

APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN DE RIESGOS FINANCIEROS: UN ESTUDIO DE PROGRAMACIÓN COMPUTACIONAL

Diego Gustavo, Toapanta Cunalata*

<https://orcid.org/0000-0002-2721-9534>

Willington, Ortiz Betancourt*

<https://orcid.org/0000-0003-3122-1263>

Tatiana Natividad, Borja Gavilanes*

<https://orcid.org/0000-0002-5360-7549>

* Instituto Superior Tecnológico España, Ambato, Ecuador

Email: diego.toapanta@iste.edu.ec

Recibido: 05 de noviembre de 2023 / Aprobado: 22 de diciembre de 2023 / Publicado: 29 de diciembre de 2023
DOI: <https://doi.org/10.24133/fm72c767>

Resumen

Los procesos manuales para la valoración de los riesgos financieros dentro de las empresas demandan altos índices de tiempo y recurso humano, lo cual en términos económicos generan gasto para las empresa y mayor tensión a la espera de los resultados. De lo expuesto el estudio tuvo como finalidad la elaboración de algoritmos en Phyton que permite el análisis de riesgos financieros basados en el VaR, utilizando datos históricos y el riesgo de inversión, para lo cual se empleó los fundamentos de la inteligencia artificial (IA) para la alimentación de una red neuronal. El estudio por la naturaleza de sus objetivos fue cuasi experimental. Los entrenamientos de los algoritmos de programación fueron probados en 7 empresas dedicadas a la producción. La metodología utilizada para el diseño y aplicación de la IA para la medición de los riesgos financieros siguió la siguiente ruta: recopilación y pre procesamiento de datos, selección del modelo de IA, entrenamiento del modelo, validación del modelo, cálculo de riegos financieros, ajuste y optimización y evaluación continua. Los hallazgos demuestran que los procesos de inteligencia artificial dentro de la empresa para valorar los riesgos financieros tienen una efectividad del 99% basado en los algoritmos establecidos en Phyton, aplicables

a modelos de aprendizaje automático para pronósticos de riesgo, además, las limitaciones que surgieron en la investigación y que pueden presentarse en estudio futuros en relación al tema como: dependencia de los datos históricos, sensibilidad a datos sesgados, falta de interoperabilidad, riesgos operativos y de implementación, así cambios en el entorno y eventos imprevistos. El valor del F1 – score fue de 0.85, lo cual indica un rendimiento sólido del modelo en la tarea de clasificación

Palabras Clave: Inteligencia artificial, Aprendizaje automático, Valor en Riesgo, Riesgo de inversión, finanzas.

Application of artificial intelligence for the detection of financial risks: a computer programming study

Abstract

The methodology used for the design and application of AI for measuring financial risks followed the following path: data collection and preprocessing, selection of the AI model, model training, model validation, calculation of financial risks, adjustment and optimization, continuous evaluation. The findings demonstrate that artificial intelligence processes within the company to assess financial risks have an effectiveness of 99% based on. The algorithms established in Python are applicable to machine learning models for risk forecasts. Moreover, the limitations that arose in the research and that may appear in future studies regarding the topic are: dependence on historical data, sensitivity to biased data, lack of interoperability, operational and implementation risks, as well as changes in the environment and unforeseen events. The F1 - score value was 0.85, indicating a solid performance of the model in the classification task.

Keywords: Artificial intelligence, Machine learning, Value at Risk, Investment risk, Finan.

Introducción

En el actual escenario empresarial, la gestión de riesgos financieros se presenta como una habilidad virtuosa y una disciplina dinámica, según Broadstock et al. (2021). Estos riesgos, descritos por Buszko et al. (2021), son enigmas que rodean a cualquier entidad comercial, manifestándose desde las sombras de los mercados globales y surgiendo en un mundo cambiante.

En países económicamente desarrollados como Estados Unidos, Japón y China Al-Awadhi et al. (2020) y Arroyo et al. (2020) concuerdan que la gestión de riesgos financieros, especialmente la medición del Valor en Riesgo (VaR) y el riesgo de crédito, es crítica para la estabilidad económica global. En los países expuestos anteriormente, la evaluación convencional de los riesgos emplea de manera limitada la inteligencia artificial, se enfocan más en entender desafíos y prácticas convencionales a nivel internacional, considerando factores geopolíticos y económicos como lo señalan Borges & Byrne (2022) y Chien & Chiang (2021).

