de Hong Kong” Dado que existe el desafío de combinar la manera efectiva de indicadores técnicos de los precios de las acciones con la percepción derivada de los artículos de las noticias textuales, y cómo hacer que un modelo fuera capaz de aprender información secuencial dentro de series de tiempo de manera inteligente; por lo que se propusieron un enfoque que representaba los datos numéricos de precios utilizando indicadores técnicos del análisis técnico, y los artículos de noticias textuales mediante vectores de sentimiento a través del análisis de sentimientos, para ello experimentaron con datos de cinco años de la bolsa de valores de Hong Kong, utilizando cuatro diccionarios de sentimientos diferentes, los resultados muestran que este enfoque supera las líneas base tanto en la validación de datos, como en las pruebas y evaluaciones diferentes, los modelos que incorporan sentimientos y precios superaron a los modelos que utilizaban indicadores solo técnicos o de noticias; entre los cuatro diccionarios que se utilizaron el diccionario específico de dominio financiero Loughran-McDonald mostro modelos mejor los sentimientos de las noticias, aportando una mejora de predicción como máximo de 120% .

Groß-Klußmann, (2024) Analizó el sentimiento de las noticias en la predicción del crecimiento del producto bruto interno, los rendimientos de diferentes activos y la inversión basada en series de tiempo temporales, para ello recuperaron desde Bloomberg el retorno de los índices bursátiles y de los futuros como son el índice ASX, el índice TSE60, el índice Hang Seng, el Eurostoxx 50, el TOPIX, el FTSE100, y el S&P500, así como el rendimiento de los bonos de 10 años con tipo de interés cero y los retornos de bonos a 10 años para el resto de la regiones de estudio a excepción de China, también recuperaron el retorno de las divisas como son los cruces AUD/USD, CAD/USD, EUR/ USD, JPY/USD y GBP/USD; en cuanto a las noticias utilizadas trabajaron con noticias financieras de Ravenpack y noticias generales de GDELT que centra sus noticias principalmente en política, los resultados revelan que las representaciones de datos no lineales generadas mediante arquitecturas de autocodificadores supervisados son superiores en comparación con otras alternativas en todas las aplicaciones evaluadas; en particular, demostramos que al complementar los autocodificadores con tareas de supervisión fundamentadas en los retornos de clases de activos comunes y en características del mercado, se optimiza la reducción dimensional y se favorece la claridad de las representaciones obtenidas, estos resultados posicionan a los autocodificadores supervisados como modelos altamente competitivos frente a enfoques como el Análisis de Componentes Principales (PCA) y la Regresión de Mínimos Cuadrados Parciales (PLS).

En el campo peruano Alanya (2023), presenta un artículo donde analiza el sentimiento de las noticias económicas del Perú sobre las expectativas de los agentes económicos, recopilando información del departamento de prensa del Banco Central de Reserva del Perú desde inicios del 2016 , utiliza la librería de R *sentimetrics* donde analiza las palabras utilizadas en las noticias con tres diferentes diccionarios o lexicons , sus resultados muestran que el indicador de alta frecuencia de noticias económicas facilita el monitoreo en tiempo real de las tendencias en las expectativas de los agentes económicos, al mostrar una elevada correlación contemporánea y servir como un predictor adelantado de diversas series de expectativas del Banco Central de Reserva del Perú (BCRP) sugiere este indicador refleja distintos episodios relevantes en la economía peruana durante los años de la pandemia tanto en consumo, inversión y empleo.

2.2 Bases teóricas

En 1965, el premio Nobel de Economía Eugene Fama empieza su hipótesis de mercado eficiente o HME, considerando que un mercado es eficiente cuando los precios de los activos financieros incorporan de manera completa toda la información disponible, estableciendo un nexo entre información y precio, Angela Pérez, (2018) de España lo explica del modo siguiente; suponiendo por ejemplo, que una acción de la empresa A se cotiza actualmente en el mercado a 10€, ahora imagine que usted tiene conocimiento de un evento que ocurrirá mañana, lo cual hará que el valor de la acción aumente un 20%, alcanzando los 12€; con este conocimiento, su intención sería adquirir hoy la acción a un precio inferior a 12€, con el propósito de venderla mañana y obtener una ganancia. Sin embargo, al intentar realizar la compra, descubre que los demás inversores en el mercado también están al tanto de este acontecimiento futuro, por lo que nadie está dispuesto a vender la acción por un precio inferior a 12€. En consecuencia, el único precio al que este activo se podría intercambiar hoy es de 12€, lo que indica que el precio de la acción de A refleja toda la información disponible en el mercado.

Respecto el mercado peruano Espino, (2022) examinó si el índice General de la Bolsa de Valores de Lima sigue una trayectoria similar a la de un proceso de caminata aleatoria, los resultados obtenidos muestran que este comportamiento no se muestra en datos con frecuencia diaria, semanal y mensual, pero se puede evidenciar cuando se trabaja con datos de frecuencia trimestral, concluyendo que la Hipótesis de Mercado Eficiente en su versión débil no se verifica en el contexto del mercado peruano.

Para predecir las tendencias de mercado se utilizan clásicamente dos estrategias análisis fundamental que basa sus decisiones en condiciones macroeconómicas y financieras; y el análisis técnico que basa sus decisiones en precios pasados de las acciones.

De Oliveira, et al. (2024) Debido al avance de la ciencia de datos el análisis financiero ahora se sirve también de la tecnología y de las grandes cantidades de información de

información no estructurada que ofrece la web, y los diferentes blogs para las decisiones de los inversores.

2.2.1 Finanzas del comportamiento

Las finanzas tradicionales suponen que los seres humanos es decir inversionistas toman sus decisiones basadas en la información y con la racionalidad debida para maximizar sus utilidades; sin embargo, una rama de las finanzas llamada finanzas conductuales plantea que los inversionistas con humanos y que sus decisiones son solo parcialmente racionales y muchas veces son las emociones las impulsadoras de las decisiones.

Las finanzas conductuales exploran las razones que hacen que un inversionista haga una elección o no con respecto a la información que tiene.

En la historia del mercado de valores, un periodo de excepcional sentimiento por inversionistas se dio a finales de la década de 1990 con el precio de las acciones tecnológicas especulativas y de difícil cálculo.

La pregunta ya no es si el sentimiento afecta los precios de las acciones, sino cómo medir el sentimiento.

2.2.2 Sentimiento de mercado

Harry Markowitz señala en su teoría del portafolio, 1959, que no se puede dar por hecho que los inversores siempre actúen de acuerdo con expectativas racionales.

Arrona, (2020) La mayoría de las definiciones se originan en la psicología cognitiva, que investiga cómo los sesgos conductuales influyen en el proceso de toma de decisiones. Esto puede llevar a que, en determinadas situaciones, el sentimiento del inversor altere el precio de un activo en el mercado; por tanto, un cambio en el sentimiento es importante para explicar excesos de ganancia y su condición de volatilidad

2.2.3 Bolsa de Valores de Lima

La Bolsa de Valores de Lima remonta sus orígenes en la Bolsa de Comercio de Lima en el año 1861, desde allí se caracteriza por la implementación de diferentes instrumentos tecnológicos y operativos.

Según portal institucional los productos y servicios que ofrece Bolsa de Valores de Lima S.A. son:

- Negociación de acciones y valores representativos de acciones
- Negociación de valores extranjeros
- Negociación de instrumentos de deuda pública y corporativa
- Operaciones de reporte
- Préstamo bursátil de valores
- Segmento de capital de riesgo para mineras junior.

Adicionalmente al mercado regular, Bolsa de Valores de Lima S.A. ofrece el Mercado Alternativo de Valores, un segmento para medianas empresas con facturación de hasta 350 millones de soles, con menores requisitos y obligaciones.

Arias, sobre el índice de la Bolsa de Valores de Lima expresa (2014, p.72) :“El índice General. Este índice está compuesto por las empresas más significativas para la BVL Y el criterio para elegir estas empresas está basado en la frecuencia de las operaciones de sus acciones, el número de operaciones y los montos negociados”

2.2.4 Perfil del inversionista peruano

Adriana Cuellar (2022), country manager de Libertex Perú, afirma que el inversor particular peruano actual tiene un perfil conservador en cuanto a inversiones en renta variable a largo plazo. Este grupo, compuesto en un 90% por hombres de entre 28 y 45 años, valora altamente la tecnología y la conectividad; la mayoría de estos inversores residen en las principales ciudades de Perú, ya que estas ofrecen la infraestructura necesaria para estar conectados y acceder a internet, un recurso esencial para ellos.

2.3 Definición de términos

2.3.1 *Machine Learning*

O aprendizaje automático es el estudio de herramientas y métodos para identificar patrones en los datos es fundamental en el campo de la ciencia de datos; estos patrones permiten no solo profundizar en la comprensión de fenómenos presentes en el entorno, sino también realizar predicciones sobre eventos futuros. El aprendizaje automático (ML, por sus siglas en inglés) se sustenta en conceptos provenientes de diversas disciplinas, como la informática, la estadística y la optimización. Rego-Rodriguez, et al. (2022)

2.3.2 *Procesamiento de lenguaje natural*

El campo de estudio que se centra en comprender el funcionamiento del lenguaje, su estructura y la generación de nuevo contenido lingüístico abarca una amplia gama de tareas relacionadas con el procesamiento del lenguaje. Entre estas tareas se incluyen la creación de textos nuevos, la traducción de idiomas, la generación de preguntas y respuestas, la elaboración de resúmenes y el desarrollo de chatbots, entre otros. Beltrán y Rodriguez, (2020)

2.3.3 *Sentiment análisis*

Análisis de sentimiento, también conocido como análisis de opinión o minería de opiniones se refiere a procesar computacionalmente datos no estructurados con el objetivo principal de extraer opiniones e identificar sus estados de ánimo; es decir a derivar los sentimientos comunicados en un fragmento de texto. Wankhade, et al. (2022)

2.3.4 *Finanzas del comportamiento*

Las finanzas del comportamiento buscan explicar y ampliar la comprensión sobre los patrones de razonamiento de los inversionistas, prestando especial atención a los procesos emocionales que intervienen y al impacto que estos tienen en la toma de decisiones financieras. Cano y Cardoso, (2015)

2.3.5 *Prensa escrita*

Se refiere a publicaciones escritas emitidas por plataformas tradicionales o digitales, con cierta regularidad, puede ser diaria, semanal, mensual o similar.

2.3.6 *Mercados financieros*

Se trata de mercados estructurados en los que se negocian la compra y venta de acciones, así como de otros tipos de activos financieros; es decir pone en contacto por un lado empresas que quieren financiación y por otro lado organizaciones o individuos que buscan rendimiento de su capital. Banco Santander, (2022)

2.3.7 *Sentimiento de los inversores*

Refleja el estado de ánimo colectivo y la percepción de los inversores respecto a un valor o mercado específico, influyendo directamente en las decisiones de compra y venta de determinados activos financieros; un sentimiento positivo suele generar condiciones de mercado alcistas, donde los inversores se muestran optimistas y más inclinados a asumir riesgos. En contraste, un sentimiento negativo puede provocar mercados bajistas, dado que el miedo y la incertidumbre impulsan a los inversores a adoptar posturas más conservadoras. FasterCapital, (2024)

CAPÍTULO III: MARCO METODOLÓGICO

3.1 Diseño de la investigación

Diseño no experimental, esto quiere decir que no existe manipulación deliberada de las variables a interpretar; por ende, examinan los fenómenos o acontecimientos en su contexto natural, tal como ocurren, para posteriormente proceder a su análisis.

