

El uso de *machine learning* PARA FINANZAS

MARCELO RONDOY*

En este artículo se resalta la creciente popularidad del aprendizaje automático (ML) en el estudio de las finanzas, destacando sus aplicaciones para interpretar mercados y predecir variables a partir de grandes volúmenes de datos. Se resalta la eficacia de los algoritmos de procesamiento de lenguaje natural (NLP) para analizar datos no estructurados, lo que ofrece perspectivas valiosas sobre tendencias de mercado, gestión de riesgos, y estrategias de inversión.



* Especialista, Departamento de Gestión de Portafolios Líquidos

marcelo.rondoy@bcrp.gob.pe

INTRODUCCIÓN

El análisis financiero experimenta una revolución, catalizada por las herramientas del aprendizaje automático (*machine learning*, ML), una rama de la inteligencia artificial. En este campo de las finanzas, los algoritmos de ML cobran cada vez mayor relevancia para descifrar las condiciones de mercado, predecir variables económicas y optimizar estrategias de inversión, aprovechando grandes volúmenes de datos.

Los mercados destacan por reaccionar frecuentemente a la información difundida a través de redes sociales, artículos periodísticos y las opiniones o discursos de personalidades influyentes. La industria financiera muestra un creciente interés en este tipo de fuentes de datos alternativas que difieren significativamente de las fuentes de información tradicionales, tales como precios de acciones, indicadores macroeconómicos y ratios financieros. Estos datos alternativos, frecuentemente no numéricos y no estructurados, presentan retos estadísticos singulares.

En el caso de los algoritmos de ML, particularmente aquellos dedicados al procesamiento de lenguaje natural (NLP, según sus siglas en inglés), estos resultan eficientes en el análisis de estas fuentes, ofreciendo perspectivas significativas sobre las tendencias del mercado, la gestión de riesgos y las oportunidades de inversión. En efecto, la literatura evidencia un creciente interés en las aplicaciones del aprendizaje automático en el ámbito financiero. En el Gráfico 1 se muestra la evolución del número de artículos académicos publicados desde el año 2000 hasta la actualidad. Los filtros y criterios para contabilizar las publicaciones se basaron en los propuestos por Goodell et al. (2021)¹.

MACHINE LEARNING PARA EL ANÁLISIS DE DATOS

La inteligencia artificial (IA) se basa en la premisa de que cualquier aspecto del aprendizaje humano puede



En este campo de las finanzas, los algoritmos de ML cobran cada vez mayor relevancia **para descifrar las condiciones de mercado, predecir variables económicas y optimizar estrategias de inversión, aprovechando grandes volúmenes de datos.**



ser descrito con suficiente precisión para ser eventualmente emulado por máquinas (McCarthy et al., 2006). Con el pasar de los años, la IA ha evolucionado hacia un campo de investigación dedicado a permitir que las máquinas manejen problemas complejos que anteriormente eran reservados solo para los humanos.

En específico, el ML es una manifestación concreta de que la IA desarrolla técnicas que permiten a las máquinas, mediante algoritmos, reconocer patrones