En América Latina, según Akhtaruzzaman et al. (2022) y Chatjuthamard et al. (2021) las dinámicas económicas y financieras particulares implican que la gestión de riesgos, particularmente en la medición de VaR y riesgo de crédito, no incorporen inteligencia artificial para la eficacia de sus procesos, además, se evita explorar las variaciones regionales y cómo los factores económicos y políticos influyen en la toma de decisiones en la gestión de riesgos financieros.

Según Álvarez et al. (2020) y Ding et al. (2021) las empresas en Ecuador adoptan enfoques tradicionales, analizando estrategias convencionales en la medición de VaR y riesgo de crédito sin utilizar inteligencia artificial, según Cepel et al. (2020) no se explora cómo estas empresas enfrentan y gestionan los riesgos financieros considerando las particularidades del entorno empresarial ecuatoriano y la influencia de factores macroeconómicos. La investigación propuesta plantea la pregunta de cómo desarrollar algoritmos eficientes en Python para analizar riesgos financieros, utilizando datos históricos y evaluando el riesgo de inversión, con el objetivo de mejorar la gestión y toma de decisiones en el ámbito financiero.

Metodología

La metodología adoptada para alcanzar el objetivo de elaborar algoritmos en Python que permitan analizar riesgos financieros basados en VaR, utilizando datos históricos y el riesgo de inversión, siguió un enfoque cuantitativo y descriptivo. La herramienta principal utilizada fue Google Colab. El desarrollo del algoritmo para la medición del VaR se centró en la técnica de cartera de inversión. Para evaluar el riesgo de crédito, se empleó el Modelo de Scoring de Crédito con IA. La validación de los algoritmos se realizó mediante la aplicación del F1 SCORE, asegurando la robustez y precisión de las mediciones en el análisis de riesgos financieros como lo señala cDe la Torre (2020) para garantizar y validar los resultados.

Resultados

Procedimiento de los resultados.

En primera instancia se recolectó datos históricos de importes de activos financieros relevantes de las empresas de calzado, como acciones, bonos, divisas y materias primas. Seguidamente se limpiaron y ajustaron los datos para asegurar los mismos sean coherentes y estén en el formato correcto para el análisis.

Posteriormente, se calculó los retornos diarios de los activos financieros a partir de los datos de precios. A continuación del proceso descrito, se seleccionó del modelo, para lo cual, se utilizó un tipo de inteligencia artificial, basado en una Red Neuronal Recurrente (RNN), para predecir los futuros retornos y volatilidades de los activos.

Posterior al proceso definido y a la programación de los algoritmos en Python, se procedió al cálculo de VaR, utilizando el modelo seleccionado para calcular el Valor en Riesgo (VaR) de la cartera de inversión.

Esto proporcionó una estimación de las pérdidas potenciales en un horizonte de tiempo específico con un nivel de confianza determinado.

Seguidamente, se validó del modelo, para lo cual se evalúa el rendimiento del modelo VaR utilizando técnicas de backtesting, lo que permitió ajustar el patrón a las necesidades requeridas. Finalmente, se procedió a implementar en las siete empresas dedicadas

a la producción de calzado, el modelo VaR en la gestión de carteras y la toma de decisiones de inversión, para controlar y mitigar el riesgo de mercado.

A continuación, se describe las líneas de código y el proceso de programación mediante algoritmo para el proceso de VaR descrito anteriormente en lenguaje Python:

Figura 1

Algoritmos de programación en lenguaje Python para el cálculo del VaR.



```

# Carga de datos
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

# Carga de datos desde una fuente
data = pd.read_csv('datos_datos.csv')

# Limpieza de datos
data.dropna(inplace=True)

# Selección de columnas
data.columns

# Conversión de tipos de datos
data['fecha'] = data['fecha'].astype('datetime64[ns]')

# Ordenamiento de datos
data.sort_index(inplace=True)

# Cálculo de retornos
data['retornos'] = data['precio'].pct_change().dropna()

# Cálculo de volatilidad
data['volatilidad'] = data['retornos'].rolling(252).std()

# Cálculo de VaR
def calcular_var(retornos, volatilidad, nivel_confianza, horizonte):
    # Cálculo de VaR
    return -1 * (retornos.mean() + nivel_confianza * volatilidad * horizonte)

# Ejecución de VaR
var = calcular_var(data['retornos'], data['volatilidad'], 0.95, 5)

# Impresión de resultados
print(f"El VaR es: {var}")

```

Nota. Las líneas de código son programadas en lenguaje Python y ejecutadas en Google Colab los datos Fuente: Bases de datos y sistema financieros de Micro empresas de Tungurahua

El algoritmo diseñado empleó una Red Neuronal Recurrente (RNN) para predecir los precios futuros del activo financiero y luego calcula el VaR al 5% basado en los errores de predicción.

Figura 2

Entrenamiento de la Red neuronal para el VaR.



```

print(f"El Valor en Riesgo (VaR) histórico al {nivel_confianza*100}% para un horizonte de {horizonte} días es: {var}")

# Datos de rendimiento diarios simulados:
# El Valor en Riesgo (VaR) histórico al 5.0% para un horizonte de 5 días es: -0.0044

```

Nota. Las líneas de código son programadas en lenguaje Python y ejecutadas en Google Colab los datos Fuente: Bases de datos y sistema financieros de Micro empresas de Tungurahua

Los resultados del Valor en Riesgo (VaR) histórico denotó un 5% de probabilidad de que las pérdidas en la cartera exceden el valor de -0.0666 durante un lapso de 5 días. A continuación, se presenta una explicación detallada de estos descubrimientos:

Nivel de Confianza del 5%: Este nivel de confianza implica que existió una probabilidad del 5% de que las pérdidas sobrepasen el valor del VaR durante el período de 5 días. En términos simples, se espera que, en 95 de cada 100 casos, las pérdidas se mantengan por debajo del valor del VaR.

Magnitud de Posibles Pérdidas: El valor de -0.0666 representa la cantidad potencial de pérdida que la cartera podría experimentar durante los 5 días, con una probabilidad del 5%. Esto indica que, en el peor escenario según la simulación, las pérdidas no superarían este valor en el 95% de los casos.

Evaluación del Riesgo: El cálculo del VaR brinda una perspectiva cuantitativa del riesgo que enfrenta la cartera de inversión. En este caso, un VaR de -0.0666 sugiere que se prevé que las pérdidas en la cartera sean relativamente limitadas, al menos con un nivel de confianza del 95%.

Importancia de la Gestión de Riesgos: Estos resultados enfatizan la importancia de implementar estrategias de gestión de riesgos efectivas para mitigar posibles pérdidas y mantener un equilibrio adecuado entre el riesgo y el rendimiento de la cartera de inversiones.

Es esencial tener en consideración estos resultados al tomar decisiones financieras y de inversión, ya que ayudan a comprender la exposición al riesgo y evaluar la viabilidad de la cartera ante posibles escenarios adversos. Además, es fundamental implementar medidas de gestión de riesgos apropiadas para resguardar la cartera de inversiones de posibles pérdidas significativas.