3.2 Acciones y actividades para la ejecución del estudio

Se analizó el repositorio histórico del diario Gestión de Perú, el cual es un diario enfocado a temas de economía y negocios a nivel nacional, se identifica los principales titulares de las noticias diarias desde el primero de enero del 2019 al 31 de diciembre de 2024, tomando las noticias de los días de la semana hábiles es decir de lunes a viernes, lo que engloba un total aproximado de 58 800 titulares relevantes durante el periodo de tiempo, posteriormente, la información fue exportada al entorno de Google Colab, en el entorno de Python para ser analizado por herramientas PNL es decir herramientas de procesamiento de lenguaje natural, esto con la finalidad de analizar los sentimientos en el contexto de las noticias, identificar, ideas, palabras y polarizarlas en valores numéricos de entre -1 y +1 siendo, asociándose un sentimiento negativo mientras el valor obtenido sea cercano a -1 y más positivo mientras el valor sea próximo a +1, de modo analizar el cambio de sentimiento en términos cuantitativos a lo largo del periodo de estudio.

Para obtener el rendimiento de la Bolsa de Valores de Lima y sus principales indicadores, obtenemos la información de la página Investing.com, plataforma web donde se consolidan los datos referidos al índice general de la bolsa de valores de Lima - IGBVL, y el de las ocho empresas más negociadas como son Alicorp, Credicorp,

Compañía de minas Buenaventura, Sociedad minera Cerro Verde, Ferreycorp, Intercorp Financial Services, Minsur, y Volcan compañía minera.

Los datos consolidados en un documento Excel fueron procesados en Python haciendo uso de la metodología Sentimental Analysis.

3.3 Población y muestra de estudio

3.3.1 Población

El Índice General de la Bolsa de Valores de Lima (IGBVL), el cual refleja el comportamiento agregado de las principales acciones que se negocian en el mercado bursátil peruano. Este índice se considera un indicador del rendimiento general del mercado de valores en el Perú, capturando las variaciones en los precios de las acciones de las empresas que cotizan en la Bolsa de Valores de Lima.

Por el lado de las noticias tenemos un total de 54 683 titulares de noticias obtenidas desde la página web del diario nacional Gestión desde el 01 de enero de 2019 al 31 de diciembre de 2024.

3.3.2 Muestra

- Rendimiento diario del Índice General de la BVL durante el período 2019-2024.
- El rendimiento diario del índice de Alicorp - ALICORP, Credicorp - BAP, Compañía de minas Buenaventura - BVN, Sociedad minera Cerro Verde - CVERDE, Ferreycorp – FERREYC1, Intercorp Financial Services - IFS, Minsur - MINSUR, y Volcan compañía minera – VOLCAN, durante el período 2019-2024
- Promedio del sentimiento de las noticias diarias de lunes a viernes, durante el período 2019-2024

Haciendo un total de 1507 observaciones por cada de las 10 series de tiempo armadas.

3.4 Materiales y técnicas para la toma de datos

Para obtener las noticias publicadas por el diario peruano Gestión, durante el periodo de estudio, se utilizó la técnica del Web Scraping utilizando el lenguaje de Python en el entorno de Google Colaborate, esta información se consolidó en un documento Excel para su organización.

La elaboración de nubes de palabras fue elaborada en el lenguaje de Python en el entorno de Google Colaborate aprovechando su GPU disponible.

Para el análisis de sentimiento se utilizó el mismo entorno de Python de Google Colaborate potenciado por la librería BERT - *Bidirectional Encoder Representations from Transformers*.

Para los estadísticos general, la prueba de raíz unitaria y la causalidad de Granger se utilizó E-Views, para aprovechar la practicidad y formato de salida del software.

Los modelos econométricos como el VAR-X y el ADCC-GARCH, así como los gráficos de las series de tiempo fueron ejecutados en R, entorno local, para aprovechar la practicidad y formatos de salida organizados del software.

Para la elaboración de los gráficos complementarios de la IRF – Función Impulso Respuesta, se utilizó Python en el entorno de Google Colaborate.

3.5 Tratamiento de datos (análisis estadístico)

3.5.1 *Modelo Transformers*

Un modelo Transformer es una red neuronal que aprende según el contexto, y detecta formas sutiles en que los elementos de una serie influyen o dependen entre si, presentados por primera vez en 2017 por un grupo de investigadores de Google en el artículo “Atención es todo lo que necesitas” liderado por Ashish Vaswani; aunque los modelos antecedentes a Transformers son capaces de representar palabras en vectores, estos vectores no contenían el contexto, y en el lenguaje natural se sabe que el significado de una misma palabra puede cambiar dependiendo del contexto.


Un “Transformer” bautizado así por Jakob Uszkoreit , es un modelo codificador – decodificador, ponen sobre la mesa dos innovaciones.

Codificación posicional; esto quiere decir que en lugar de procesar directamente las palabras según aparecen, se les asigna un valor único según su posición, generándose tokens, lo que ayuda al modelo a entender el contexto y comprender mejor su significado en relación a las otras palabras.

Autoatención; es un mecanismo aprendido conforme se entrena el modelo con una gran cantidad de datos, esto permite que los modelos predigan y aprendan la importancia y la secuencia de cada palabra según las probabilidades estadísticas conforme al uso natural en el lenguaje.

Figura 1

Arquitectura del modelo de lenguaje Transformer



Nota. Tomado del artículo ‘Attention is all you need’ de Vaswani et al., (2017)

En la arquitectura propuesta podemos ver dos componentes principales Encoders y Decoders, en la figura original el encoder está compuesto por $N=6$ layers, es decir 6 capas idénticas cada capa dividida en dos sub capas la primera es el mecanismo de autoatención multicabezas, y la segunda es la red de alimentación directa, adicionalmente la salida de la subcapa no es simplemente el resultado de esta sino que se suma la entrada original expresado en LayerNorm ($x + \text{Sublayer}(x)$), esto ayuda a mejorar el rendimiento y la estabilidad del modelo.

El decoder de igual modo este compuesto por $N=6$ layers, pero en adición cuenta con un tercera sub capa un llamado de autoatención multicabezas con un enmascaramiento especial, lo que impide que una posición vea palabra que vienen después de la secuencia, lo que permite que las predicciones estén basadas en palabras generadas solo previamente.

Hay muchos modelos preentrenados basados en la tecnología transformers, BART utiliza el componente encoder & decoder, BERT utiliza solo el encoder y GPT-2, GPT-3 utilizan solo el decoder.

3.5.2 BERT

BERT es uno de los modelos Transformer entrenados significa Bidirectional Encoder Representations from Transformers, desarrollado por Google en 2018, BERT se entrenó en dos variaciones, un modelo contiene el modelo base con una pila de 12 transformadores, con alrededor de 110 millones de parámetros y BERT Large tiene 24 capas de transformadores con aproximadamente 340 millones de parámetros, fueron entrenados con datos de Wikipedia y Google Books, BERT se entrenó en diferentes tareas, lo que significa que tiene un objetivo de tareas múltiples.

3.5.3 Rendimiento de las series de tiempo

El análisis de sentimiento de las noticias se llevó a cabo de manera diaria, generando un valor promedio de la polaridad y subjetividad para cada día, posteriormente, los datos agregados se transformarán en una serie de tiempo con la misma frecuencia que los datos de rendimiento de la Bolsa de Valores de Lima.

Obtenido los precios que cotizan para las ocho empresas más negociadas en la Bolsa de Valores de Lima

Para el cálculo del rendimiento de las ocho empresas más negociadas en la Bolsa de Valores de Lima, así como su índice se obtienen los valores naturales y después se aplica la siguiente fórmula.

$$Rendimiento = \ln \left(\frac{Valor\ futuro}{Valor\ presente} \right)$$

Con todos los datos organizados se realizó un análisis de correlación con el fin de caracterizar las relaciones entre las series de tiempo.

3.5.4 *Modelo VAR-X*

Los modelos de vector autoregresivos – VAR propuestos por Sims en 1980, generalmente parten del supuesto de que todas las variables estocásticas tienen el mismo estatus, siendo determinadas dentro del sistema (endógenas). Sin embargo, en el presente estudio se introduce una variación al incorporar el ‘Sentimiento de las noticias’ (X_t); esta variable se considera determinada fuera del sistema de interés, siendo clasificada como ‘variable exógena’ o ‘variable no modelada’.

Un ejemplo de variable exógenas incluye factores externos no modelables por el sistema económico local, como variables climáticas o en el contexto de una economía pequeña y abierta, el nivel de precios o el PBI global.

Al considerar el ‘Sentimiento mediático’ como exógeno, se asume que, aunque puede afectar la dinámica de los retornos de las acciones (Y_t), no es a su vez significativamente explicado por ello en el corto plazo; esta aproximación requiere el uso de un modelo que permita la inclusión de variables no modeladas, formalmente conocido en su forma como un Sistema de Ecuaciones Simultáneas Dinámicas o VAR-X:

$$Ay_t = A_1^* y_{t-1} + \dots + A_p^* y_{t-p} + B_0^* x_t + B_1^* x_{t-1} + \dots + B_s^* x_{t-s} + w_t$$

Donde y_t es el vector de variables endógenas, x_t es el vector de variables exógenas, w_t es el vector de error; A representa la matriz de relaciones instantáneas, A_i^* matrices de coeficientes endógenos retrasados, B_j^* matrices de coeficientes exógenos retrasados.

3.5.5 Causalidad de Granger

Que, dos series de tiempo muestren correlación no necesariamente indican “causalidad” es decir capacidad de predicción de una sobre otra, es por ellos que en 1969 Jhon Granger introdujo el algoritmo de causalidad en el sentido de Granger un método inicialmente utilizado en econometría que ha encontrado uso en diferentes disciplinas.

López, (2022), consideremos entonces la serie temporal Y_t , predecir el valor basandonos en sus propios valores seria:

$$Y_t = \alpha_0 + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \epsilon_t$$

Donde p es el número de rezagos considerados y ϵ_t es el término de error

Para evaluar si X_t causa en el sentido de Granger Y_t se introduce la serie temporal X_t en el modelo junto con los rezagos de Y_t :

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \dots + \beta_p Y_{t-p} + \gamma_1 X_{t-1} + \dots + \gamma_q X_{t-q} + \epsilon_t$$

Donde si los coeficientes $\gamma_1, \gamma_2, \dots, \gamma_q$ son significativamente diferentes de cero, entonces se dice que X_t causa en el sentido de Granger a Y_t , es decir que la información contenida en X_t es útil para predecir Y_t .

