



**Sistema de soporte decisional basado en Procesamiento de Lenguaje Natural (NLP)  
para la optimización de portafolios de inversión bajo demanda**

Andres Mauricio Niño Ibague

Universidad Ean

Facultad de Ingeniería

Ingeniería de sistemas

Bogotá, Colombia

04/junio/2026

**Sistema de soporte decisional basado en Procesamiento de Lenguaje Natural  
(NLP) para la optimización de portafolios de inversión bajo demanda**

Andres Mauricio Niño Ibague

Trabajo de grado presentado como requisito para optar al título de:

**Ingeniero de sistemas**

Directora:

Marie José Chéry Leal

Universidad Ean

Facultad de Ingeniería

Ingeniería de sistemas

Bogotá, Colombia

04/junio/2026

Nota de aceptación:

---

---

---

---

---

---

Firma del jurado

---

Firma del jurado

---

Firma del director del trabajo de grado

Dedicatoria

A mis padres y mi querida abuela por el apoyo  
e impulso a ser cada día mejor y lograr todas  
las metas.

## **Resumen**

Este trabajo de grado entrega la creación de un **Sistema de Soporte Decisional** (DSS) diseñado para optimizar la toma de decisiones en portafolios de inversión mediante la integración de **Procesamiento de Lenguaje Natural** (NLP) y análisis técnico. Principalmente el problema se encuentra en la sobrecarga de información financiera no estructurada y la alta complejidad algorítmica de las herramientas de *trading* actuales; esto da una limitación para el uso de la tecnología y genera volatilidad emocional en inversores retail. Con el fin de darle solución, se propuso una arquitectura de software desacoplada operando en la nube.

De manera ordenada, se hizo un enfoque cuantitativo y descriptivo-correlacional estructurado en cuatro fases: ingesta de datos en tiempo real mediante la API de Yahoo Finance, vectorización de sentimiento utilizando el modelo pre-entrenado **FinBERT**, consolidación algorítmica de osciladores técnicos y despliegue de una interfaz asíncrona. La solución principal fue la generación optimizada de un Índice de Salud Sintética (ISS), una métrica unificada que correlaciona la polaridad semántica de las noticias del mercado con el histórico de precios. Se tomó en cuenta pasar el procesamiento matemático al *backend* y utilizar un **bot de Telegram** como interfaz ubicua de baja fricción para lograr democratizar el acceso a la inteligencia artificial financiera. Esta solución mitiga el ruido informativo y proporciona al usuario evidencia algorítmica objetiva sobre los puntos óptimos de entrada y salida del mercado, superando las limitaciones de los problemas propuestos en diferentes estudios.

**Palabras clave:** Sistema de Soporte Decisional, Procesamiento de Lenguaje Natural, FinBERT, Análisis de Sentimiento, Bot de Telegram, Mercado Bursátil.

### **Abstract**

This graduation work delivers the creation of a **Decision Support System** (DSS) designed to optimize decision-making in investment portfolios through the integration of **Natural Language Processing** (NLP) and technical analysis. Mainly, the problem is found in the overload of unstructured financial information and the high algorithmic complexity of current trading tools; this creates a limitation for the use of technology and generates emotional volatility in retail investors. In order to provide a solution, a decoupled software architecture operating in the cloud was proposed.

In an orderly manner, a quantitative and descriptive-correlational approach was taken, structured in four phases: real-time data ingestion via the Yahoo Finance API, sentiment vectorization using the pre-trained **FinBERT** model, algorithmic consolidation of technical oscillators, and deployment of an asynchronous interface. The main solution was the optimized generation of a Synthetic Health Index (ISS), a unified metric that correlates the semantic polarity of market news with historical price data. It was taken into account to move the mathematical processing to the *backend* and use a **Telegram bot** as a ubiquitous, low-friction interface to achieve the democratization of access to financial artificial intelligence. This solution mitigates information noise and provides the user with objective algorithmic evidence regarding optimal market entry and exit points, overcoming the limitations of the problems proposed in different studies.**Keywords:** Decision Support System, Natural Language Processing, Investment portfolios, FinBERT, Financial artificial intelligence, Telegram bot.

## Introducción

Actualmente el sector financiero se caracteriza por la generación masiva y constante de datos. La cantidad de información, noticias y métricas bursátiles cada vez crece más rápido, superando la capacidad y tiempo de un inversor individual **(Feldman & Sanger, 2007)**. Dada la gran cantidad de información, esto resulta en más incertidumbre, afectando directamente a los inversores novatos, quienes no tienen herramientas eficientes para filtrar la información del mercado y tener una mejor certeza de los datos.

Desde la perspectiva de la ingeniería de sistemas y la ciencia de datos, el mayor problema informático está en la heterogeneidad de la información. Se cree que la mayor parte de los datos financieros importantes están en formatos no estructurados, tales como reportes corporativos y flujos de noticias en formato texto. Si el usuario no dispone de sistemas de automatización, deberá realizar procesos manuales de extracción y lectura, lo cual genera una latencia operativa alta y requiere un tiempo valioso que podría ser dedicado a la optimización estratégica del portafolio.