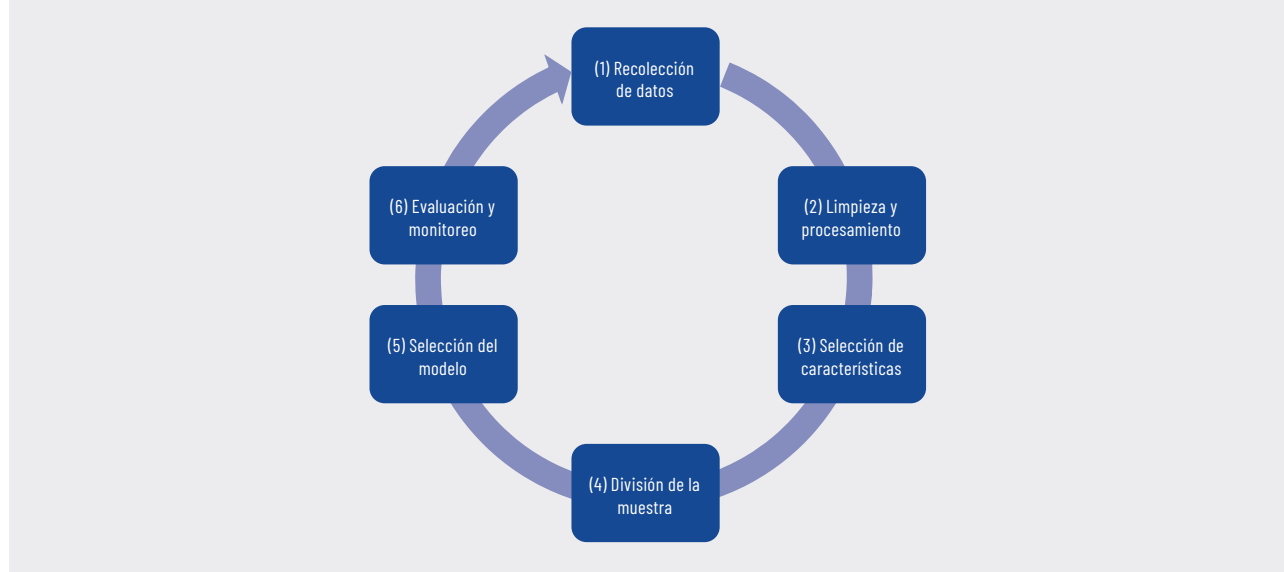
GRÁFICO 1 ■ Evolución del número de publicaciones académicas de ML en finanzas



NOTA: ELABORADO A PARTIR DE LA METODOLOGÍA USADA POR GOODELL ET AL. (2021).

1 Se limitó la búsqueda a revistas académicas Q1/Q2 dentro de las categorías de *Economics, Econometrics and Finance; Social Sciences; y Business, Management and Accounting*.

GRÁFICO 2 ■ Pasos para el análisis de datos usando ML



en un conjunto de datos. Esto ha revolucionado el enfoque con el que se procesan, analizan y formulan predicciones. Históricamente, el análisis financiero se basaba en gran medida en datos numéricos, pero con el crecimiento de las fuentes de datos digitales, ha habido un cambio de paradigma hacia el análisis de otros tipos de datos.

El Gráfico 2 muestra el procedimiento que emplea el ML para el análisis de datos. El caso más representativo de las ventajas de estos algoritmos puede ser el uso de datos de texto. Por ejemplo, para una empresa que va a desarrollar un nuevo e innovador producto le resultaría útil tener un modelo capaz de reconocer patrones que indiquen si es que la información publicada en relación con ese nuevo producto es, en promedio, favorable o desfavorable.

El primer paso es **la recolección de datos**. En este caso consistirá en recopilar fuentes de información (noticias, publicaciones en redes sociales, reportes financieros, minutas, etc.). Incluso las declaraciones o comentarios del CEO de la empresa pueden impactar en el precio de la acción. Por ejemplo, "La empresa anuncia un nuevo e innovador Smartphone con Tecnología 5G, ¡y espera que aumenten sus ventas significativamente!" es un encabezado potencialmente relevante.

El siguiente paso corresponde al **procesamiento de los datos**, para lo cual se realiza una **limpieza del texto** (*data cleansing*), donde se eliminan caracteres especiales (signos de exclamación o espacios en blanco) u otros que no brinden información útil (*stop words* como "la", "y"). Las técnicas de NLP como la tokenización y derivación permiten estructurar textos. La tokenización consiste en dividir el encabezado en palabras (*tokens*), mientras que la derivación las reduce a su forma base ("innovador" deriva de "innovar"). Si dos o más palabras tienen un significado

conjunto y el orden importa, deberían ser consideradas como un solo *token* (denominados *n-grams*). Por ejemplo, "aumentar" y "ventas" dan información más precisa al estar juntas: "aumentar_ventas". De este modo, el encabezado original se ha descompuesto en sus elementos clave: "innovar", "smartphone", "5G", "aumentar_ventas". Este proceso se replica para cada texto dentro de la base de datos (donde cada documento es una observación).