3.5.6 Modelo ADCC-GARCH

Para analizar la dinámica de la volatilidad entre los activos financieros y el ‘Sentimiento de las noticias’ se seleccionó el modelo ADCC-GARCH – Asymmetric Dynamic Conditional Correlation GARCH) para capturar la volatilidad cambiante, la

correlación dinámica (la interdependencia entre las acciones que cambia con el tiempo) y los efectos asimétricos (la reacción de la volatilidad y la correlación ante las noticias positivas y la diferencia a las noticias negativas).

La estructura general del modelo se define a través de la matriz de covarianzas condicionales Σ_t

$$\Sigma_t = D_t R_t D_t$$

Donde D_t son los componentes de la desviación estándar condicional y R_t la correlación condicional; existe una matriz de cuasi - correlaciones subyacentes, Q_t la cual no aparece directamente en la fórmula de la varianza (Σ_t), pero que es fundamental para complementar el modelo de la asimetría en el modelo ADCC-GARCH, siendo R_t la matriz de correlaciones condicionales explicamos:

$$R_t = \text{diag}(Q_t)^{-\frac{1}{2}} Q_t \text{diag}(Q_t)^{-\frac{1}{2}}$$

Q_t es el término que contiene los productos cruzados de las innovaciones estandarizadas para efectos simétricos y asimétricos

CAPÍTULO IV: RESULTADOS

4.1 Análisis descriptivo de las variables

4.1.1 Sentimiento mediático

Durante los 6 años de análisis se han analizado 54 677 titulares de noticias detallados como describe la Tabla 2

Tabla 2

Distribución del sentimiento de las noticias por año

Sentimiento de la noticia	Año					
	2019	2020	2021	2022	2023	2024
Positivas	743	470	531	485	757	863
Negativas	2458	2726	2397	2532	2144	1740
Neutras	5906	5954	6197	6058	6174	6547
Total	9107	9150	9125	9075	9075	9150

Nota. Elaboración propia

Se observa en la Tabla 2 que en la mayor carga de noticias obtuvieron polaridad neutra, y que la predominancia de las noticias son ‘Negativas’ y la menor cantidad de noticias durante el periodo de análisis es ‘Positivas’, se observa que es durante el año 2020 que se presenta el menor número de noticias ‘Positivas’ con 470 titulares y la mayor cantidad de noticias ‘Negativas’ con 2726 titulares, lo que podría estar asociado al periodo de alta incertidumbre sanitaria y económica el año 2020 en que se anuncia la crisis global del COVID-19.

En el año 2024 se observa un mínimo de noticias ‘Negativas’ y la concentración máxima de noticias ‘Positivas’ lo que refuerza la percepción del tono de las noticias ha tendido hacia una dirección más favorable desde el periodo de la pandemia.

4.1.1.1 Nubes de palabras del contexto mediático del 2019 al 2024

A continuación, se resume a modo de nube de palabras el clima informativo y las áreas temáticas clave que dominaron el discurso mediático durante el periodo de investigación 2019 al 2024.

El tamaño de la palabra indica su frecuencia, es decir a mayor frecuencia mayor tamaño en la nube de palabras.

La figura 2 muestra las palabras mas frecuentes utilizadas en el año 2019

Figura 2

Nube de palabras de las noticias del año 2019



Nota. Elaboración propia

Las palabras clave en la figura 2 tienen un tono geopolítico y de mercados, ‘Perú’, ‘Lima’, confirman el enfoque geográfico de las noticias, ‘EEUU’, ‘Venezuela’, ‘China’, muestran los temas internacionales de mayor interés, palabras de política internas como ‘Congreso’, ‘Gobierno’, ‘Vizcarra’, ‘Keiko Fujimori’, señalan puntos de conflictos de poder, casos bandera de debate social como ‘Tía María’; palabras como ‘Caso’, ‘Odebrecht’, ‘Fiscalía’, ‘Poder Judicial’, muestran una agenda económica y corporativa entrelazada a altos casos de corrupción.

La figura 5 muestra las palabras mas frecuentes utilizadas en el año 2022

Figura 5

Nube de palabras de las noticias del año 2022




Nota. Elaboración propia

Las palabras clave en la figura 5 muestran que el escenario político interno se mantuvo como factor predominante esto reflejado en palabras como ‘Congreso’, ‘Pedro Castillo’, ‘Gobierno’, ‘Ejecutivo’, ‘Dina Boluarte’, ‘Anibal Torres’; en el escenario sanitario la palabra ‘COVID’ se reduce drásticamente; en cuanto al escenario macroeconómico global palabras como ‘Ucrania’, ‘Rusia’, ‘China’, ‘Petroperú’ y ‘derrame’, muestran el problema de la inflación global producto de la guerra en Ucrania, y el derrame asociado a PetroPerú.

La figura 6 muestra la las palabras mas frecuentes utilizadas en el año 2023

Figura 6

Nube de palabras de las noticias del año 2023




Nota. Elaboración propia

Las palabras clave en la figura 6 muestran la persistencia de un enfoque informativo dominado por la inestabilidad política reflejado en palabras como ‘protesta’, ‘Gobierno’, ‘Congreso’, ‘comisión’; el tema económico y desastres climáticos se manifiestan en palabras como ‘Niño’, ‘lluvia’, ‘Riesgo regiones’, ‘Temblor’, ‘Magnitud’; en el contexto global ‘EE UU’, ‘Argentina’, ‘México’, y ‘España’ cobran relevancia como principales actores internacionales.

La figura 7 muestra la las palabras mas frecuentes utilizadas en el año 2024

Figura 7

Nube de palabras de las noticias del año 2024



Nota. Elaboración propia

Las palabras clave en la figura 7 muestran un mayor enfoque en la reactivación y la inversión lo cual se ve representado en palabras clave como ‘Perú’, ‘proyecto’, ‘inversión’, ‘Chancay’, ‘US’, lo que indica que la agenda informática ha tenido un enfoque centrado en el desarrollo; sin embargo la insistencia de palabras como ‘Congreso’, ‘Dina Boluarte’, ‘Fiscalía’, indican una especie de consolidación en la temática de política interna; en cuanto al contexto global, ‘EEUU’ reduce tamaño en el mapa de nubes en comparación con años anteriores y aparece ‘China’ para resaltar relaciones comerciales, mientras que eventos como la ‘Copa América’ cobran relevancia y resalta siendo tema contraste a temáticas como fueron el ‘COVID’, el conflicto en ‘Ucrania’ o fenómenos como ‘El Niño’.

En total se analizaron con el modelo BERT los 54 677 titulares, a continuación, se muestra la polaridad y la puntuación de las noticias más destacadas acorde su intensidad mediática.

La tabla 3 muestra las 15 titulares de noticias que mayor ‘SENTIMIENTO POSITIVO’ expresaron según el modelo BERT.

Tabla 3

15 Noticias con mayor 'Sentimiento Positivo'

N.º	Fecha	Titular	Polaridad	Puntuación
1	2024-02-02	San Valentín y los prometedores resultados para los aplicativos de delivery	POS	0,998865128
2	2024-06-03	Christian Bustos: “Me gusta aprender y transmitir mi experiencia a los nuevos valores de la empresa”	POS	0,998796225
3	2024-11-17	CEO de Vista Equity: “El software con IA será la herramienta más productiva”	POS	0,998786986
4	2023-03-31	Las mejores promociones para compartir en familia con el Club.	POS	0,998761892
5	2019-02-15	10 hábitos de las personas extremadamente felices	POS	0,998760462
6	2023-02-04	Señor Honey va por restaurantes propios para conquistar con sus salsas de miel picante	POS	0,998760462
7	2019-11-17	Las mejores fotos de la semana en América Latina	POS	0,998732984
8	2019-07-12	Oficinas en lima: tu mejor inversión, ahora a tu alcance desde US\$ 49,900	POS	0,998723567
9	2024-11-12	Adelántate al Black Friday 2024 en Home Depot: ofertas impresionantes que ya puedes aprovechar	POS	0,9987185
10	2023-09-27	Meta lanza gafas inteligentes: sus tres principales bondades	POS	0,998707891
11	2019-07-02	Maestro Parrillero: las sabrosas novedades de la segunda temporada	POS	0,998707175
12	2021-01-16	Presidente de Sinopharm destaca cualidades de su vacuna: segura, eficaz y amigable	POS	0,99870038
13	2023-06-23	Cajas: “Estamos listas para manejar fondos de AFP y dar más rentabilidad a afiliados”	POS	0,998689711
14	2021-08-24	Pedro Castillo: “Por encima de las diferencias políticas está el país, tengo fe en este Gabinete”	POS	0,998684466

15	2021-07-09	Vacuna de Moderna demuestra alta eficacia contra las primeras variantes	POS	0,998683035
----	------------	---	-----	-------------

Nota. Elaboración propia

Se observa que las mayores puntuaciones en noticias positivas, es decir las más cercanas a [+1], se las llevan temas referidos a el desarrollo de la ‘IA’, ‘el delivery’, ‘las vacunas’, e ‘inversión’, permitiéndonos detectar sectores clave como son la tecnología y la salud pública.

La tabla 4 muestra las 15 titulares de noticias que expresaron el mayor ‘SENTIMIENTO NEGATIVO’ o peores noticias durante el 2019 al 2024 según el modelo BERT.

Tabla 4

15 Noticias con mayor 'Sentimiento Negativo'

N.º	Fecha	Titular	Polaridad	Puntuación
1	2024-07-03	HBR: Señales de que sus reuniones uno a uno no funciona	NEG	-0,999496222
2	2023-04-24	Movimiento de pasajeros por aeropuertos no se recupera aún a niveles prepandemia	NEG	-0,999451101
3	2021-09-05	Una “crisis silenciosa” asoma en EE.UU. ante el fin de ayudas por COVID a desempleados	NEG	-0,999435008
4	2020-05-20	Fed: Hay modelos de negocios que no van a sobrevivir a la pandemia en EE.UU.	NEG	-0,999431551
5	2022-09-28	Dos tercios de los latinos de EE.UU. no disponen de ahorros para imprevistos	NEG	-0,999429524
6	2019-06-16	Elmer Cuba: "Las cifras son para llorar. Este es un año desperdiciado"	NEG	-0,999428928
7	2023-08-07	En EE.UU. es ‘peor’ momento para comprar una casa en últimos 13 años	NEG	-0,999427974
8	2022-11-10	Vladimir Cerrón: Me siento decepcionado en gran parte de Pedro Castillo	NEG	-0,999427736
9	2019-12-25	Cubanos entre las dichas y desdichas de políticas hacia Cuba de Obama y Trump	NEG	-0,999417067
10	2021-02-18	Nelson Shack: “es decepcionante ver este tráfico de vacunas en el marco de un ‘pseudo ensayo clínico’”	NEG	-0,999414444

11	2021-03-19	Salud mental de alumnos en EE.UU. se desmorona fuera de la escuela, señala investigación de Reuters	NEG	-0,999414086
12	2024-10-12	Seguro Social: por qué dicen que es frustrante el COLA 2025 para los jubilados	NEG	-0,999412179
13	2020-10-01	Ola de despidos en EE.UU., sin acuerdo a la vista en el Congreso	NEG	-0,999410152
14	2021-11-10	Minem: “hemos heredado una bomba de tiempo, los conflictos sociales nos están golpeando”	NEG	-0,99940908
15	2024-12-24	Entre la provocación y la realidad, Trump es de nuevo un dolor de cabeza internacional	NEG	-0,999407291

Nota. Elaboración propia


Se identifica que las peores puntuaciones es decir las más cercanas a [-1], tocan temas a un riesgo sistémico económico y político detectadas en frases como ‘modelos de negocio que no van a sobrevivir’, ‘tráfico de vacunas decepcionante’, ‘crisis silenciosa’, ‘falta de ahorros en latinos de EEUU’, ‘fractura política de Cerrón’, ‘ola de despidos’, y ‘muerte’; frases lo suficientemente relacionadas para detectar el pánico en las noticias.