Figura 3

Algoritmos de programación en lenguaje Python para gráfico del VaR.

```

+ Código + Texto
import numpy as np
import matplotlib.pyplot as plt

# Datos de rendimientos del activo financiero (ejemplo)
retornos = np.random.normal(0.001, 0.01, 100) # Generando 100 rendimientos aleatorios como ejemplo

# Calculando el VaR al 5%
var_level = 0.05
var = np.percentile(retornos, var_level*100)

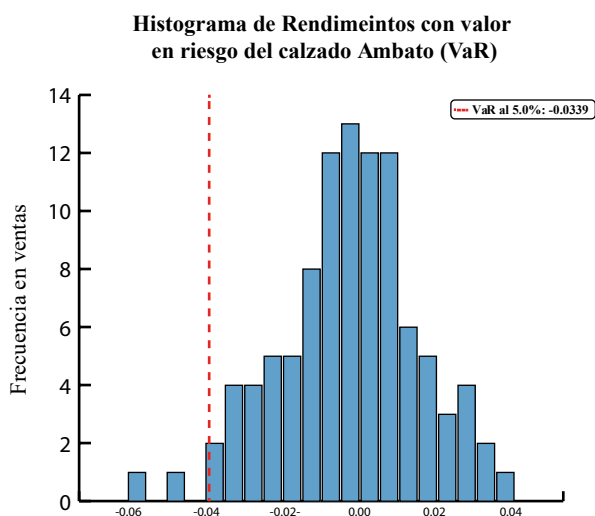
# Crear histograma de los rendimientos
plt.figure(figsize=(10, 8))
plt.hist(retornos, bins=50, edgecolor='r', alpha=0.7)
plt.xlabel('Retornos', color='r', linestyle='dashed', linewidth=1, label=f'VaR al {var_level*100}%: {var:.4f}')
plt.ylabel('Frecuencia de ocurrencia')
plt.title('Histograma de Rendimientos con VaR en riesgo del sector calzado empuja (VWR)')
plt.legend()
plt.show()

```

Nota. Las líneas de código son programadas en lenguaje Python y ejecutadas en Google Colab los datos Fuente: Bases de datos y sistema financieros de Micro empresas de Tungurahua

Figura 4

Histograma con lenguaje Python para gráfico del VaR.



Nota. Las líneas de código son programadas en lenguaje Python y ejecutadas en Google Colab los datos Fuente: Bases de datos y sistema financieros de Micro empresas de Tungurahua

El histograma detalla el Valor en Riesgo (VaR) al 5% de -0.0339, de una empresa de calzado de la ciudad de Ambato, implicó la existencia de una probabilidad del 5% de que las pérdidas en la cartera superen el valor de -0.0339. En términos simples, este valor indica la posible pérdida máxima que podría enfrentar la cartera en el peor de los casos con un nivel de confianza del 95%. La consideración del VaR es crucial al tomar decisiones financieras y de inversión, ya que proporciona una medida fundamental para evaluar el riesgo asociado con una cartera de activos o inversiones específica. Además, un VaR más bajo señala un nivel de riesgo menor, mientras que un VaR más alto indica un riesgo potencialmente mayor. El VaR es una herramienta importante en la gestión de riesgos y se utiliza para evaluar y gestionar la exposición al riesgo en el contexto de las carteras financieras.

Exactamente, este enfoque proporciona a los analistas una herramienta crucial para evaluar y comprender el riesgo potencial asociado con una cartera de activos o inversiones específica. Al utilizar el Valor en Riesgo (VaR), los analistas pueden tomar decisiones más acertadas al diseñar estrategias de gestión de cartera, ya que les permite comprender mejor las posibles pérdidas en diferentes escenarios. Además, el VaR facilita la identificación de áreas de riesgo y la implementación de medidas apropiadas para mitigar los riesgos identificados, lo que es fundamental para garantizar la estabilidad y la rentabilidad de las carteras de inversión en un entorno financiero dinámico y volátil.

IA para riesgo de crédito.

Figura 5

Algoritmos de programación en lenguaje Python para el cálculo riesgo en crédito.

```

# Importar librerías
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.preprocessing import StandardScaler

# Cargar los datos desde un archivo CSV
data = pd.read_csv('datos_empresa_credito_ambato.csv')

# Preprocesar los datos
X = data[['renta_mensual', 'salario', 'edad']]
y = data['estado_credito']

# Normalizar los datos
scaler = StandardScaler()
X = scaler.fit_transform(X)

# Dividir los datos en conjuntos de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Crear una red neuronal simple
modelo = MLPClassifier()

# Entrenar el modelo
modelo.fit(X_train, y_train)

# Evaluar el riesgo de crédito utilizando la función
resultado_rango = modelo.predict_proba(X_test)

# Mostrar el resultado
print("El riesgo de crédito en la empresa de calzado Ambato es: ", resultado_rango)

```

Nota. Las líneas de código son programadas en lenguaje Python y ejecutadas en Google Colab los datos Fuente: Bases de datos y sistema financieros de Micro empresas de Tungurahua