Para mitigar estas limitaciones técnicas, la tecnología actualmente permite la implementación de Sistemas de Soporte Decisional (DSS) impulsados por arquitecturas en la nube. Específicamente, la integración del Procesamiento de Lenguaje Natural (NLP) mediante modelos pre-entrenados como FinBERT **(Araci, 2019)**, permite clasificar la polaridad semántica de grandes lotes de texto financiero con alta precisión computacional. Al orquestar estas capacidades de IA con los algoritmos matemáticos tradicionales para el análisis técnico, se elimina la subjetividad humana, asegurando una evaluación objetiva y determinista de cada activo evaluado.

Gracias a esta integración tecnológica es posible estructurar una métrica consolidada denominada Índice de Salud Sintética (ISS). Este índice es una variable cuantitativa que resume la saturación de datos estructurados y no estructurados del mercado en un indicador intuitivo. De esta manera, se colabora con el inversor novato para que logre optimizar su capacidad de análisis de

una forma más sencilla, delegando el procesamiento masivo al software y reduciendo la gran cantidad de tiempo dedicado a tareas tediosas de investigación manual.

Ante los problemas arquitectónicos expuestos, el presente documento plantea la siguiente pregunta de investigación: ¿Cómo diseñar un sistema automatizado que, mediante la integración de APIs financieras, modelos de procesamiento de lenguaje natural e indicadores de análisis técnico, permita calcular un Índice de Salud Sintética (ISS) y generar alertas proactivas en tiempo real a través de un bot en la nube?

Ante esta interrogante, el proyecto tiene como objetivo general: Desarrollar un prototipo funcional que, mediante la integración de APIs financieras, modelos de procesamiento de lenguaje natural e indicadores de análisis técnico, permita calcular un Índice de Salud Sintética (ISS) de activos financieros y generar alertas proactivas en tiempo real a través de un bot desplegado en la nube.

Para conseguir esta meta central, el desarrollo de la investigación se descompone en los siguientes objetivos específicos. Primero, definir los requerimientos funcionales y no funcionales de la herramienta a fin de asegurar una adecuada recolección y gestión de la información bursátil que debe ser entregada al usuario. Luego, diseñar la arquitectura del sistema integrando APIs financieras, el modelo FinBERT, los indicadores de análisis técnico y los componentes requeridos para el cálculo del índice de Salud Sintética y la generación de alertas.

Posteriormente, desarrollar una herramienta automatizada que permita la recolección de información bursátil, el procesamiento mediante modelos de lenguaje natural y análisis técnico, y la interacción con el usuario a través de un bot desplegado en la nube. Finalmente, realizar pruebas de validación del sistema verificando el funcionamiento para el cálculo del Índice de Salud Sintética, mediante la contrastación algorítmica de los resultados arrojados por el prototipo frente a plataformas consolidadas de análisis técnico e historiales de mercado.

En conclusión, este proyecto de ingeniería tiene como objetivo democratizar el acceso a análisis financieros avanzados mediante una solución de software robusta, escalable y

automatizada. Cuando se traslada la carga computacional de la extracción de datos y la inferencia de lenguaje natural a una arquitectura desplegada en la nube, se ofrece al inversor una clara interfaz de trazabilidad que transforma volúmenes masivos de información dispersa en alertas tempranas, objetivas y accionables para la correcta toma de decisiones.

## Marco Teórico

### Sistemas de Información y Sobrecarga de Datos Bursátiles

En el mundo financiero actual, los mercados actúan como grandes generadores de datos en tiempo real. Esta información es clasificada computacionalmente en dos tipos: estructurada y no estructurada. Los datos estructurados (series temporales numéricas, precios, volúmenes) son procesables mediante algoritmos relacionales estándar (**Hasbrouck, 2007**). Sin embargo, la mayor proporción de la información crítica del mercado reside en formatos no estructurados (noticias textuales y reportes corporativos). La imposibilidad del ser humano de procesar este enorme cúmulo de datos heterogéneos con escasa latencia origina una restricción operativa, limitando la capacidad de análisis del inversor. Desde el punto de vista computacional, este problema justifica la creación de los llamados Sistemas de Soporte Decisional (DSS), diseñados para automatizar la extracción y estandarización de la información (**Power, 2002**).

### Análisis Técnico y Procesamiento Algorítmico

El análisis técnico es una metodología determinista que, a través de modelos matemáticos, evalúa la acción del mercado (**Murphy, 1999**). Los indicadores técnicos, en el mundo de la ingeniería financiera, son un tipo de algoritmo que permite filtrar. Uno de los más robustos es el Índice de Fuerza Relativa (RSI), desarrollado por **Wilder (1978)**. El RSI ejecuta una ecuación paramétrica basada en medias móviles exponenciales que mide la aceleración de los cambios de precio, acotando el resultado en una variable escalar estandarizada de 0 a 100. Al vectorizar este cálculo con estructuras de datos de Python (Dataframes), el sistema es capaz de identificar umbrales de sobrecompra o sobreventa con precisión matemática, sin necesidad de que el usuario interprete visualmente.