Durante el periodo de estudio cada día ha reportado 25 titulares por cada día hábil de la semana, a los cuales se les sacó promedio de la puntuación del sentimiento obteniendo un total de 1507 observaciones

La figura 8 muestra el sentimiento promedio de los titulares de las noticias durante el periodo de estudio, enero de 2019 a diciembre de 2024.

Figura 8

Promedio del sentimiento de las noticias del 2019 al 2024



Nota. Elaboración propia

La figura 8 presenta la evolución de diaria del promedio del sentimiento de las noticias o ‘Sentimiento mediático’, se puede apreciar que los valores se reúnen mayormente en la línea bajo [0.0] , es decir en terreno negativo, lo que concuerda con el análisis de las nubes de palabras realizado; entre los inicios del año 2022 y 2024 se puede apreciar una tendencia ascendente hacia la neutralidad, es decir lo valores se aproximan más a [0.0] y brevísimo periodo en que las noticias alcanzan un ligero tono optimista.

4.1.2 Rendimiento del IGBVL y principales acciones negociadas

Tabla 5

Estadísticas descriptivas del IGBVL y (08) acciones más negociadas


	IGBVL	ALICORP	BAP	BVN	CVERDE	FERREYC1	IFS	MINSUR	VOLCAN
Prom	21767.6	10.97	158.2	11.12	26.96	2.16	28.78	3.05	0.48
Media	20897.3	9.90	148.0	10.50	26.20	2.15	25.47	3.25	0.47
Máx	31009.7	19.00	250.5	19.00	48.00	3.17	50.00	6.28	0.92
Min	13538.8	5.26	93.0	5.26	13.00	1.12	18.15	1.20	0.17
Des.S	3836.1	3.46	36.5	3.53	8.73	0.49	7.85	1.27	0.17
Skew.	0.8	0.39	0.8	0.29	0.49	0.09	1.05	0.25	0.34
Kurto	3.1	1.82	2.7	1.70	2.15	2.69	2.83	2.06	2.62
J-Bera	156.2	124.37	181.5	126.14	104.99	8.03	279.88	72.19	38.07
Prob.	0.00	0.00	0.0	0.00	0.00	0.02	0.00	0.00	0.00
Obs	1507	1507	1507	1507	1507	1507	1507	1507	1507

Nota. Elaboración propia

La tabla 5 muestra las estadísticas descriptivas referente al precio de cierre de ‘IGBVL’ – Índice General de La Bolsa de Valores de Lima, así como para las ocho (08) empresas más negociadas diariamente durante el periodo de estudio desde enero de 2019 a diciembre de 2024, conteniendo 1507 observaciones para cada una de las nueve series de tiempo.; el precio de cierre de cada serie de tiempo se observa que todas las series presentan asimetría positiva (Skewness > 0); la figura 9 muestra la evolución del precio de cierre del IGBVL, de enero 2019 a diciembre 2024.

Figura 9

Índice general de precios de la BVL, 2019 a 2024




Nota. Elaboración propia

La figura 10 presenta el comportamiento de las ocho (08) acciones más negociadas en la BVL entre 2019 y 2024; se puede apreciar que todas las series reflejan una ‘no estacionariedad’, además de un comportamiento alcista desde 2021.

Figura 10

Precios de las 8 acciones más negociadas en la BVL, 2019 a 2024




Nota. Elaboración propia

Debido a que las series de tiempo referidas a los precios estaban expresadas en magnitudes diferentes y unidades monetarias diferentes, para homogenizar los datos, se realizó una transformación para trabajar con los rendimientos diarios donde obtenidos de la diferencia logarítmica natural es decir $\text{rendimiento} = \ln(\text{valor de hoy}) - \ln(\text{valor de ayer})$.

La figura 11 exhibe que los valores del rendimiento diario tienen un comportamiento estacionario en $I(0)$, es decir los valores oscilan alrededor de una media cercana a 0.0; lo cual es requisito fundamental para el uso de modelos autorregresivos; se presenta alta volatilidad; picos negativos en 2020 y a mediados de 2021, periodos que coinciden con la pandemia y el clima político interno que hubo en el Perú, comportamiento que hace alusión a la heterocedasticidad condicional; este análisis visual justifica el componente asimétrico, para capturar posibles reacciones a las noticias, como componente exógeno.

Figura 11

Rendimiento del Índice general de la BVL, 2019 a 2024




Nota. Elaboración propia

La figura 12 muestra el rendimiento de las acciones más negociadas en la BVL, durante el 2019 a 2024, todas las series se mueven alrededor de 0.0; mientras que las series de BAP, FERREYC1, y MINSUR muestran una volatilidad agrupada en 2023.

Figura 12

Rendimientos de las 8 acciones más negociadas en la BVL, 2019 a 2024



Nota. Elaboración propia

4.2 Prueba de estacionariedad – ADF

La prueba de estacionariedad Augmented Dickey-Fuller (ADF), se realiza bajo la hipótesis nula de que la serie en análisis contiene raíz unitaria es decir que es no estacionaria;

para determinar la estacionariedad se compara los valores absolutos del ‘estadístico-t’ o la probabilidad presentada en el p-valor.

Tabla 6

Prueba de estacionariedad ADF - ‘Sentimiento mediático’

Null Hypothesis: SENTIMENT has a unit root
Exogenous: Constant
Lag Length: 6 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-7.834469	0.0000
Test critical values: 1% level	-3.434552	
5% level	-2.863283	
10% level	-2.567746	

*MacKinnon (1996) one-sided p-values.

Nota. Elaboración propia

La tabla 6 muestra la prueba de estacionariedad para la serie de tiempo que contiene el sentimiento de las noticias, el valor absoluto del estadístico Augmented Dickey- Fuller es $|-7.834469| = 7.834469$, valor que es mayor que el valor crítico más estricto al 1% que es $|-3.434552| = 3.434552$; entonces se rechaza la hipótesis nula de raíz unitaria en todos los niveles de significancia y concluimos que la serie ‘Sentimiento Mediático’ es estacionaria en $I(0)$, sin necesidad de diferenciación.

Tabla 7

Prueba de estacionariedad ADF - 'Índice General de la BVL'

Null Hypothesis: IGBVL has a unit root

Exogenous: Constant

Lag Length: 1 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-24.73753	0.0000
Test critical values: 1% level	-3.434488	
5% level	-2.863255	
10% level	-2.567731	

*MacKinnon (1996) one-sided p-values.

Nota. Elaboración propia

La tabla 7 presenta los resultados de la prueba de estacionariedad para la serie de tiempo que contiene los rendimientos logaritmos del Índice General de la Bolsa de Valores de Lima – IGBVL, el valor absoluto del estadístico Augmented Dickey-Fuller es $|-24.73753| = 24.73753$; valor que resulta ser significativamente mayor que el valor crítico más estricto al 1% que es $|-3.434488| = 3.434488$, así se confirma que la serie es estacionaria en $I(0)$.

Las pruebas de estacionariedad ADF para los retornos logaritmos de las series de tiempo correspondiente a los ocho índices más negociados dentro de la Bolsa de Valores de Lima - ALICORP, BAP, BVN, CVERDE, FERERYC1, IFS, MINSUR, y VOLCAN - mostraron también resultados estacionarios, las tablas con los resultados de sus respectivas pruebas se presentan en los ANEXOS.

4.3 Modelo del Vector AutoRegresivo con variables exógenas – VAR-X

La tabla 8 muestra los resultados de la primera matriz del modelo VARX (2,0) correspondiente al rendimiento del Índice General de la Bolsa de Valores de Lima – IGBVL.

Tabla 8

Ecuación del modelo VARX- IGBVL

	Coeficiente	Std. error	t-stat	prob.
const	0.000483	0.000662	0.730	0.465
sent_pos_l1	0.012128	0.021194	0.572	0.567
sent_neg_l1	0.001842	0.003066	0.601	0.548
L1.igbvl	0.144972	0.068095	2.129	0.033
L1.alicorp	0.009614	0.016920	0.568	0.570
L1.bap	-0.044280	0.025929	-1.708	0.088
L1.bvn	-0.036372	0.015082	-2.412	0.016
L1.cverde	0.001375	0.010315	0.133	0.894
L1.ferreyc1	0.000297	0.007075	0.042	0.966
L1.ifs	-0.015216	0.013224	-1.151	0.250
L1.minsur	0.004885	0.010866	0.450	0.653
L1.volcan	0.002172	0.010489	0.207	0.836
L2.igbvl	0.069647	0.067870	1.026	0.305
L2.alicorp	0.007677	0.016934	0.453	0.650
L2.bap	0.040984	0.025820	1.587	0.112
L2.bvn	-0.006461	0.015139	-0.427	0.670
L2.cverde	0.005880	0.010302	0.571	0.568
L2.ferreyc1	-0.002665	0.007065	-0.377	0.706
L2.ifs	-0.005985	0.013081	-0.458	0.647
L2.minsur	-0.005611	0.010852	-0.517	0.605
L2.volcan	-0.020811	0.010530	-1.976	0.048

Nota. Elaboración propia

En la tabla 8 se muestran cómo los retornos pasados de la variable endógena – L1 y L2- y el sentimiento mediático – componente exógeno- influyen en el rendimiento del IGBVL al día de hoy.

El coeficiente de la constante es 0.000483 con una prob.de 0.465, muy por encima de 0.05 por tanto es no significativo por tanto se interpreta que el rendimiento promedio diario esperado sin considerar otras variables es insignificante.

El sentimiento positivo – componente exógeno – tiene un valor de 0.012128 y un nivel de significancia de 0.567; lo que resulta no significativo; es decir optimismo de las noticias de ayer no tienen un impacto predecible en el Índice General de la Bolsa de Valores de Lima al día de hoy.

El sentimiento negativo – componente exógeno – tiene un valor de 0.001842 y un nivel de significancia de 0.548; lo que resulta no significativo; es decir que el pesimismo de las noticias de ayer no tienen un impacto predecible en el Índice General de la Bolsa de Valores de Lima al día de hoy.

La autodependencia y persistencia del IGBVL, expresado en $L1.igbvl$ tiene un valor de 0.144972 y un nivel de significancia de 0.033; lo que resulta significativo; es decir un rendimiento positivo en el IGBVL de ayer (Y_{t-1}) índice a un rendimiento positivo el día de hoy.