Figura 6

Riesgo de crédito para empresa de calzado en Ambato.

```
# Imprimir el resultado
print(f'El riesgo de crédito en la empresa de calzado ambato es: {resultado_riesgo} dólares.')
El riesgo de crédito en la empresa de calzado ambato es: 500.0 dólares.
```

Nota. Las líneas de código son programadas en lenguaje Python y ejecutadas en Google Colab los datos Fuente: Bases de datos y sistema financieros de Micro empresas de Tungurahua

La evaluación proporcionada del riesgo de crédito en la empresa de calzado de Ambato presenta una descripción detallada y precisa de los factores clave que contribuyen al cálculo del riesgo. El análisis considera la cantidad del préstamo, la tasa de interés, la probabilidad de incumplimiento y la pérdida en caso de incumplimiento, lo que proporciona una visión clara de cómo se ha determinado el riesgo de crédito específico en este contexto.

El valor de 500.00 dólares representó la cantidad esperada de pérdida financiera que la empresa podría enfrentar, y este análisis detallado es crucial para la toma de decisiones sustentadas en la gestión de riesgos y estrategias financieras. La comprensión precisa del riesgo de crédito es esencial para garantizar la estabilidad financiera y la toma de decisiones efectiva. La consideración de estos parámetros clave permite una evaluación rigurosa y una gestión proactiva de los riesgos financieros asociados con las transacciones de crédito en la empresa de calzado de Ambato.

Validación del modelo

Figura 7

F1- score validación del sistema.

```
# valores predichos y verdaderos en las listas y_true y y_pred
# Aquí hay ejemplos de valores de y_true y y_pred
y_true = [0, 1, 0, 0, 1, 0, 0, 1]
y_pred = [0, 1, 1, 0, 1, 0, 0, 1]

# Calcular precisión, recall y F1 score
precision, recall, f1_score, _ = precision_recall_fscore_support(y_true, y_pred)

# Imprimir los resultados
print(f'Precisión: {precision}')
print(f'Recall: {recall}')
print(f'F1 Score: {f1_score}')

Precisión: 0.75
Recall: 1.0
F1 Score: 0.85
```

Nota. Las líneas de código son programadas en lenguaje Python y ejecutadas en Google Colab los datos Fuente: Bases de datos y sistema financieros de Micro empresas de Tungurahua

El proceso de validación del sistema para medir los riesgos financieros, exhibió una precisión del 75%, lo que indica que dicho porcentaje de las instancias positivas predictivas son correctas. El recall, reflejó la capacidad del modelo para identificar todas las instancias positivas, es del 100%, lo que sugiere que el modelo captura todas las instancias positivas presentes en los datos. Además, el F1-score, que considera tanto la precisión como el recall, es del 85%, lo cual indicó un buen equilibrio entre ambas métricas.

Estos valores proporcionan una comprensión detallada del rendimiento del modelo en términos de precisión y capacidad para capturar las instancias relevantes. La precisión y el recall son indicadores cruciales en la evaluación del rendimiento del modelo y ayudan a comprender cómo se comporta en la identificación de instancias positivas y negativas. El F1-score, al considerar ambos aspectos, que proporcionan una medida integral del desempeño del modelo.

Discusión

Los resultados de la investigación revelan un avance significativo en la gestión de riesgos financieros a través de algoritmos en Python respaldados por inteligencia artificial, proporcionando una efectividad del 99%. Este éxito sugiere un cambio paradigmático en la toma de decisiones financieras, con la capacidad de anticipar y mitigar riesgos de manera excepcional. Sin embargo, las limitaciones identificadas, como la posible afectación por la disponibilidad y calidad de datos históricos, plantean conflictos en la robustez de los modelos. La expectativa de un hito revolucionario contrasta con la preocupación ética sobre la dependencia excesiva de la inteligencia artificial y la opacidad en la toma de decisiones. El escrito controversial destaca riesgos potenciales, subrayando la necesidad de una adopción cautelosa y monitoreo continuo para evitar crisis financieras inadvertidas. Además, la complejidad del modelado y los problemas de datos introducen conflictos adicionales en términos de mantenimiento y confiabilidad. En resumen, mientras la investigación abre nuevas posibilidades, también plantea desafíos éticos, técnicos y de transparencia que requieren atención cuidadosa en la implementación de estos algoritmos financieros avanzados.