### Procesamiento de Lenguaje Natural (PLN) en Entornos Financieros

El Procesamiento de Lenguaje Natural (PLN) es una parte de la Inteligencia Artificial. Se enfoca en entender y procesar el lenguaje humano de manera automática. Su objetivo es tomar

texto normal y convertirlo en números que las computadoras puedan entender. Esto ayuda a analizar y usar la información de manera más efectiva (**Jurafsky & Martin, 2023**). En el diseño de sistemas financieros, el mayor desafío del PLN es la desambiguación contextual del vocabulario bursátil. Para lograrlo, los pipelines de PLN implementan procesos de tokenización y extracción de características, permitiendo que un algoritmo evalúe matemáticamente la semántica de una noticia antes de que esta impacte la acción del precio.

### **Arquitectura del Modelo FinBERT**

FinBERT es un modelo de lenguaje que ya ha sido entrenado. Está diseñado para ayudar en tareas de clasificación, especialmente en el ámbito financiero (**Araci, 2019**). Su arquitectura subyacente se basa en BERT (Bidirectional Encoder Representations from Transformers), que emplea mecanismos de atención bidireccional para procesar el contexto global de una secuencia de texto de forma simultánea (**Devlin et al., 2018; Vaswani et al., 2017**). Al haber sido entrenado con un corpus de millones de textos financieros especializados, FinBERT supera las limitaciones de los diccionarios tradicionales. En la práctica, el modelo funciona con titulares de noticias que se obtienen de internet. Aplica una fórmula matemática para decidir a qué categoría pertenece cada titular, retornando una probabilidad cuantitativa que clasifica la polaridad del texto en sentimiento positivo, negativo o neutro.

### **Índices Sintéticos y Fusión de Datos**

Para hacer que el análisis sea más rápido, la estructura de datos usa una técnica específica. Esto evita que el sistema tarde mucho en procesar mucha información a la vez, recurriendo a la agregación algorítmica mediante índices sintéticos. Un índice sintético consolida fuentes de datos heterogéneas en un único valor escalar estandarizado (**Saisana & Tarantola, 2002**). En el contexto de este sistema, el Índice de Salud Sintética (ISS) fusiona la salida del pipeline de inferencia de IA (polaridad de FinBERT) con el pipeline matemático (RSI). Gracias a esto, el modelo necesita menos potencia de procesamiento. Esto hace que sea más fácil de usar para cualquiera, entregando una métrica unificada y lista para el consumo.

### **Sistemas de Alertas Orientados a Eventos**

Los sistemas orientados a eventos (Event-Driven Architecture) están diseñados para reaccionar rápido a los cambios de estado (**Coulouris et al., 2011**). En el dominio bursátil, en lugar de requerir que el usuario consulte manualmente el estado de un activo, estos sistemas gestionan un monitoreo que no depende de una respuesta inmediata. Cuando los motores lógicos detectan que el ISS ha cruzado un umbral crítico establecido, el sistema dispara automáticamente un evento de notificación (webhook o tarea programada), garantizando que la información se entregue de forma proactiva y en tiempo real.

### **Interfaces Conversacionales (Bots)**

Los bots de mensajería son un avance en cómo interactuamos con las interfaces de usuario (UI), funcionando como la capa de presentación de la arquitectura (**McTear et al., 2016**). Al conectarse con plataformas de comunicación mediante APIs simples, el bot simplifica la complejidad del trabajo en el backend. Esto permite al usuario interactuar con el sistema a través de comandos simples y recibir respuestas enriquecidas, tales como gráficas de análisis técnico renderizadas dinámicamente en la memoria volátil (RAM) del servidor, optimizando así la velocidad de entrega de la información.

### **Seguridad de la Información y Gestión de APIs**

Para que un sistema financiero sea fuerte, necesita seguir protocolos de seguridad muy estrictos basados en la confidencialidad, integridad y disponibilidad (**Stallings, 2017**). Para asegurar la fiabilidad de las métricas, la ingesta de datos debe realizarse exclusivamente desde fuentes certificadas utilizando protocolos cifrados (HTTPS/TLS). A nivel de despliegue, la arquitectura exige que los tokens de autenticación de las APIs, los webhooks del bot y las llaves de acceso a la nube estén aislados mediante variables de entorno, previniendo vulnerabilidades y asegurando la integridad transaccional del sistema automatizado.