Los coeficientes más importantes que resultaron significativos en la interdependencia de mercados con el IGBVL son; $L1.bvn$ tiene un valor de -0.036372, un nivel de significancia de 0.016; es decir que el índice de la compañía Buena Ventura – BVL- es predictor del IGBVL, un rendimiento positivo en BVL ayer se asocia con una caída en IGBVL hoy.

El segundo coeficiente de influencia cruzada es $L2.volcan$ mostrando un valor de -0.020811 y un nivel de significancia de 0.048; es decir que el índice de la compañía minera VOLCAN es predictor del IGBVL, un rendimiento positivo hace dos días se asocia con una caída en el IGBVL hoy.

La ecuación del IGBVL revela que la dinámica del índice está impulsada por el mercado interno y los flujos de información cruzada y no por el sentimiento mediático ni positivo ni negativo durante el periodo de análisis; la causalidad endógena esta influenciada por su propio retorno y el desempeño de dos de las ocho compañías más negociadas en la BVL como son Buena Ventura y Volcan.

La debilidad de la exogeneidad, sentimiento mediático, no explican significativamente la media condicional del IGBVL.

Los resultados de cada una de los índices evaluados se muestran en la sección de ANEXOS a modo de complemento ya que su análisis excede los objetivos del presente estudio.

Tabla 9

Matriz de Correlación Residual

	igbvl	alicorp	bap	bvn	cverde	ferreyc1	ifs	minsur	volcan
igbvl	1.000	0.348	0.773	0.631	0.341	0.197	0.475	0.263	0.463
alicorp	0.348	1.000	0.234	0.153	0.080	0.124	0.459	0.178	0.236
bap	0.773	0.234	1.000	0.272	0.178	0.139	0.444	0.158	0.273
bvn	0.631	0.153	0.272	1.000	0.179	0.078	0.196	0.077	0.242
cverde	0.341	0.080	0.178	0.179	1.000	0.136	0.044	0.281	0.257
ferreyc1	0.197	0.124	0.139	0.078	0.136	1.000	0.088	0.152	0.144
ifs	0.475	0.459	0.444	0.196	0.044	0.088	1.000	0.136	0.191
minsur	0.263	0.178	0.158	0.077	0.281	0.152	0.136	1.000	0.256
volcan	0.463	0.236	0.273	0.242	0.257	0.144	0.191	0.256	1.000

Nota. Elaboración propia

La tabla 9 muestra la matriz de correlación residual, donde se revela una alta interdependencia instantánea entre los errores de pronóstico de todas las acciones, confirmando la existencia de una riesgo sistémico no explicado por los retornos propios de las acciones, ni por el sentimiento de las noticias (positivas o negativas); las correlaciones más altas se hallan entre el IGBVL y BAP con un índice de 0.773, lo que indica que aquel shock no predicho afecta el índice con una conexión muy fuerte; otras relaciones que muestran índices interesantes son IGBVL – BVN con 0.630 ; CVERDE – MINSUR con 0.280 y VOLCAN – MINSUR con 0.256; y el sector financiero IFS tiene una conexión con ALICORP de 0.459 y de 0.444 con BAP.

4.4 Resultados de la prueba de la Causalidad de Granger

El análisis de causalidad se base en la probabilidad asociada al estadístico F, basado en la regla de decisión, si Prob. < 0.05 ; es decir si el valor Prob. es menor a 0.05 se rechaza la hipótesis nula; H_0 ; caso contrario no hay evidencia de causalidad.

Tabla 10

Causalidad de Granger - IGBVL vs. Sentimiento de las noticias

Sample: 1/03/2019 12/31/2024

Lags: 2

Null Hypothesis:	Obs	F-Statistic	Prob.
IGBVL does not Granger Cause SENTIMENT	1505	0.59794	0.5501
SENTIMENT does not Granger Cause IGBVL		0.42428	0.6543

Nota. Elaboración propia

La tabla 10 muestra los resultados de la prueba de Causalidad en el sentido de Granger de las series de tiempo que contienen la información del Índice General de la Bolsa de Valores de Lima – IGBVL y la serie de tiempo que contiene el sentimiento general de las noticias – SENTIMENT.

- Dado que la primera hipótesis nula H_0 plantea que;

“El rendimiento del IGBVL NO causa en el sentido de Granger los sentimientos de las noticias” obtuvo una probabilidad de 0.5501 superando 0.05, entonces, no se rechaza.

- Dado que la segunda hipótesis nula H_0 plantea que;

“Los sentimientos de las noticias NO causan en el Sentido de Granger el Rendimiento del IGBVL” obtuvo una probabilidad de 0.6543 superando el valor de 0.05, entonces esta hipótesis no se rechaza.

Se llegó a la conclusión de que no existe una relación bidireccional entre ambas series; el sentimiento de las noticias no predice el comportamiento del rendimiento del Índice General de la Bolsa de Valores de Lima, ni viceversa.

Tabla 11

Causalidad de Granger - IGBVL vs. Sentimiento Positivo en las noticias

Sample: 1/03/2019 12/31/2024

Lags: 2

Null Hypothesis:	Obs	F-Statistic	Prob.
IGBVL does not Granger Cause SENT_POS	1505	0.15872	0.8533
SENT_POS does not Granger Cause IGBVL		0.28105	0.7550

Nota. Elaboración propia

La tabla 11 muestra los resultados de la prueba de Causalidad en el sentido de Granger de las series de tiempo que contienen la información del rendimiento diario del Índice General de la Bolsa de Valores de Lima – IGBVL y la serie de tiempo que contiene los valores de los sentimientos positivos de las noticias – SENT_POS.

- Dado que la primera hipótesis nula H_0 plantea que;

“El rendimiento diario del IGBVL NO causa en el sentido de Granger los sentimientos positivos de las noticias” obtuvo una probabilidad de 0.8533 superando 0.05, entonces, no se rechaza.

- Dado que la segunda hipótesis nula H_0 plantea que;

“Los sentimientos positivos de las noticias NO causan en el Sentido de Granger el Rendimiento del IGBVL” obtuvo una probabilidad de 0.7550 superando el valor de 0.05, entonces esta hipótesis no se rechaza.

Estos resultados concluyeron que no existe ninguna relación bidireccional entre el sentimiento positivo de las noticias y el rendimiento diario del Índice General de la Bolsa de Valores de Lima.

Tabla 12

Causalidad de Granger - IGBVL vs. Sentimiento Negativo en las noticias

Sample: 1/03/2019 12/31/2024

Lags: 2

Null Hypothesis:	Obs	F-Statistic	Prob.
IGBVL does not Granger Cause SENT_NEG	1505	0.69476	0.4994
SENT_NEG does not Granger Cause IGBVL		0.39976	0.6706

Nota. Elaboración propia

La tabla 12 muestra los resultados de la prueba de causalidad en el sentido de Granger de las series de tiempo que contienen la información del rendimiento diario del Índice General de la Bolsa de Valores de Lima – IGBVL y la serie de tiempo que contiene los valores de los sentimientos negativos de las noticias – SENT_NEG.

- Dado que la primera hipótesis nula H_0 plantea que;

“El rendimiento diario del IGBVL NO causa en el sentido de Granger los sentimientos negativos de las noticias” obtuvo una probabilidad de 0.4994 superando 0.05, entonces, no se rechaza.

- Dado que la segunda hipótesis nula H_0 plantea que;

“Los sentimientos negativos de las noticias NO causan en el Sentido de Granger el Rendimiento del IGBVL” obtuvo una probabilidad de 0.6706 superando el valor de 0.05, entonces esta hipótesis tampoco no se rechaza.


Estos resultados concluyeron que no existe ninguna relación bidireccional entre el sentimiento negativo de las noticias y el rendimiento diario del Índice General de la Bolsa de Valores de Lima.

4.5 Impulso Respuesta en el IGBVL

La figura 13 muestra la respuesta dinámica del IGBVL ante un shock positivo o negativo en las noticias; la figura sugiere que las noticias no son estadísticamente significativas en para una respuesta en el IGBVL ni en los otros ocho (08) índices que más se negocian dentro de ella.

Figura 13

Función Impulso - Respuesta en el IGBVL



Nota. Elaboración propia

4.6 Correlación Dinámica ADCC- GARCH del IGBVL

Tabla 13

Dinámica de la correlación ADCC-GARCH

	Estimate	Std. Error	t value	Pr(> t)
[igbv1].mu	0.000819	0.000500	1.637.995	0.101423
[igbv1].ar1	0.578736	0.274446	2.108.739	0.034967
[igbv1].ma1	-0.505621	0.293008	-1.725.618	0.084416
[igbv1].mxreg1	0.002396	0.002580	0.928660	0.353065
[igbv1].omega	0.000003	0.000005	0.564346	0.572519
[igbv1].alpha1	0.136139	0.067131	2.027.968	0.042564
[igbv1].beta1	0.851823	0.077461	10.996.796	0.000000
[Joint]dcca1	0.022618	0.064315	0.351679	0.725079
[Joint]dccb1	0.901701	0.163461	5.516.301	0.000000
[Joint]dccg1	0.009440	0.108843	0.086730	0.930886

Nota. Elaboración propia

La tabla 13 muestra que el retorno del IGBVL es impulsado principalmente por su propia inercia interna, $AR1 = 0.578736$ y no por los sentimientos mediáticos (componente exógeno) $mxreg1 = 0.0024$ a una significancia de 0.353065 resultando un factor no significativo; respecto a la volatilidad el coeficiente de $alpha1 = 0.136139$, significativo lo que indica que los errores de ayer tienen un impacto significativo en el nivel de volatilidad de hoy; un coeficiente de $beta1 = 0.851823$ con un valor p de 0.000 altamente significativo, lo que indica la persistencia de la volatilidad es decir la volatilidad pasada como predictor de la volatilidad futura.

El coeficiente de la persistencia de correlación $dccb1 = 0.9017$ altamente significativo indica que el riesgo sistémico es altamente inercial; el término de la asimetría $dccg1 = 0.0094$ es insignificante estadísticamente, por lo tanto, se refuta la hipótesis de que los shocks atribuidos al componente exógeno de noticias negativas provoquen un aumento en el nivel de la correlación sistémica, el coeficiente del impacto simétrico $dcca1 = 0.0226$ no alcanza la significancia estadística, por tanto se interpreta que los shocks de volatilidad

simétricos tampoco tienen un impacto significativo en cambiar el nivel de la correlación sistémica en la Bolsa de Valores de Lima.

4.7 Contratación de hipótesis

4.7.1 Hipótesis Nula General

H0: No existe una influencia significativa entre el sentimiento de las noticias y rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024.

Hipótesis Alternativa General

H1: No existe una influencia significativa entre el sentimiento de las noticias y rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024

Debido a que en la prueba de causalidad en el sentido de Granger la variable SENTIMENT tuvo una prob. de 0.6543, y en modelo ADCC- GARCH representada en su coeficiente de MXREG1 obtuvo un valor de 0.3530 superior a 0.05 (ver Tabla 13) ; excediendo los valores de significancia estadística; por tanto, no existe evidencia para rechazar la hipótesis nula; por lo cual se acepta H_0 .