El tercer paso es la **selección de características** (*feature selection*). Esta implica convertir datos "crudos" en un formato más adecuado que los modelos puedan interpretar y utilizar. Uno de los métodos más usados en este contexto es el TF-IDF (*term frequency – inverse document frequency*), que combina dos métricas:

- **Frecuencia de término (TF):** mide la relevancia de un *token* "i" en un documento "j".
- **Frecuencia inversa de documento (IDF):** evalúa la importancia del *token* "i" en el total de documentos (N).

$$TF_{(i,j)} = \frac{\# \text{ Ocurrencias del token "i" en la obs. "j" }}{\text{Cantidad total de token en las obs. "j"}}$$

$$IDF_{(i)} = \text{Log} \left(\frac{N}{\text{Cantidad de obs. que contienen el token "i"}} \right)$$

$$TF-IDF_{(i,j)} = TF_{(i,j)} * IDF_{(i)}$$

El TF-IDF transforma el texto en una matriz en la que cada fila representa una observación y cada columna representa un *token*. Los valores de TF-IDF indican la relevancia de cada palabra para cada documento, dando menos peso a las palabras comunes y más a las palabras distintivas. Esta representación es

extremadamente útil, ya que permite a los modelos de aprendizaje automático identificar y utilizar las características más significativas de los datos de texto.

El cuarto paso involucra **segmentar la muestra** en dos subconjuntos. Por un lado, la muestra de entrenamiento (*training sample*) se utiliza para enseñar al modelo. Es aquí donde el modelo aprende a identificar patrones, correlaciones y tendencias en los datos, a partir de los cuales luego podrá ajustar sus parámetros y minimizar el error entre las predicciones². Por otro lado, la muestra de prueba (*test sample*) ofrece una evaluación final y objetiva del rendimiento del modelo. Esta etapa es importante para evaluar el desempeño de nuestro modelo para datos nuevos (*out-of-sample*). Es crucial que el modelo no haya tenido acceso a estos datos durante las fases de entrenamiento y validación. En nuestro ejemplo, la muestra de entrenamiento se puede componer de noticias publicadas desde 2020 hasta 2022 y, una vez desarrollado el modelo, se puede evaluar sus predicciones usando datos nuevos a partir de 2022.

Después, se procede con la **elección del modelo**. Una técnica popular es la de máquina de vectores de soporte (*Support Vector Machines, SVM*), útil para clasificar textos en categorías (*bullish* o *bearish*, *hawkish* o *dovish*, etc.). En este caso, el SVM puede dividir la información en categorías como buenas o malas, y se espera que noticias clasificadas como buenas (malas) tengan un impacto positivo (negativo) en los precios. El Cuadro 1 muestra un ejemplo de clasificación automática de textos.

Finalmente, existen distintas métricas para **evaluar el desempeño de los modelos de ML** (CFA Institute, 2023). Algunas métricas a considerar son:

- **Precisión (*precision*)**. De todos los textos clasificados como positivos, ¿cuántos son realmente positivos? Minimiza los falsos positivos (error tipo I).
- **Sensibilidad (*recall*)**. De todos los textos realmente positivos, ¿cuántos se identificaron correctamente? Minimiza los falsos negativos (error tipo II).
- **Exactitud (*accuracy*)**. Proporción total de predicciones correctas que se emplea cuando las categorías son equilibradas. Por ejemplo, la proporción de noticias positivas y negativas en toda la muestra es aproximadamente la misma.

En este último paso también es importante **monitorear y actualizar constantemente el modelo** para adaptarse a nuevas condiciones de mercado y datos. Conforme pase el tiempo, los datos nuevos pasarán a formar parte de la muestra de entrenamiento, lo que permitirá que el modelo incorpore esa información, aprenda, ajuste sus parámetros y, últimamente, mejore sus predicciones futuras.