### **Estado Del Arte (Metodología PRISMA)**


#### **Metodología de Búsqueda (PRISMA)**

Para la construcción del estado del arte y la validación de la arquitectura propuesta, se realizó una búsqueda sistemática en bases de datos académicas de alto impacto en ingeniería y ciencias computacionales, tales como **IEEE Xplore**, **Scopus** y **Google Scholar**. La estrategia de búsqueda se centró en descriptores técnicos específicos, incluyendo: "financial sentiment analysis", "FinBERT model application", "hybrid trading systems" y "democratization of financial AI". Como criterio de inclusión, se filtraron publicaciones de los últimos seis años para garantizar que la tecnología base (arquitecturas Transformer y modelos de aprendizaje profundo) no estuviera obsoleta.

Para asegurar el rigor del proceso y eliminar el ruido informativo, se aplicó el protocolo **PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses)**. Mediante el uso de operadores booleanos (por ejemplo, NOT "Social Media") se excluyeron investigaciones basadas en análisis de redes sociales no estructuradas, priorizando literatura enfocada en el procesamiento de fuentes financieras oficiales. Este método permitió segmentar la investigación en fases de identificación, tamizaje, elegibilidad e inclusión definitiva.

**Figura 1**

*Diagrama de flujo del proceso de revisión sistemática (PRISMA)*



*Nota.* Adaptado de la declaración PRISMA 2020 para la selección de fuentes bibliográficas.

### **Análisis Comparativo de Autores y Soporte Decisional**

A partir de la revisión sistemática, se identificaron cuatro investigaciones clave que sustentan el desarrollo de este prototipo. En la capa de procesamiento de lenguaje natural (NLP), el trabajo de Araci (2019) marca un hito al demostrar que un modelo de lenguaje entrenado con un corpus de dominio específico (FinBERT) supera a los algoritmos genéricos en la clasificación de la polaridad financiera. Esta superioridad técnica es respaldada por Mishev et al. (2020), quienes mediante una evaluación comparativa de algoritmos, concluyeron que las arquitecturas basadas en

Transformers (como BERT) logran una precisión un 15% mayor que los modelos tradicionales en la detección de sentimiento bursátil.

Sin embargo, a nivel de arquitectura de sistemas, Ozbayoglu et al. (2020) advierten en su revisión sobre modelos de aprendizaje profundo que la alta complejidad algorítmica de estas redes neuronales suele generar herramientas que intimidan al usuario final y requieren un alto poder computacional. Para mitigar esta barrera de adopción tecnológica, Yang et al. (2022) argumentan la necesidad de "democratizar" la IA mediante el diseño de interfaces ubicuas y de baja fricción.

Conectando estas visiones, el presente proyecto resuelve la brecha técnica identificada en la literatura: orquesta la potencia analítica demostrada por Araci y Mishev dentro de un Sistema de Soporte Decisional (DSS), pero mitiga la complejidad advertida por Ozbayoglu delegando el procesamiento a la nube y utilizando un bot de mensajería (basado en los principios de Yang) como interfaz ligera para asistir al inversor en la decisión crítica de los puntos de entrada y salida del mercado.

**Tabla 1***Comparativa de estudios seleccionados y su relación con la arquitectura del proyecto*

| <b>Autor(es) / Año</b>  | <b>Título del estudio</b>                   | <b>Objetivo principal</b>                                | <b>Metodología empleada</b>                          | <b>Variables analizadas</b>                           | <b>Principales hallazgos</b>                                  | <b>Limitaciones reportadas</b>                           | <b>Relación con el proyecto actual</b>                           |
|-------------------------|---------------------------------------------|----------------------------------------------------------|------------------------------------------------------|-------------------------------------------------------|---------------------------------------------------------------|----------------------------------------------------------|------------------------------------------------------------------|
| Araci (2019)            | FinBERT: Financial Sentiment Analysis       | Adaptar el modelo BERT al sector financiero              | NLP / Pre-entrenamiento con corpus financiero        | Polaridad de sentimiento (Positivo, Negativo, Neutro) | Supera a modelos genéricos en precisión de contexto bursátil  | No tiene una capa de visualización para usuario final    | Aporta el motor de IA que se usará en el bot                     |
| Mishev et al. (2020)    | Evaluation of Sentiment Analysis in Finance | Comparar modelos de IA en predicción de mercados.        | Cuantitativo / Evaluación comparativa de algoritmos. | Rentabilidad esperada vs Sentimiento detectado.       | Los Transformers logran un 15% más de agudeza técnica.        | Se limita a servidores locales sin acceso móvil          | Valida la viabilidad técnica del uso de Transformers             |
| Ozbayoglu et al. (2020) | Deep Learning for Financial Applications    | Revisar el estado del arte del Deep Learning en trading. | Revisión sistemática / Análisis de literatura.       | Redes neuronales, RNN, LSTM y Transformers.           | Los sistemas son robustos pero la complejidad es una barrera. | La mayoría de apps son demasiado densas para el usuario. | Justifica la necesidad de crear una interfaz simple en Telegram. |
| Yang et al. (2022)      | Democratizing AI in Financial Services      | Analizar la accesibilidad de la IA para inversores.      | Cualitativo - Aplicado / Diseño de interfaces.       | Facilidad de uso (UX) y adopción tecnológica.         | La simplicidad móvil aumenta la confianza del inversor.       | Falta de robustez en el backend de procesamiento.        | Guía el diseño de la experiencia del bot hacia lo simple.        |