4.7.2 Contrastación de hipótesis específicas

Primera hipótesis nula específica

H0: El sentimiento positivo de las noticias no tiene un impacto positivo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024

Primera hipótesis alternativa específica

H1: El sentimiento positivo de las noticias tiene un impacto positivo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024

Debido a que el coeficiente de la variable sent_pos_l1 dentro del modelo VAR-X fue de 0.0121 con un p-valor de 0.567 muy por encima del 0.05 esperado para ser

estadísticamente significativa (ver Tabla 8); y que en la prueba de causalidad en el sentido de Granger SENT_POS hacia IGBVL mostró una probabilidad de 0.7550 (ver Tabla 11) también muy por encima del 0.05 es que no rechazamos la hipótesis nula H_0 , es admitida entonces la ausencia de causalidad.

Segunda hipótesis nula específica

H_0 : El sentimiento negativo de las noticias no tiene un impacto negativo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 - 2024

Segunda hipótesis alternativa específica

H_1 : El sentimiento negativo de las noticias tiene un impacto negativo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024

Debido a que el coeficiente de la variable `sent_neg_l1` dentro del modelo VAR-X fue de 0.0018 con un p-valor de 0.548 muy por encima del 0.05 esperado para ser estadísticamente significativa (ver Tabla 8); y que en la prueba de causalidad en el sentido de Granger SENT_NEG hacia IGBVL mostró una probabilidad de 0.6706 (Ver Tabla12) también muy por encima del 0.05 es que no rechazamos la hipótesis nula H_0 , entonces admitimos la ausencia de causalidad.

CAPÍTULO V: DISCUSIÓN, CONCLUSIONES Y RECOMENDACIONES

5.1 Discusión

Los resultados obtenidos en esta investigación, que demuestra la No significancia del sentimiento mediático, discrepan con los resultados de las investigaciones de Wen et al.(2024), De Olivera (2024) y Chatziloizos et al. (2024), quienes reportaron que la integración del sentimiento utilizando las herramientas de Deep Learning, pueden mejorar la precisión predictiva de los precios de las acciones; esta discrepancia puede sugerir la eficiencia del mercado peruano para digerir las noticias o sugerir la anulación del poder predictivo del sentimiento de las noticias sobre la modelización de los rendimientos en el índice General de la Bolsa de Valores de Lima.

La alta persistencia del riesgo sistemático es congruente con los estudios presentados con Bin & Wohar (2023) quienes analizaron los mercados financieros durante periodos de alta volatilidad; el riesgo de contagio se vuelve inercial ante choques, la Bolsa de Valores de Lima presenta una alta persistencia ($dccb1=0.90$) es decir fragilidad estructural lo cual permite que los riesgos perduren por periodos extensos, característica que es común en mercados financieros emergentes.

Los resultados la no significancia el término de asimetría desafía la expectativa teórica, en la que el pánico (noticias negativas) amplifica la interdependencia sistémica ante el optimismo, nuestros resultados implican que ante la propagación del riesgo el nivel de correlación sistémica se comporta de forma simétrica.

5.2 Conclusiones

- No se encontró evidencia significativa para afirmar que el sentimiento mediático de la noticias haya influido significativamente en el rendimiento diario del Índice General de la Bolsa de Valores de Lima (IGBVL) durante el periodo 2019 – 2024; tanto la prueba de causalidad de Granger ($p=0.6543$) como los modelos VAR-X y ADCC-GARCH ($p=0.3531$) mostraron que el sentimiento mediático no tiene un efecto predictivo ni significativo sobre los rendimientos bursátiles, aceptándose consecuentemente la hipótesis nula general.
- El sentimiento positivo de las noticias tampoco mostró tener un impacto significativo en el rendimiento de la BVL. Los coeficientes asociados al sentimiento positivo de las noticias en el modelo VAR-X ($p= 0.567$) no fueron estadísticamente significativos, y la prueba de causalidad de Granger no evidenció causalidad en ninguna dirección ($p=0.7550$); por tanto, se acepta la hipótesis nula específica en que el sentimiento positivo de las noticias no impulsa al alza el rendimiento bursátil en el IGBVL.
- Se concluye que el sentimiento negativo de las noticias no tiene un impacto negativo estadísticamente significativo en el rendimiento del IGBVL; los coeficientes de las pruebas como VAR-X ($p=0.548$) y en la prueba de Causalidad de Granger también se refutó una relación causal ($p=0.6706$); por tanto, se acepta la hipótesis nula en la que el pesimismo en las noticias no constituye un antecedente a las caídas en el mercado accionario peruano.

5.3 Recomendaciones

- Se recomienda a los actores del mercado no utilizar el sentimiento mediático global de las noticias como un factor predictivo del comportamiento diario del Índice General de la Bolsa de Valores de Lima; se sugiere profundizar el modelo estudiado con otras variables macroeconómicas, indicadores técnicos o eventos corporativos concretos; ya que el mercado sugiere responder a factores endógenos y estructurales antes que a la percepción mediática.
- Al no encontrarse evidencia de que el optimismo de las noticias impulse el alza del IGBVL, se recomienda a los inversionistas evitar estrategias de compra basadas únicamente en titulares positivos o en expectativas basadas en noticias alentadores; en su lugar se recomienda evaluar cualquier señal alcista con análisis técnicos o fundamentales basados en estrategias y no en derivaciones del sesgo mediático.
- No se recomienda a los inversionistas asumir automáticamente que una ola de noticias negativas provocará caídas bursátiles inmediatas en el IGBVL, lo que es resulta particularmente importante útil para evitar ventas innecesarias en momentos de alarma mediática; sin embargo se recomienda al inversionista diferenciar entre ruido informativo y eventos de riesgo real que involucren como cambios estructurales regulatorios, sanciones, crisis políticas confirmadas; eventos que pueden tener un impacto concreto en el precio de los activos del mercado.

REFERENCIAS BIBLIOGRÁFICAS

- Alanya, W. (marzo de 2023). Un indicador de sentimiento a partir de las noticias económicas. *MONEDA*. Obtenido de <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Moneda/moneda-193/moneda-193-03.pdf>
- Alvarado, M., & Rodriguez, G. (2024). *Time-Varying effects of financial uncertainty shocks on macroeconomic fluctuations in Peru [Documento de trabajo]*. Pontificia Universidad Católica del Perú, Departamento de Economía, Lima.
doi:<http://doi.org/10.18800/2079-8474.0531>
- Arias, C. (2014). Conozca algo más: La Bolsa de Valores de Lima. *Revistas PUCP*, 72 - 75. Obtenido de <https://revistas.pucp.edu.pe/index.php/revistalidera/article/download/14747/15331/>
- Arrona, P. (diciembre de 2020). Breve semblanza del sentimiento de mercado. *Vincula Téctica EFAN*, 6(2), 1850-1855.
- Banco Santander. (2022). *¿Qué son los mercados financieros?* Obtenido de [bancosantander.es: https://www.bancosantander.es/glosario/mercados-financieros](https://www.bancosantander.es/glosario/mercados-financieros)
- Beltrán, N., & Rodriguez, E. (2020). Procesamiento de lenguaje natural (PNL) - GPT-3, y su aplicación en la Ingeniería de Software. *Tecnología, Investigación y Academia - Red Avanza - RITA*, 18-36. Obtenido de <https://revistas.udistrital.edu.co/index.php/tia/article/view/17323/17210>
- Bin, J., & Wohar, M. (2023). Heterogenous responses of stock markets to covid related news and sentiments: Evidence from the 1st year of pandemic. *International*

- Economics*, 68-85. Obtenido de <https://www.sciencedirect.com/science/article/pii/S211070172200083X>
- Blita Internacional. (2022). *Perfil del Perú, Descripción panorama económico*. Obtenido de <https://www.blita.com/es/perfil-peru>: <https://www.blita.com/es/perfil-peru>
- Bravo, S. (2022). *¿Cómo se determina el rendimiento de una acción?* Obtenido de ESAN DEJA HUELLA: <https://www.esan.edu.pe/conexion-esan/como-se-determina-el-rendimiento-de-una-accion-1>
- Cano, C., & Cardoso, E. (2015). El impacto de los sesgos conductuales en la toma de decisiones de inversión. *Moneda*, 28-33. Obtenido de <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Moneda/moneda-162/moneda-162-07.pdf>
- Cedeno-Moreno, D., & Vargas-Lombardo, M. (01 de agosto de 2020). Aprendizaje automático aplicado al análisis de sentimientos. *Revista de I+D Tecnológico*, 16(2), 59-66. Obtenido de <https://revistas.utp.ac.pa/index.php/id-tecnologico/article/view/2833>
- Chatziloizos, G., Gunopulos, D., & Konstantinou, K. (2024). Deep Learning for Stock Market Prediction Using Sentiment [Aprendizaje automático para la predicción del mercado de valores mediante el sentimiento y análisis técnico]. *SN Computer Science*, 5(446). doi:<https://doi.org/10.1007/s42979-024-02651->
- Costola, M., Hinz, O., Nofer, M., & Pelizzon, L. (2023). Machine learning sentiment analysis, COVID-19 news and stock market reactions. *Research in International Business and Finance*, 64. doi:<https://doi.org/10.1016/j.ribaf.2023.101881>

- De Oliveira, A., Antunes, A., & Palermo, G. (mayo de 2024). Predicting the Brazilian Stock market with sentiment analysis, technical indicators and stock prices: a deep learning approach. *Computational Economics*. doi:<https://doi.org/10.1007/s10614-024-10636-y>
- Diario Gestión. (01 de 01 de 2015). *Los 25 años de Gestión: hoy se inicia una nueva era*. Obtenido de Gestión: <https://gestion.pe/economia/25-anos-gestion-hoy-inicia-nueva-70890-noticia/?ref=gesr>
- Espino, F. (Mayo de 2022). Análisis de la versión débil de la hipótesis del mercado eficiente en el Perú. *Serie de Documentos de trabajo del BCRP*. Obtenido de <https://www.bcrp.gob.pe/docs/Publicaciones/Documentos-de-Trabajo/2022/documento-de-trabajo-003-2022.pdf>
- FasterCapital. (junio de 2024). *Sentimiento de los inversores analisis de la psicologia del mercado en la Bolsa de Valores de Bombay*. Obtenido de [fastercapital.com: https://fastercapital.com/es/contenido/Sentimiento-de-los-inversores--analisis-de-la-psicologia-del-mercado-en-la-Bolsa-de-Valores-de-Bombay.html#Indicadores-de-sentimiento-de-los-inversores.html](https://fastercapital.com/es/contenido/Sentimiento-de-los-inversores--analisis-de-la-psicologia-del-mercado-en-la-Bolsa-de-Valores-de-Bombay.html#Indicadores-de-sentimiento-de-los-inversores.html)
- Ferraz, C., Moura, L., Norden, L., & Schechtman, R. (2023). *The real costs of washing away corruption*. Central Bank of Brazil. Obtenido de <https://afajof.org/management/viewp.php?n=23996>
- Groß-Klußmann, A. (february de 2024). Learning deep news sentiment representations for macro-finance [Aprendizaje de representaciones profundas de sentimientos noticiosos para las finanzas macroeconómicas]. *Digital Finance*. doi:<https://doi.org/10.1007/s42521-024-00107-2>