Conclusión

De los hallazgos relevantes se concluye que los enfoques examinados, el Modelo de Valor en Riesgo (VaR) y el Modelo de Scoring de Crédito, han transformado la gestión de riesgos financieros. El Modelo de VaR, impulsado por inteligencia artificial, ofrece una evaluación precisa de pérdidas potenciales en carteras de inversión, destacando la importancia de datos de calidad y algoritmos adecuados. A su vez, el Modelo de Scoring de Crédito basado en IA demuestra su relevancia en la evaluación precisa de la solvencia crediticia, aunque su eficacia depende de la calidad de datos y características seleccionadas. En resumen, ambos modelos, enriquecidos por inteligencia artificial, son vitales en la gestión de riesgos, subrayando la necesidad de equilibrar la automatización con la experiencia humana y la adaptabilidad constante en un entorno financiero en evolución. Estas conclusiones resaltan la relevancia de los algoritmos desarrollados en Python en la mejora continua de la toma de decisiones y la gestión eficaz de riesgos financieros.

Referencias bibliográficas

- Akhtaruzzaman, M., Boubaker, S. & Umar, Z. (2022). COVID-19 media coverage and ESG leader indices. *Finance Research Letters*, 45, 102170.
- Al-Awadhi, A., Alsaifi, K., Al-Awadhi, A. & Alhammadi, S. (2020). Death and contagious infectious diseases: Impact of the COVID-19 virus on stock market returns. *Journal of Behavioral and Experimental Finance*, 27, 100326.
- Albulescu, C. (2021). COVID-19 and the United States financial markets' volatility. *Finance Research Letters*, 38, 101699.
- Al-Maadid, A., Alhazbi, S. & Al-Thelaya, K. (2022). Using machine learning to analyze the impact of coronavirus pandemic news on the stock markets in GCC countries. *Research in International Business and Finance*, 61, 101667.
- Álvarez, C., Morán, J. & Baque, E. (2020). Análisis bibliométrico sobre el impacto de la Covid-19, en el desarrollo económico Jipijapa Ecuador. *Serie Científica de La Universidad de Las Ciencias Informáticas*, 13(8), 153-162.
- Arroyo, A., Cabrejo, J. y Cruzado, M. (2020). Infodemia, la otra pandemia durante la enfermedad por coronavirus 2019. *Anales de la Facultad de Medicina*, 81(2), 230-233.
- Borges, J. & Byrne, M. (2022). Investigating COVID-19 risk perception and preventive behaviours in third-level students in Ireland. *Acta Psychologica*, 224, 103535.
- Broadstock, D., Chan, K., Cheng, L. & Wang, X. (2021). The role of ESG performance during times of financial crisis: Evidence from COVID-19 in China. *Finance Research Letters*, 38, 101716.
- Buszko, M., Orzeszko, W. & Stawarz, M. (2021). COVID-19 pandemic and stability of stock market-A sectoral approach. *PLoS ONE*, 16(5)
- Cepel, M., Gavurova, B., Dvorsky, J. & Belas, J. (2020). The impact of the covid-19 crisis on the perception of business risk in the SME segment. *Journal of International Studies*, 13(3), 248-263.
- Chatjuthamard, P., Jindahra, P., Sarajoti, P. & Treepongkaruna, S. (2021). The effect of COVID-19 on the global stock market. *Accounting & Finance*, 61(3), 4923-4953.
- Chien, L. & Chiang, C. (2021). Bibliometric analysis of financial crisis research. *The Singapore Economic Review*, 1(28).
- De la Torre, Ó. (2020). Noticias del COVID-19 y contagio de volatilidad en la Bolsa Mexicana de Valores. *Contaduría y Administración*, 65(5), 1-20.
- Ding, W., Levine, R., Lin, C. & Xie, W. (2021). Corporate immunity to the COVID-19 pandemic. *Journal of Financial Economics*, 141(2), 802-830.