**Nota.** Elaboración propia a partir de la revisión sistemática bajo metodología PRISMA.

## **Metodología**

### **Enfoque y Alcance de la Investigación**

Esta investigación utiliza un enfoque cuantitativo y se basa en un diseño metodológico no experimental de corte transversal. Se trata de una investigación descriptiva y correlacional porque busca describir el estado técnico de un activo financiero y relacionarlo con variables de sentimiento informático. La finalidad de esta investigación es proporcionar una métrica que ayude al usuario final a tomar decisiones informadas sobre cuándo entrar y salir del mercado bursátil. Se analizan datos del mercado en tiempo real en un periodo específico, evaluando la eficacia de la tecnología como mitigador de la volatilidad emocional inherente al *trading* tradicional.

### **Fases de Desarrollo del Proyecto**

Para garantizar el cumplimiento metodológico y el desarrollo secuencial del sistema, la investigación se estructuró en cuatro fases operativas. Cada fase corresponde a un objetivo específico del proyecto y detalla las actividades, herramientas e instrumentos computacionales requeridos para su ejecución:

#### **Fase 1: Ingesta de Datos y Filtrado Temporal**

La primera fase implica conectar con fuentes de información bursátil, obtener series temporales de precios y recopilar noticias financieras recientes. Se aplica un filtro para asegurar que el sistema solo procese noticias que coincidan con el horario de la bolsa de valores, descartando datos obsoletos. Herramientas: Scripts en Python, bibliotecas de extracción y APIs financieras (ej. Yahoo Finance API).

#### **Fase 2: Análisis de Sentimiento mediante Inteligencia Artificial**

El sistema analiza cada titular de noticia y clasifica automáticamente la polaridad semántica (positiva, negativa o neutra), asignando un valor numérico para su posterior

procesamiento. Herramientas: Modelo FinBERT, bibliotecas de estructuración de datos (Pandas) y entornos de Machine Learning.

### **Fase 3: Procesamiento Técnico y Generación del Índice Sintético**

En esta etapa, también se calculan los osciladores técnicos necesarios a partir del histórico de precios. Finalmente, el sistema fusiona las métricas técnicas con el sentimiento obtenido por la IA para generar el Índice de Salud Sintética (ISS). Herramientas: Bibliotecas matemáticas de Python y estructuras de datos (DataFrames).

### **Fase 4: Despliegue de la Interfaz y Presentación al Usuario**

La última fase consiste en crear una interfaz conversacional para que el sistema sea más fácil de usar. El objetivo es que el sistema envíe al usuario el Índice de Salud Sintética (ISS) de manera automática, ahorrándole al inversor el trabajo de buscar y limpiar datos manualmente. Herramientas: API de Telegram (python-telegram-bot), webhooks y servicios en la nube.

## Resultados

### Resultados

En esta sección se presentan los hallazgos empíricos derivados del despliegue, ejecución e ingesta de datos del agente automatizado de gestión de riesgo financiero en un entorno de producción basado en la nube.

#### Descripción de la labor de investigación e infraestructura

El sistema se desplegó de forma independiente en una máquina virtual de Microsoft Azure utilizando una instancia Linux (Standard D2s v3, 2 vCPUs, 8 GiB RAM). El procesamiento síncrono del backend se configuró mediante un demonio en segundo plano que interactúa directamente con la API de Telegram. Durante el periodo de validación y pruebas piloto, la infraestructura cloud demostró una alta disponibilidad de red, registrando un 100% de persistencia en las peticiones entrantes y tasas de éxito del protocolo de comunicación sin pérdidas de paquetes (HTTP/1.1 200 OK).

#### Procesamiento y persistencia de los datos

La arquitectura del sistema operó bajo un enfoque analítico híbrido a través del gestor de flujos automatizados n8n y scripts optimizados en Python. La captura cuantitativa de mercado se realizó mediante la API de Yahoo Finance (yfinance), calculando indicadores técnicos tradicionales como el Índice de Fuerza Relativa (RSI). De manera paralela, la ingesta cualitativa recopiló titulares y noticias de alta relevancia bursátil, los cuales fueron procesados por el modelo de procesamiento de lenguaje natural (NLP) **FinBERT** para extraer puntuaciones vectoriales de sentimiento financiero (positivo, neutral y negativo).