- Gu, W. J., Wei, C. S., Zhong, Y. H., Dong, L. T., Wang, Z. Y., & Yan, C. (2024). "Predicting Stock Prices with FinBERT-LSTM: Integrating News Sentiment Analysis". *Association for Computing Machinery*, 67-72. Obtenido de <https://dl.acm.org/doi/10.1145/3694860.3694870>
- Li, X., Wu, P., & Wenpeng, W. (2020). Incorporating stock prices and news sentiments for stock market prediction: A case of Hong Kong [Incorporación de los precios de las acciones y noticias para la predicción del mercado de valores: Un caso de Hong Kong]. *Information Processing and Management*, 57. doi:<https://doi.org/10.1016/j.ipm.2020.102212>
- López, R. (12 de diciembre de 2022). *Causalidad de Granger: Causalidades en series temporales*. Obtenido de blog.damavi.com: <https://blog.damavis.com/causalidad-de-granger-causalidades-en-series-temporales/>
- McCombs, M., & Shaw, D. (1972). *The Agenda-setting function of mass media*. North Carolina. Obtenido de <https://fbaum.unc.edu/teaching/articles/POQ-1972-McCOMBS-176-87.pdf>
- Mino, D., & Williamson, C. (2025). *Sentiment and volatility in financial markets: A review of BERT and GARCH applications during geopolitical crises*. University College Cork, School of Mathematical Sciences . doi:doi.org/10.48550/arXiv.2510.16503
- Oliva, C. (2014). El periodismo digital y sus retos en la sociedad global y del conocimiento. *Revista de Ciencias Sociales*(61), 1-30. Obtenido de <https://www.redalyc.org/pdf/4959/495950257004.pdf>
- Pérez, A. (2018). *Uso del análisis de texto para medir el sentimiento de mercado de España [Universidad Pontificia Comillas]*. Madrid, España. Obtenido de

<https://repositorio.comillas.edu/xmlui/bitstream/handle/11531/18978/TFG%20-%20PeIrez%20Albertos%2c%20AIngela.pdf?sequence=1&isAllowed=y>

Rego-Rodriguez, F., Germán-Flores, L., & Vitón-Castillo, A. (septiembre de 2022).

Artificial intelligence and machine learning: present and future applications in health sciences. *Seminars in Medical Writing and Education*, 1-9.

doi:<https://doi.org/10.56294/mw20229>

Revista Económica. (08 de julio de 2022). *¿Cuál es el perfil del inversionista peruano actual?* Recuperado el agosto de 2024, de Revista económica:

https://www.revistaeconomia.com/cual-es-el-perfil-del-inversionista-peruano-actual/#goog_rewarded

Silva, N., Paredes, I., & Ocaña, J. (2022). La calidad de la información en los medio digitales de noticia. *Revista científica mundo de la investigación y el conocimiento*, 46-57. doi:10.26820/recimundo/6.(4).octubre.2022.46-57

Swathi, T., Kasiviswanath, N., & Ananda, A. (08 de march de 2022). An optimal deep learning-based LSTM for stock price prediction using twitter sentiment analysis [Un LSTM óptimo basado en aprendizaje profundo para la predicción del precio de las acciones mediante el análisis del sentimiento de Twitter]. *Applied intelligence*. doi:10.1007/s10489-022-03175-2

Wan, X., Yang, J., Marinov, S., Callies, J.-P., Zohren, S., & Dong, X. (2021). Sentiment correlation in financial news networks and associated market movements. *The Springer Nature*. doi:<https://doi.org/10.1038/s41598-021-82338-6>

Wankhade, M., Sekhara, A., & Chaitanya, K. (febrero de 2022). A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*, 55,

5731-5780. Obtenido de <https://link.springer.com/article/10.1007/S10462-022-10144-1>

Yasir, A., Prihandini, R., Makhfudloh, I., Agatha, A., R.J, D., & Wulandari, Y. (2024).

Stock price prediction model using temporal graphs and market sentiment analysis

[Modelo de predicción de precios de acciones mediante gráficos temporales y análisis de sentimientos de mercado]. Obtenido de

https://www.researchgate.net/publication/381490475_STOCK_PRICE_PREDICTION_MODEL_USING_TEMPORAL_GRAPHS_AND_MARKET_SENTIMENT_ANALYSIS

Zapata, M. (08 de mayo de 2024). *Por qué son importantes las buenas noticias*. Obtenido

de El Comercio: <https://elcomercio.pe/opinion/columnistas/periodismo-de-soluciones-por-que-son-importantes-las-buenas-noticias-por-mariza-zapata-vasquez-noticia/?ref=ecr>

Zhang, B., Yang, H., Zhou, T., Babar, A., & Liu, X.-Y. (2023). Enhancing Financial

Sentiment analysis via retrieval augmented large models. *ACM International Conference on AI in Finance*. Obtenido de <https://arxiv.org/abs/2310.04027>

ANEXOS

Anexo 1: Matriz de Consistencia

Título: “Sentimiento Mediático Y Rendimiento De La Bolsa De Valores De Lima, Periodo 2019 – 2024”

PROBLEMA	OBJETIVO	HIPÓTESIS	VARIABLES	DIMENSIONES	INDICADORES	METODOLOGÍA
Problema principal	Objetivo principal	Hipótesis principal	Variable independiente			Tipo de Investigación: Aplicada
¿Influye el sentimiento mediático de las noticias en el rendimiento de la Bolsa de Valores de Lima, periodo 2019 – 2024?	Evaluar si influye el sentimiento mediático de las noticias en el rendimiento de la Bolsa de Valores de Lima, periodo 2019 – 2024	Ho: No existe una influencia significativa entre el sentimiento mediático de las noticias y el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024 H₁: Existe una influencia significativa entre el sentimiento mediático de las noticias y el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 - 2024	Sentimiento mediático	Popularidad del sentimiento Intensidad del sentimiento	Porcentaje de sentimiento positivos, negativos y neutros en las noticias. Escala de intensidad del sentimiento diario [-1, +1]	Nivel de investigación: Explicativo
						Diseño de la investigación: No experimental; Longitudinal
Problemas específicos	Objetivos específicos	Hipótesis específicas	Variable dependiente			Población: Índice general de la BVL
¿Influye el sentimiento positivo de las noticias en el rendimiento de la Bolsa de Valores de Lima, periodo 2019 – 2024? ¿Influye el sentimiento negativo de las noticias en el rendimiento de la Bolsa de Valores de Lima, periodo 2019 – 2024?	Evaluar la influencia del sentimiento positivo de las noticias en el rendimiento de la Bolsa de Valores de Lima, durante el periodo 2019 – 2024 Analizar cómo el sentimiento negativo de las noticias afecta el rendimiento de la Bolsa de Valores de Lima, periodo 2019 -2024	El sentimiento positivo de las noticias tiene un impacto positivo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 – 2024 El sentimiento negativo de las noticias tiene un impacto negativo en el rendimiento de la Bolsa de Valores de Lima durante el periodo 2019 - 2024	Rendimiento de la Bolsa de Valores de Lima	Variación del Índice Bursátil de la Bolsa de Valores de Lima	Cambio porcentual diario del índice de la Bolsa de Valores de Lima	Muestra: Rendimiento diario del índice general de la BVL periodo, 2019 -2024 Rendimiento de las 8 empresas más negociadas en la BVL, periodo 2019 -2024
						Técnica: Observación, recolección de datos de fuentes secundarias
						Tratamiento estadístico: Procesamiento de lenguaje natural (PNL) Modelos VEC

Anexo 2: Pruebas de raíz unitaria para los 08 índices más negociados en la IGBVL

Tabla 14

Prueba de estacionariedad ADF - 'Alicorp'

Null Hypothesis: ALICORP has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-45.12925	0.0001
Test critical values: 1% level	-3.434485	
5% level	-2.863253	
10% level	-2.567730	

*MacKinnon (1996) one-sided p-values.

Tabla 15

Prueba de estacionariedad ADF - 'BAP'

Null Hypothesis: BAP has a unit root
Exogenous: Constant
Lag Length: 1 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-25.96891	0.0000
Test critical values: 1% level	-3.434488	
5% level	-2.863255	
10% level	-2.567731	

*MacKinnon (1996) one-sided p-values.

Tabla 16

Prueba de estacionariedad ADF - 'BVN'

Null Hypothesis: BVN has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-40.07568	0.0000
Test critical values: 1% level	-3.434485	
5% level	-2.863253	
10% level	-2.567730	

*MacKinnon (1996) one-sided p-values.

Tabla 17

Prueba de estacionariedad ADF - 'CVERDE'

Null Hypothesis: CVERDE has a unit root

Exogenous: Constant

Lag Length: 4 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-16.97382	0.0000
Test critical values: 1% level	-3.434497	
5% level	-2.863258	
10% level	-2.567733	

*Mackinnon (1996) one-sided p-values.

Tabla 18

Prueba de estacionariedad ADF - 'Ferreyrc1'

Null Hypothesis: FERREYC1 has a unit root

Exogenous: Constant

Lag Length: 2 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-30.25734	0.0000
Test critical values: 1% level	-3.434491	
5% level	-2.863256	
10% level	-2.567732	

*Mackinnon (1996) one-sided p-values.

Tabla 19

Prueba de estacionariedad ADF - 'IFS'

Null Hypothesis: IFS has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-49.45391	0.0001
Test critical values: 1% level	-3.434485	
5% level	-2.863253	
10% level	-2.567730	

*Mackinnon (1996) one-sided p-values.

Tabla 20

Prueba de estacionariedad ADF - 'MINSUR'

Null Hypothesis: MINSUR has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-52.08446	0.0001
Test critical values: 1% level	-3.434485	
5% level	-2.863253	
10% level	-2.567730	

*Mackinnon (1996) one-sided p-values.

Tabla 21

Prueba de estacionariedad ADF - 'VOLCAN'

Null Hypothesis: VOLCAN has a unit root

Exogenous: Constant

Lag Length: 0 (Automatic - based on SIC, maxlag=23)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-38.62358	0.0000
Test critical values: 1% level	-3.434485	
5% level	-2.863253	
10% level	-2.567730	

*Mackinnon (1996) one-sided p-values.

