

Redes neuronales recurrentes como mecanismo de Gestión de Riesgo en mercados de valores

Recurrent neural networks as a risk management mechanism in markets values

Carlos Andrés Mendoza Bravo¹

Jefferson Agustín Macias Bravo²

Maribel Pérez Pirela. PhD³

Ambrosio Tineo Moya. PhD⁴

¹Estudiante Universidad Técnica de Manabí, Facultad de Ciencias Básicas, Portoviejo – Ecuador, Correo: cmendoza1073@utm.edu.ec, Código Orcid: <https://orcid.org/0009-0002-1345-2308>

²Estudiante Universidad Técnica de Manabí, Facultad de Ciencias Básicas, Portoviejo – Ecuador, Correo: jmacias5287@utm.edu.ec, Código Orcid: <https://orcid.org/0009-0003-5616-408X>

³Docente de la Universidad Técnica de Manabí, Facultad de Ciencias Básicas, Portoviejo – Ecuador, Correo: maribel.perez@utm.edu.ec, Código Orcid: <https://orcid.org/0000-0002-9687-5471>

Docente de la Universidad Técnica de Manabí, Facultad de Ciencias Básicas, Portoviejo – Ecuador, Correo: ambrosio.tineo@utm.edu.ec, Código Orcid: <https://orcid.org/0000-0002-2060-8860>

Contacto: jmacias5287@utm.edu.ec

Recibido: 24-01-2025

Aprobado: 19-04-2025

Resumen

En el presente trabajo se propone la aplicación de las redes neuronales recurrentes, específicamente Long Short-Term Memory (LSTM), para predecir los valores del precio de cierre de las acciones de NVIDIA, utilizando estas predicciones como un mecanismo de gestión de riesgo en los mercados de valores. El modelo incluye la recolección, limpieza y preparación de datos, así como el análisis y la modelización mediante Python. Se analizan los precios de cierre de la acción en los tres últimos años, comparando los resultados obtenidos con la predicción de los dos días siguientes tanto gráfica como analíticamente, utilizando métricas como la raíz de error cuadrático medio (RMSE) y el porcentaje del error absoluto medio (MAPE). Este enfoque resalta la importancia del análisis predictivo como una herramienta clave para la gestión de riesgo.

Palabras clave: Redes neuronales, Python, Mercados de valores, Gestión de riesgo

Abstract

This paper proposes the application of recurrent neural networks, specifically Long Short-Term Memory (LSTM), to predict the closing prices of NVIDIA stocks. These predictions are used as a risk management mechanism in stock markets. The model includes data collection, cleaning, and preparation, as well as analysis and modeling using Python. Closing prices from the past three years are analyzed, and the results are compared with predictions for the following two days, both graphically and analytically, using metrics such as Root Mean Square Error (RMSE) and Mean

Absolute Percentage Error (MAPE). This approach highlights the importance of predictive analysis as a tool for risk management.

Keywords: Neural networks, Python, Stock markets, Risk management.

Introducción

Los Mercados Financieros son entes en los cuales se negocian activos financieros, desempeñando un papel crucial en la economía global al facilitar la transferencia eficiente de fondos (Mishkin & Eakins, 2015). Estos mercados permiten a empresas y gobiernos obtener capital para financiar operaciones y proyectos, al tiempo que ofrecen a los inversores oportunidades para diversificar sus carteras y gestionar riesgos. Dada su alta volatilidad, sus predicciones son inexactas y recurren a problemas no lineales en los cuales interfieren variables externas, capaces de no ser modeladas matemáticamente. Según Kotler y Armstrong (2016), los valores de los activos están determinados por diversos elementos, entre los que destacan los costos asociados a la producción, la demanda del mercado, la competencia existente y las estrategias de marketing implementadas por la empresa.

Se han distinguido algunas métricas capaces de analizar el mercado como indicadores técnicos al momento de realizar operaciones en mercados de valores. Para Murphy (1999), una de las herramientas fundamentales en el trading son los indicadores técnicos puesto que ofrecen datos sobre las tendencias de precios y los patrones del comportamiento del mercado, facilitando que los traders puedan tomar decisiones más estratégicas y fundamentadas. Entre los indicadores se pueden encontrar indicadores de tendencia, indicadores de momento, indicadores de volatilidad, indicadores de volumen e indicadores basados en el precio; ellos desempeñan un papel importante al momento de manejar la gestión de riesgo. Según Smith (2022), los riesgos en el trading abarcan la inestabilidad del mercado, la falta de liquidez y el uso desproporcionado del apalancamiento, factores que pueden ocasionar pérdidas cuantiosas. Por ello, es fundamental que los traders conozcan estos riesgos y empleen estrategias de gestión eficaces para reducir su efecto.