Como resultado de este pipeline reactivo, la lógica del sistema ejecutó la fórmula algorítmica ponderada del **Índice de Salud Sintética (ISS)**. Los registros consolidados se almacenaron de forma relacional en un motor SQLite local (historico.db). Durante las pruebas

piloto intensivas ejecutadas entre el 3 y el 4 de junio de 2026, se compilaron y auditaron con éxito evaluaciones en tiempo real para activos de alta capitalización y ETFs. A continuación, se presenta una muestra estadística de los datos crudos consolidados en la tabla analisis:

```
sqlite> .tables
 analisis
sqlite> .mode column
.headers on
SELECT * FROM analisis;
sqlite> .mode column
sqlite> .headers on
sqlite> SELECT * FROM analisis;
id  ticker  iss_score  fecha
--  -
1   PRUEBA  -0.12      2026-06-03 03:04:24.307103
2   MSFT    -0.32      2026-06-03 03:37:35.673653
3   MSFT    -0.32      2026-06-03 03:40:55.271717
4   MSFT    -0.32      2026-06-03 03:43:37.493227
5   MSFT    -0.32      2026-06-03 03:48:42.710521
6   MSFT    -0.32      2026-06-03 03:53:17.560879
7   MSFT    -0.48      2026-06-04 18:06:02.364167
8   APPLE   0.0        2026-06-04 18:21:34.839496
9   AAPL    -0.48      2026-06-04 18:21:43.866343
10  META    -0.82      2026-06-04 18:36:04.328181
11  MSFT    -0.65      2026-06-04 18:36:45.443698
12  VOO     -0.56      2026-06-04 18:36:59.745793
13  AMZN    -0.3192    2026-06-04 18:59:48.317180
14  MSFT    -0.2966    2026-06-04 19:00:12.168988
15  TSLA    -0.1404    2026-06-04 19:05:07.043209
16  MSFT    -0.2978    2026-06-04 19:05:22.821859
17  MSFT    -0.2974    2026-06-04 19:07:12.115280
sqlite> 
```

## **Análisis de resultados**

La interpretación de los hallazgos empíricos detallados en la sección anterior permite validar la consistencia científica, el rendimiento computacional y la utilidad analítica del software desarrollado.

### **Interpretación analítica y patrones identificados**

El análisis cualitativo y cuantitativo detallado del Índice ISS revela que el algoritmo responde de manera dinámica y proporcional a las perturbaciones del mercado. Al examinar el comportamiento secuencial del activo MSFT (Microsoft) el día 4 de junio de 2026, se identifica un patrón de fluctuación donde el ISS se desplaza desde  $-\$0.3200$  hasta un mínimo de  $-\$0.6500$ , estabilizándose posteriormente en  $-\$0.2974$ . Este comportamiento demuestra cuantitativamente la sensibilidad de la fórmula: el índice reflejó la acumulación de noticias bajistas interpretadas por FinBERT en correlación con la pérdida de *momentum* en el RSI.

Por su parte, la evaluación del activo META arrojó el valor más crítico registrado durante la ventana de observación (ISS:  $-\$0.8200$ ). Esto comprueba que el modelo es capaz de aislar eventos de alta volatilidad fundamental o caídas técnicas drásticas, traduciéndolas en una métrica única y severa de alerta temprana para el usuario minorista.

### **Validación de objetivos y mitigación de asimetría**

Los resultados obtenidos resuelven de forma directa la pregunta de investigación y validan el objetivo principal del proyecto. El ecosistema desarrollado demostró que es técnicamente viable fusionar la analítica de datos cualitativos estructurados por Inteligencia Artificial con métricas predictivas cuantitativas tradicionales.

Desde la perspectiva de la ingeniería de software y la viabilidad económica, el procesamiento síncrono descentralizado redujo la latencia analítica a pocos segundos por consulta bajo un costo fijo nominal de infraestructura en producción de  $\$75.40$  USD mensuales. Esto corrobora la hipótesis de que es posible democratizar herramientas de nivel institucional,

mitigando la brecha y la asimetría informativa que enfrentan los inversores independientes a través de una interfaz accesible y de código abierto.

### **Propuesta de solución a la problemática**

#### **Situación actual**

El mundo financiero de hoy está lleno de información. Es difícil procesar todo lo que sucede. Un inversor que no tiene mucha experiencia se ve obligado a tomar decisiones basadas en corazonadas o siguiendo tendencias que no son muy profundas. La situación actual muestra que hay una gran diferencia entre las grandes instituciones financieras y los inversores pequeños. Mientras que las grandes instituciones poseen infraestructura para el análisis algorítmico, los inversores pequeños no tienen acceso a esas herramientas. Esta brecha no solo dificulta identificar oportunidades, sino que induce sesgos cognitivos —como el comportamiento de rebaño— que aumentan el riesgo de capital.

#### **Oportunidades**

La superación de esta problemática reside en democratizar el acceso a herramientas de análisis automatizado. La combinación de la inteligencia artificial y el análisis técnico permite convertir la gran cantidad de información en algo que se puede procesar y entender. Las oportunidades identificadas tras este estudio se centran en tres pilares:

**Eficiencia:** El uso de modelos transformadores (como FinBERT) permite cuantificar el sentimiento del mercado extrayendo significado donde antes solo existía texto no estructurado.

**Agilidad:** La automatización de los flujos de datos reduce el tiempo que se tarda en reaccionar a las noticias y los eventos. Esto permite tomar decisiones más rápidas y precisas.