Anexo 3: Resultados VARX para los 08 índices más negociados en la IGBVL

Tabla 22

Ecuación del modelo VARX- Alicorp

	Coefficient	std. error	t-stat	prob
const	-0.001364	0.001178	-1.158	0.247
sent_pos_l1	-0.008660	0.037725	-0.230	0.818
sent_neg_l1	-0.005746	0.005458	-1.053	0.292
L1.igbvl	0.228644	0.121209	1.886	0.059
L1.alicorp	-0.161667	0.030117	-5.368	0.000
L1.bap	0.010484	0.046154	0.227	0.820
L1.bvn	0.007785	0.026845	0.290	0.772
L1.cverde	0.003728	0.018360	0.203	0.839
L1.ferreyc1	0.022406	0.012593	1.779	0.075
L1.ifs	-0.108509	0.023539	-4.610	0.000
L1.minsur	-0.025531	0.019342	-1.320	0.187
L1.volcan	0.062411	0.018671	3.343	0.001
L2.igbvl	0.070875	0.120809	0.587	0.557
L2.alicorp	-0.051985	0.030142	-1.725	0.085
L2.bap	0.083303	0.045959	1.813	0.070
L2.bvn	-0.003175	0.026947	-0.118	0.906
L2.cverde	-0.014722	0.018337	-0.803	0.422
L2.ferreyc1	0.009014	0.012576	0.717	0.474
L2.ifs	-0.040682	0.023284	-1.747	0.081
L2.minsur	-0.004346	0.019317	-0.225	0.822
L2.volcan	-0.005248	0.018743	-0.280	0.779

Nota. Elaboración propia

Tabla 23

Ecuación del modelo VARX - BAP

	Coefficient	std. error	t-stat	prob
const	0.000869	0.001217	0.714	0.475
sent_pos_l1	0.003437	0.038987	0.088	0.930
sent_neg_l1	0.006083	0.005641	1.078	0.281
L1.igbvl	0.172210	0.125263	1.375	0.169
L1.alicorp	0.023695	0.031125	0.761	0.446
L1.bap	-0.136151	0.047698	-2.854	0.004
L1.bvn	-0.033006	0.027743	-1.190	0.234
L1.cverde	0.007783	0.018975	0.410	0.682
L1.ferreyc1	-0.001479	0.013015	-0.114	0.910
L1.ifs	-0.022880	0.024327	-0.941	0.347
L1.minsur	-0.008001	0.019989	-0.400	0.689
L1.volcan	0.008296	0.019296	0.430	0.667
L2.igbvl	0.055005	0.124850	0.441	0.660
L2.alicorp	0.034756	0.031151	1.116	0.265
L2.bap	0.073613	0.047496	1.550	0.121
L2.bvn	-0.006993	0.027848	-0.251	0.802
L2.cverde	0.026200	0.018951	1.383	0.167
L2.ferreyc1	0.008397	0.012996	0.646	0.518
L2.ifs	-0.001763	0.024063	-0.073	0.942
L2.minsur	-0.016662	0.019963	-0.835	0.404
L2.volcan	-0.032871	0.019370	-1.697	0.090

Nota. Elaboración propia

Tabla 24

Ecuación del modelo VARX - BVN

	Coefficient	std. error	t-stat	prob
const	0.001263	0.001691	0.747	0.455
sent_pos_l1	0.005506	0.054171	0.102	0.919
sent_neg_l1	0.010026	0.007837	1.279	0.201
L1.igbvl	0.339228	0.174047	1.949	0.051
L1.alicorp	-0.009518	0.043246	-0.220	0.826
L1.bap	0.004102	0.066274	0.062	0.951
L1.bvn	-0.101793	0.038548	-2.641	0.008
L1.cverde	-0.038640	0.026364	-1.466	0.143
L1.ferreyc1	0.001169	0.018083	0.065	0.948
L1.ifs	-0.016183	0.033801	-0.479	0.632
L1.minsur	0.055891	0.027773	2.012	0.044
L1.volcan	-0.054383	0.026810	-2.028	0.043
L2.igbvl	0.416509	0.173472	2.401	0.016
L2.alicorp	-0.031945	0.043282	-0.738	0.460
L2.bap	-0.007998	0.065994	-0.121	0.904
L2.bvn	-0.054737	0.038693	-1.415	0.157
L2.cverde	-0.008280	0.026331	-0.314	0.753
L2.ferreyc1	-0.021745	0.018058	-1.204	0.229
L2.ifs	-0.008966	0.033434	-0.268	0.789
L2.minsur	-0.016736	0.027737	-0.603	0.546
L2.volcan	-0.066910	0.026913	-2.486	0.013

Nota. Elaboración propia

Tabla 25

Ecuación del modelo VARX - CVERDE

	Coefficient	std. error	t-stat	prob
const	0.001442	0.001826	0.790	0.430
sent_pos_l1	0.061676	0.058475	1.055	0.292
sent_neg_l1	0.006579	0.008460	0.778	0.437
L1.igbvl	0.605017	0.187877	3.220	0.001
L1.alicorp	0.106653	0.046683	2.285	0.022
L1.bap	-0.125932	0.071540	-1.760	0.078
L1.bvn	-0.077482	0.041611	-1.862	0.063
L1.cverde	-0.375467	0.028459	-13.193	0.000
L1.ferreyc1	0.027242	0.019520	1.396	0.163
L1.ifs	0.033531	0.036487	0.919	0.358
L1.minsur	-0.008446	0.029980	-0.282	0.778
L1.volcan	0.056299	0.028941	1.945	0.052
L2.igbvl	0.336484	0.187257	1.797	0.072
L2.alicorp	0.077471	0.046721	1.658	0.097
L2.bap	-0.076463	0.071238	-1.073	0.283
L2.bvn	-0.026435	0.041768	-0.633	0.527
L2.cverde	-0.169983	0.028423	-5.980	0.000
L2.ferreyc1	0.023530	0.019493	1.207	0.227
L2.ifs	-0.013537	0.036091	-0.375	0.708
L2.minsur	0.061543	0.029941	2.055	0.040
L2.volcan	-0.042133	0.029052	-1.450	0.147

Nota. Elaboración propia

Tabla 26

Ecuación del modelo VARX - FERREYC1

	Coefficient	std. error	t-stat	prob
const	0.000642	0.002464	0.260	0.795
sent_pos_l1	-0.027119	0.078905	-0.344	0.731
sent_neg_l1	0.002874	0.011416	0.252	0.801
L1.igbvl	0.758436	0.253517	2.992	0.003
L1.alicorp	-0.087204	0.062992	-1.384	0.166
L1.bap	-0.090433	0.096534	-0.937	0.349
L1.bvn	-0.110196	0.056149	-1.963	0.050
L1.cverde	0.018777	0.038402	0.489	0.625
L1.ferreyc1	-0.547646	0.026340	-20.792	0.000
L1.ifs	0.045457	0.049234	0.923	0.356
L1.minsur	-0.047976	0.040455	-1.186	0.236
L1.volcan	0.052823	0.039052	1.353	0.176
L2.igbvl	-0.128208	0.252680	-0.507	0.612
L2.alicorp	0.107359	0.063045	1.703	0.089
L2.bap	0.125879	0.096127	1.310	0.190
L2.bvn	0.021361	0.056361	0.379	0.705
L2.cverde	0.012204	0.038354	0.318	0.750
L2.ferreyc1	-0.163897	0.026303	-6.231	0.000
L2.ifs	-0.021156	0.048700	-0.434	0.664
L2.minsur	0.067004	0.040402	1.658	0.097
L2.volcan	-0.025164	0.039201	-0.642	0.521

Nota. Elaboración propia

Tabla 27

Ecuación del modelo VARX - IFS

	Coefficient	std. error	t-stat	prob
const	-0.000942	0.001612	-0.585	0.559
sent_pos_l1	0.014017	0.051613	0.272	0.786
sent_neg_l1	-0.001843	0.007467	-0.247	0.805
L1.igbvl	0.623708	0.165831	3.761	0.000
L1.alicorp	-0.168233	0.041205	-4.083	0.000
L1.bap	-0.006296	0.063145	-0.100	0.921
L1.bvn	-0.137230	0.036728	-3.736	0.000
L1.cverde	0.046895	0.025120	1.867	0.062
L1.ferreyc1	-0.003435	0.017229	-0.199	0.842
L1.ifs	-0.298250	0.032205	-9.261	0.000
L1.minsur	-0.016641	0.026462	-0.629	0.529
L1.volcan	0.038474	0.025545	1.506	0.132
L2.igbvl	0.062477	0.165283	0.378	0.705
L2.alicorp	0.007703	0.041239	0.187	0.852
L2.bap	0.202059	0.062878	3.213	0.001
L2.bvn	-0.026507	0.036867	-0.719	0.472
L2.cverde	0.031332	0.025088	1.249	0.212
L2.ferreyc1	0.003548	0.017205	0.206	0.837
L2.ifs	-0.114795	0.031856	-3.604	0.000
L2.minsur	-0.032340	0.026428	-1.224	0.221
L2.volcan	-0.030965	0.025642	-1.208	0.227

Nota. Elaboración propia

Tabla 28

Ecuación del modelo VARX - MINSUR

	Coefficient	std. error	t-stat	prob
const	0.001825	0.001702	1.072	0.284
sent_pos_l1	0.019276	0.054503	0.354	0.724
sent_neg_l1	0.004060	0.007885	0.515	0.607
L1.igbvl	0.205669	0.175116	1.174	0.240
L1.alicorp	0.079559	0.043512	1.828	0.067
L1.bap	-0.013939	0.066681	-0.209	0.834
L1.bvn	-0.077397	0.038785	-1.996	0.046
L1.cverde	0.048770	0.026526	1.839	0.066
L1.ferreyc1	-0.014350	0.018194	-0.789	0.430
L1.ifs	0.029273	0.034008	0.861	0.389
L1.minsur	-0.378737	0.027944	-13.553	0.000
L1.volcan	0.099897	0.026975	3.703	0.000
L2.igbvl	0.245601	0.174538	1.407	0.159
L2.alicorp	0.002266	0.043548	0.052	0.959
L2.bap	0.007445	0.066399	0.112	0.911
L2.bvn	-0.039475	0.038931	-1.014	0.311
L2.cverde	0.053538	0.026493	2.021	0.043
L2.ferreyc1	0.011031	0.018169	0.607	0.544
L2.ifs	-0.005334	0.033639	-0.159	0.874
L2.minsur	-0.111627	0.027907	-4.000	0.000
L2.volcan	-0.011853	0.027078	-0.438	0.662

Nota. Elaboración propia

Tabla 29

Ecuación del modelo VARX - VOLCAN

	Coefficient	std. error	t-stat	prob
const	-0.003155	0.001910	-1.652	0.099
sent_pos_l1	-0.040762	0.061164	-0.666	0.505
sent_neg_l1	-0.012885	0.008849	-1.456	0.145
L1.igbvl	0.291930	0.196517	1.486	0.137
L1.alicorp	0.033481	0.048829	0.686	0.493
L1.bap	-0.106763	0.074830	-1.427	0.154
L1.bvn	-0.024739	0.043525	-0.568	0.570
L1.cverde	-0.003248	0.029768	-0.109	0.913
L1.ferreyc1	0.007790	0.020418	0.382	0.703
L1.ifs	-0.039972	0.038165	-1.047	0.295
L1.minsur	-0.019710	0.031359	-0.629	0.530
L1.volcan	-0.006055	0.030272	-0.200	0.841
L2.igbvl	0.197554	0.195868	1.009	0.313
L2.alicorp	-0.108988	0.048870	-2.230	0.026
L2.bap	0.104327	0.074514	1.400	0.161
L2.bvn	-0.028276	0.043689	-0.647	0.517
L2.cverde	-0.035831	0.029730	-1.205	0.228
L2.ferreyc1	-0.006924	0.020389	-0.340	0.734
L2.ifs	0.007995	0.037750	0.212	0.832
L2.minsur	-0.032943	0.031318	-1.052	0.293
L2.volcan	-0.002087	0.030388	-0.069	0.945

Nota. Elaboración propia