Hull (2012) expone que la gestión del riesgo es un aspecto esencial en el trading que involucra la identificación, la evaluación y la priorización de riesgos, seguida de la asignación de recursos con la intención de reducir, monitorear y controlar la probabilidad y/o el impacto de eventos negativos. Al momento de realizar operaciones en los mercados de valores, usualmente se consideran los siguientes mecanismos para gestionar el riesgo en el mercado: stop loss, el método estándar para limitar las pérdidas; el tamaño de lote que, por lo general, se aconseja invertir solo entre el 1% y el 5% del portafolio; el ratio riesgo/beneficio, importante para no arriesgar de más, dependiendo del beneficio de la operación; y el break even, el método de mover el stop loss a un punto medio, además del apalancamiento.

De acuerdo con Díaz del Río y Peña (2017), el uso de las redes neuronales se ha empleado considerablemente con el propósito de modelar y anticipar las series temporales financieras, como, por ejemplo, el costo de las acciones. En el presente artículo se destaca el uso de redes neuronales recurrentes LSTM (Long Short-Term Memory) en la predicción del valor de cierre de la empresa NVDA (Nvidia); se entrena al modelo de redes neuronales con datos históricos y se muestra una predicción para los próximos dos días.


1.1 Redes Neuronales Artificiales

Las redes neuronales artificiales se basan en el comportamiento biológico, cuyo objetivo es simular, matemáticamente, al comportamiento del sistema de redes neuronales. Según Conti, Simó y Rodríguez (2005), se caracterizan por su topología, el mecanismo de aprendizaje, tipo de asociación realizada entre la información de entrada y salida y la forma de representación de dichas informaciones. Esto se aprecia en la figura 1.1 y en la figura 1.2.

Figura 1.1 Red Neuronal Biológica


<https://www.itsup.edu.ec/sinapsis>





Derechos de autor: <https://cs231n.github.io/neural-networks-1/>

Figura 1.2 Red neuronal artificial



Derechos de autor: <https://cs231n.github.io/neural-networks-1/>

Metodología

Recolección, visualización y preparación de datos

Se recopilan datos históricos desde Yahoo Finance, en el periodo comprendido entre el 03/01/2020 y el 15/05/2024, con un intervalo de un día, y se relacionan con el volumen de negociación, precio de cierre y otros indicadores clave para Nvidia Corporation (NVDA) (Yahoo Finance, 2024). Se utilizan herramientas de limpieza de datos para obtener los valores del precio de cierre de la acción (NVDA) y se realizan visualizaciones del precio de cierre del activo, como se observa en la figura 2.1.

Figura 2.1 Precio de Cierre de (NVDA)



Se realiza una normalización de los datos de la columna de los precios de cierre del activo, escalando los valores entre 0 y 1, siendo este un paso importante para asegurar una convergencia más rápida del modelo de redes neuronales y evitar problemas numéricos. El siguiente paso es la preparación de los datos para entrenar el modelo:

Creación de columnas con los valores futuros de los precios escalados, desplazando tres días hacia arriba.

Obtención de la última secuencia de precios escalados.

Eliminación de filas nulas.

Construcción de secuencias de datos.

Creación de arrays de predicciones.

Conversión a arrays Numpys numéricos.

2.2 Modelo de redes neuronales LSTM

Se inicializa un modelo secuencial, permitiendo agregar capas lineales. El modelo aplicado tiene las siguientes características:

Primera capa LSTM de 1000 unidades.

Segunda capa Dropout, con una tasa del 30% para evitar el sobreajuste.

Primera capa densa con 100 unidades, intermedia para procesar la salida de la segunda capa.

- Segunda capa Dropout con una tasa del 30%.
- Capa de salida densa con una unidad que produce la predicción.


Configuración del modelo:

- Se define la función pérdida como el error cuadrático medio.
- Se utiliza el optimizador “Adam” para ajustar el peso del modelo durante el entrenamiento.
- Se entrena el modelo con un tamaño de lote de 8 unidades y un total de 100 épocas.

Resultados y Discusión

El entrenamiento del modelo de redes neuronales en el intervalo seleccionado, se observa en la figura 3.1. Se obtiene un coeficiente de determinación de 0.967 (R-cuadrado), indicando un buen ajuste entre los datos entrenados por el modelo y el precio de cierre real de la acción.