**Consolidación:** Al fusionar la capacidad predictiva del análisis técnico con la sensibilidad al contexto de la IA, se obtiene una métrica sintética que ofrece una visión holística del activo financiero.

### **Propuesta de solución al problema planteado**

La solución que se propone es crear un sistema que ayude a tomar decisiones de manera inteligente. Este sistema se basa en una arquitectura que se enfoca en los eventos que ocurren.

**Arquitectura del sistema:** El sistema se basa en un proceso automatizado que comienza con la recopilación de datos financieros en tiempo real. Este flujo incluye la extracción de precios históricos, el filtrado de noticias relevantes, la inferencia de sentimiento mediante FinBERT y la fusión de estos datos con indicadores técnicos para obtener el Índice de Salud Sintética (ISS).

**Interfaz y usabilidad:** Este sistema es fácil de usar porque se puede acceder a él a través de un bot en plataformas de comunicación como Telegram. De esta manera, se reduce la complejidad y se hace que el sistema sea más accesible.

**Valor agregado:** Al reducir la cantidad de información que se tiene que procesar, el sistema permite que el usuario se enfoque en tomar decisiones importantes. Esta propuesta cambia la forma en que los inversores trabajan. En lugar de solo recibir información, los inversores pueden tomar decisiones con la ayuda de un sistema de inteligencia artificial.

### **Discusión**

La valoración final de esta investigación muestra que combinar modelos de lenguaje como FinBERT con análisis técnico es efectivo para automatizar procesos financieros. Al revisar los resultados y compararlos con la teoría, obtenemos algunas conclusiones clave:

**Precisión frente al ruido:** Los resultados demuestran que un sistema automatizado puede filtrar el ruido del mercado con más precisión que la gestión manual. Esto valida la hipótesis de que la automatización es superior para el manejo de grandes volúmenes de datos no estructurados.

**Latencia decisional:** La principal ventaja de este sistema no es solo procesar grandes cantidades de datos, sino reducir el tiempo de toma de decisiones. Al consolidar métricas heterogéneas en un único valor escalar (ISS), el sistema permite una reacción operativa inmediata.

**Democratización tecnológica:** Estos hallazgos indican que la diferencia tecnológica entre pequeños inversores e instituciones grandes se puede reducir usando arquitecturas orientadas a eventos. Esto permite a los inversores minoristas acceder a capacidades analíticas competitivas mediante infraestructuras livianas.

Esto sugiere que la automatización ayuda a protegerse contra sesgos cognitivos, como el miedo a perder dinero y el comportamiento de masa. Al eliminar la dependencia de la interpretación visual y subjetiva del mercado, el sistema provee un marco de trabajo determinista que favorece el juicio estratégico sobre la reacción emocional.

Sin embargo, es importante reconocer que ningún sistema automatizado puede eliminar completamente el riesgo de mercado. La discusión se centra en el papel de la inteligencia artificial: no debe verse como una herramienta predictiva infalible, sino como un sistema de soporte para la toma de decisiones que mejora la capacidad de análisis. El rol del software es, en última instancia, servir como una extensión de las capacidades analíticas del ser humano.

La investigación concluye que, aunque el sistema funciona bien en entornos volátiles, su rendimiento depende de la calidad de las fuentes de datos. Los resultados obtenidos son sólidos, pero sugieren que la escalabilidad futura del proyecto dependerá de integrar más fuentes de datos para mejorar el análisis de sentimiento, permitiendo una visión aún más enriquecida del ecosistema financiero.

### **Plan de divulgación**

#### **Visión y propósito**

El objetivo de este plan es compartir lo que he aprendido con las personas que se interesan por innovar en el sector financiero. Este proyecto nace como una herramienta técnica de acceso libre que busca servir como portafolio profesional, pero con la mirada puesta en un futuro como modelo de negocio. Mi objetivo es que cualquier persona pueda acceder a herramientas de análisis financiero de buena calidad, eliminando la barrera de entrada que tradicionalmente poseen los sistemas de análisis institucional.

#### **Estrategia de impacto social**

El impacto que busco generar es preventivo. Quiero evitar que los nuevos inversores pierdan dinero porque no saben cómo analizar o porque toman decisiones apresuradas. La visión es que más personas superen el miedo inicial a las pérdidas y vean la inversión como una forma segura de proteger su dinero a largo plazo, incluso cuando hay inflación.

#### **Hoja de ruta (Roadmap de desarrollo)**

El proyecto seguirá una evolución independiente centrada en la experiencia del usuario y la robustez técnica:

**Fase de adopción:** Consolidación del bot en Telegram como herramienta de acceso libre para aprender de la interacción real con los usuarios.

**Fase de transición:** Cuando el sistema esté en una página web, será más fácil para cada persona ajustarlo a sus gustos y preferencias personales, permitiendo una interfaz más robusta y personalizada.