MACHINE LEARNING EN LA LITERATURA FINANCIERA

Los algoritmos de ML permiten un análisis más completo y rápido, lo que resulta útil especialmente en mercados volátiles, donde mantenerse al tanto de las tendencias puede marcar una diferencia significativa. El campo de investigación del ML está enfocado en sus aplicaciones al análisis técnico y fundamental (Nti et al., 2019), predicciones macroeconómicas (Kurihara y Fukushima, 2019), análisis de sentimiento (Bollen et al., 2011), entre otros. El Gráfico 3 muestra los en-

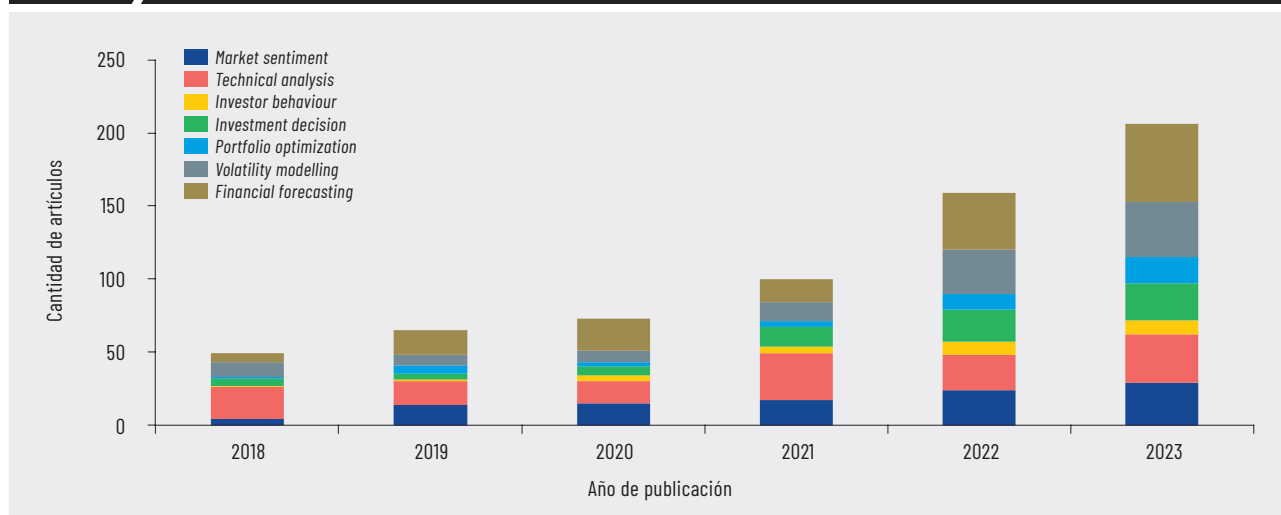
CUADRO 1 ■ Ejemplos de clasificación automática del sentimiento de textos

Sentence	Sentiment
Profit before taxes decreased by 9% to EUR 187,8 mn in the first nine months of 2008, compared to EUR 207.1 mn a year earlier.	negative
Profit before taxes decreased to EUR 31.6 mn from EUR 50.0 mn the year before.	negative
Profit before taxes was EUR 4,0 mn, down from EUR 4.9 mn.	negative
The company's profit before taxes fell to EUR 21.1 mn in the third quarter of 2008, compared to EUR 35.8 mn in the corresponding period in 2007.	negative
In August-October 2010, the company's result before taxes totalled EUR 9.6 mn, up from EUR 0.5 mn in the corresponding period in 2009.	positive
Finnish Bore that is owned by the Rettig family has grown recently through the acquisition of smaller shipping companies.	positive
The plan is estimated to generate some EUR 5 million (USD 6.5 m) in cost savings on an annual basis.	positive
Finnish pharmaceuticals company Orion reports profit before taxes of EUR 70.0 mn in the third quarter of 2010 up from EUR 54,9 mn in the corresponding period in 2009.	positive
Finnish Sampo Bank, of Danish Danske Bank group, reports profit before taxes of EUR 152.3 mn in 2010, up from EUR 32.7 mn in 2009.	positive

FUENTE: CFA INSTITUTE (2023).

² También se puede definir una submuestra de validación, que ayuda a prevenir el problema de sobreajuste (*overfitting*) a los datos de entrenamiento, que ocurre cuando un modelo se ajusta demasiado a los datos de entrenamiento y no generaliza bien nuevos datos.