Figura 3.1 Precio real de cierre de NVDA vs Entrenamiento del Modelo



Otro mecanismo para medir el error es mediante la función de pérdida del modelo, definido como el error cuadrático medio, la cual, al momento de realizar el entrenamiento de redes neuronales, es la función objetivo a minimizar. Al finalizar las 100 épocas de entrenamiento, se obtiene un


error de 0.0006, demostrando un gran ajuste entre los precios reales de cierre de la acción y el modelo planteado. Además, en la figura 3.2 se puede apreciar el cambio del error a través de las épocas de entrenamiento del modelo.

Figura 3.2 Progreso del entrenamiento



El modelo predice los dos días posteriores al entrenamiento del precio de cierre: 15 y 16 de mayo de 2024 [\$93.12, \$91.97]. Además, se realiza una comparación con los valores reales para dichas fechas [\$94.63, \$94.36], como se aprecia en la figura 3.3.

Figura 3.3 Precios Reales de Cierre vs Predicción



En la figura 3.3 se grafica el precio de cierre de la acción Nvidia para el día 14 de mayo de 2024, el cual es de \$91.36. A partir de este dato se relacionan las predicciones de los valores de cierre con los valores reales, notando una tendencia alcista en ambos precios de cierre y, luego, una bajista en el segundo día, apreciando un mayor descenso en el precio de cierre predicho que en el real, obteniendo el valor de la raíz del error cuadrático medio: 1.999, lo que indica que los precios varían aproximadamente en dos unidades monetarias. Asimismo, se considera el porcentaje del error absoluto medio de 2.06 %, lo que refleja que los valores predichos por el modelo difieren en un 2.06% de los valores reales de precio de cierre, lo que indica una comparación precisa entre ambos.

Sumado a los indicadores de tendencia, indicadores de momento, indicadores de volatilidad, indicadores de volumen e indicadores basados en el precio, el método presentado ofrece un mayor campo de alcance analítico, mejorando así la manera en cómo se gestiona el riesgo en el trading, ofreciendo mecanismos basados en inteligencia artificial.

Conclusiones

El modelo planteado se considera un mecanismo efectivo para la detección de posibles riesgos. Aunque no establece pronósticos exactos debido al alto nivel de volatilidad en los mercados de valores, el uso de algoritmos de redes neuronales mejora significativamente la probabilidad de predecir tendencias y contribuye al desarrollo de una técnica de detección de riesgos más precisa. El uso de indicadores técnicos, junto con estos algoritmos, permite un análisis integral con el objetivo de minimizar el riesgo al interactuar en los mercados financieros.

El avance constante de la tecnología ha traído innovaciones en todos los campos y la inteligencia artificial no es la excepción. Esto también ha generado mayores exigencias a nivel computacional, especialmente en el uso de procesadores como tarjetas gráficas. Las limitaciones del modelo presentado están relacionadas con el poder de procesamiento disponible. Para mejorar el modelo, se recomienda entrenar más neuronas y aumentar la cantidad de capas, lo que refuerza la importancia del uso de tarjetas gráficas o unidades de procesamiento que pueden manejar múltiples operaciones de manera simultánea. Las redes neuronales requieren cálculos paralelos, y una mayor capacidad de procesamiento optimiza su rendimiento. Además, se mostró cómo ha crecido en los últimos años la empresa encargada de la fabricación de estos componentes (Nvidia), debido a su relevancia en el campo de la inteligencia artificial. Para futuros proyectos, se sugiere entrenar una mayor cantidad de datos, aumentar el número de capas y el número de neuronas por capa, con la expectativa de obtener un mejor ajuste entre los valores reales y los valores predichos por el modelo.

Bibliografía

1. Conti, D., Simó, C. & Rodríguez A. (2005). Teoría de carteras de inversión para la diversificación del riesgo: enfoque clásico y uso de redes neuronales artificiales (RNA). *Ciencia e Ingeniería*, 26(1), 35-42
2. Díaz del Río, F. & Peña, J. I. (2017). Redes neuronales artificiales en finanzas. En M. A.
3. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
4. Hull, J. C. (2012). *Risk Management and Financial Institutions*. John Wiley & Sons.
5. Kotler, P., & Armstrong, G. (2016). *Principios de marketing* (16a ed.). Pearson Educación. p. 324.
6. Mishkin, F. S., & Eakins, S. G. (2015). *Financial Markets and Institutions*. Pearson.
7. Murphy, J. J. (1999). *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. New York Institute of Finance.
8. Smith, J. (2022). Factores de riesgo en el trading financiero. *Journal of Financial Markets*, 34(2), 40-55.