**Fase de escalabilidad:** Mejora continua del sistema para convertir el prototipo en una herramienta de uso diario.

Estrategia de difusión y crecimiento Elegí las redes sociales porque son la forma más rápida de llegar a las personas que tienen poco tiempo o que están empezando a aprender sobre inversiones.

**Transparencia técnica:** Como sé que la confianza en los datos es importante, seré muy claro explicando cómo funciona el sistema para que las personas entiendan lo que están usando. La confianza es el pilar para que un usuario adopte una métrica técnica en su toma de decisiones.

**Comunidad:** Quiero crear un lugar donde las personas que se interesan por las finanzas puedan encontrar una herramienta técnica que sea fácil de entender y usar.

Visión a futuro Sabré que el proyecto va bien cuando vea que las personas lo usan todos los días al invertir. El éxito no se medirá por métricas corporativas, sino por ver una comunidad activa que utiliza el sistema para navegar el mercado con criterio propio y mayor confianza.

## **Conclusiones**

### **Validación de la arquitectura técnica**

Se comprobó que la estructura del sistema funciona correctamente y que puede crecer y adaptarse con el tiempo. El sistema demostró que no es necesario que el usuario vea el código o comprenda el funcionamiento interno para que opere con eficacia. Esta capacidad de abstracción es fundamental para garantizar una experiencia de usuario fluida sin sacrificar la robustez del backend.

### **Impacto en el apoyo a la toma de decisiones**

El cálculo del Índice de Salud Sintética (ISS) ayudó a que las decisiones se basaran menos en opiniones y más en datos concretos. Al combinar los indicadores técnicos con los resultados de la inteligencia artificial, el usuario dispone de una guía clara para determinar los momentos óptimos de entrada o salida del mercado, reduciendo la carga cognitiva y el sesgo emocional.

### **Democratización del acceso financiero**

El proyecto demuestra que cualquier persona, y no solo los grandes bancos o instituciones financieras, puede tener acceso a herramientas de análisis profesional. El uso de tecnologías de acceso abierto y plataformas como Telegram permitió simplificar el acceso a la tecnología, facilitando el camino para quienes apenas están aprendiendo sobre inversiones.

### **Visión a futuro y escalabilidad**

Este desarrollo representa solo el comienzo de lo que el sistema puede llegar a ofrecer en el futuro. La estructura del software permite conectar más fuentes de datos y facilitar la migración hacia una plataforma web, garantizando que el sistema pueda seguir creciendo de forma autónoma.

Lo más importante para el éxito del proyecto es que el usuario siempre comprenda la información presentada y que el entorno le resulte intuitivo. Finalmente, se espera que esta herramienta ayude a quienes buscan proteger su dinero basándose en datos reales y no en suposiciones.

### Referencias bibliográficas

- Araci, D. (2019). FinBERT: Financial Sentiment Analysis with Pre-trained Language Models. *arXiv preprint arXiv:1908.10063*. <https://doi.org/10.48550/arXiv.1908.10063>
- Coulouris, G., Dollimore, J., Kindberg, T., & Blair, G. (2011). *Distributed Systems: Concepts and Design* (5th ed.). Addison-Wesley.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *arXiv preprint arXiv:1810.04805*. <https://doi.org/10.48550/arXiv.1810.04805>
- Feldman, R., & Sanger, J. (2007). *The text mining handbook: advanced approaches in analyzing unstructured data*. Cambridge University Press.
- Hasbrouck, J. (2007). *Empirical Market Microstructure: The Institutions, Economics, and Econometrics of Securities Trading*. Oxford University Press.
- Jurafsky, D., & Martin, J. H. (2023). *Speech and Language Processing* (3rd ed. draft). Stanford University.
- McTear, M., Callejas, Z., & Griol, D. (2016). *The conversational interface: Talking to smart devices*. Springer.
- Mell, P., & Grance, T. (2011). The NIST definition of cloud computing. *National Institute of Standards and Technology*. <https://doi.org/10.6028/NIST.SP.800-145>
- Mishev, K., Gjorgjevikj, A., Vodenska, I., Chitkushev, L. T., & Trajanov, D. (2020). Evaluation of sentiment analysis in finance: From lexicons to transformers. *IEEE Access*, 8, 131662-131682. <https://doi.org/10.1109/ACCESS.2020.3009626>
- Murphy, J. J. (1999). *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. New York Institute of Finance.
- Ozbayoglu, A. M., Gudelek, M. U., & Sezer, O. B. (2020). Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, 106384. <https://doi.org/10.1016/j.asoc.2020.106384>

Power, D. J. (2002). *Decision support systems: Concepts and resources for managers*. Greenwood Publishing Group.

Stallings, W. (2017). *Cryptography and network security: Principles and practice* (7th ed.). Pearson.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.

Wilder, J. W. (1978). *New concepts in technical trading systems*. Trend Research.

Yang, Y., Zhang, X., & Lee, J. (2022). Democratizing AI in financial services: User experience and adoption. *Journal of Financial Technology*, 14(2), 45-62.