GRÁFICO 3 ■ Enfoques de investigación más frecuentes del ML en finanzas



NOTA: ELABORADO A PARTIR DE LA METODOLOGÍA USADA POR GOODELL ET AL. (2021).

foques de investigación más prolíficos en este campo, al igual que su evolución en los últimos años.

El análisis de sentimiento implica la identificación y la medición de estados afectivos (emociones) a partir de fuentes de texto. La economía del comportamiento sugiere que las emociones pueden afectar la toma de decisiones de los agentes, en algunos casos de manera significativa. Bollen et al. (2011) cuantifican el estado de ánimo del mercado, basándose en publicaciones de X (Twitter), y evalúan su correlación con el índice Dow Jones (DJIA). Para su análisis, comparan dos algoritmos³ y hallan que cambios en el sentimiento asociados a un estado de tranquilidad en el mercado predicen los retornos de hasta los siguientes cuatro días con una exactitud del 87,6 por ciento.

En cuanto a los métodos utilizados para evaluar y predecir el comportamiento de los mercados financieros, destacan el análisis técnico y fundamental. El primero se basa en el estudio de los movimientos de precios históricos para identificar patrones, mientras que el segundo, en el valor intrínseco de una empresa al analizar sus fundamentos. Nti et al. (2019) realizaron una revisión sistemática de más de 100 trabajos de investigación donde se emplea alguna aplicación del ML para predecir el mercado de acciones. Sus resultados revelaron que alrededor del 66 por ciento de los documentos revisados se basaron en análisis técnico, mientras que un 11 por ciento lo combinaron también con análisis fundamental. Además, ellos identificaron que los algoritmos más utilizados para predecir el comportamiento del mercado financiero fueron el SVM y las redes neuronales artificiales (*artificial neural networks*, ANN)⁴.

CONCLUSIÓN

El uso del aprendizaje automático representa un cambio significativo en cómo se analizan y se toman decisiones en los mercados financieros. La capacidad de procesar y analizar grandes conjuntos de datos, incluyendo información no estructurada como textos, ha abierto nuevas oportunidades para la predicción y optimización en el ámbito financiero. Con la evolución continua de estas tecnologías, es esencial mantener una actualización constante de los modelos para reflejar las cambiantes dinámicas de los mercados. El futuro del análisis financiero, cada vez más integrado con el ML, promete una comprensión más profunda y una toma de decisiones más informada y efectiva.

REFERENCIAS

- Bollen, J., Mao, H., & Zeng, X. (2011). Twitter mood predicts the stock market. *Journal of computational science*, 2(1), 1-8. <https://doi.org/10.1016/j.jocs.2010.12.007>
- CFA Institute. (2023). Learning Module 7 Big Data Projects. In *CFA Program Curriculum: Level 2, Volume 1* (pp. 275-355).
- Goodell, J. W., Kumar, S., Lim, W. M., & Pattnaik, D. (2021). Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. *Journal of Behavioral and Experimental Finance*, 32, 100577. <https://doi.org/10.1016/j.jbef.2021.100577>
- Kurihara, Y., & Fukushima, A. (2019). AR Model or Machine Learning for Forecasting GDP and Consumer Price for 67 Countries. *Applied Economics and Finance*, 6 (3). <https://doi.org/10.1114/AEF.V6I3.4126>
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the Dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-14. <https://doi.org/10.1609/aimag.v27i4.1904>
- Nti, I., Adekoya, A., & Weyori, B. (2019). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 53, 3007-3057. <https://doi.org/10.1007/s10462-019-09754-z>

3 Estos son OpinionFinder, que divide el sentimiento en optimista y pesimista, y Google-Profile of Mood States (GPOMS), que segmenta los tweets en seis distintas dimensiones de ánimo (tranquilidad, alerta, convicción, vitalidad, amabilidad y felicidad).

4 Modelos computacionales inspirados en la estructura y funcionamiento del cerebro humano. Se utilizan para realizar tareas complejas de reconocimiento de patrones y procesamiento de datos.