

DOI: 10.26820/reciamuc/9.(4).diciembre.2025.89-103

URL: <https://reciamuc.com/index.php/RECIAMUC/article/view/1648>

EDITORIAL: Saberes del Conocimiento

REVISTA: RECIAMUC

ISSN: 2588-0748

TIPO DE INVESTIGACIÓN: Artículo de revisión

CÓDIGO UNESCO: 53 Ciencias Económicas

PAGINAS: 89-103



Modelado predictivo del riesgo financiero en empresas de tecnología mediante una plataforma de inteligencia de negocio

Predictive financial risk modeling in technology companies using a business intelligence platform

Modelagem preditiva de risco financeiro em empresas de tecnologia usando uma plataforma de inteligência empresarial

María Jose Trujillo Coloma¹; Erick Orlando Guerrero Zambrano²; Victor Hugo Moreno Díaz³; Mariuxi Ileana Tejada Castro⁴

RECIBIDO: 21/09/2025 **ACEPTADO:** 28/10/2025 **PUBLICADO:** 25/11/2025

1. Especialista Seguridad Informática, Magíster en Seguridad Informática Aplicada; Ingeniera en Sistemas Computacionales; Universidad de Guayaquil; Guayaquil, Ecuador; maria.trujilloc@ug.edu.ec;  <https://orcid.org/0000-0001-8619-224X>
2. Magíster en Comunicación Pública de la Ciencia y la Tecnología; Máster Universitario en Desarrollo del Software; Licenciado en Sistemas de Información; Universidad de Guayaquil, Guayaquil, Ecuador; erick.guerreroz@ug.edu.ec;  <https://orcid.org/0009-0002-4221-2450>
3. Magíster en Sistemas de Información Gerencial; Máster Universitario en Diseño y Desarrollo de Videojuegos; Licenciado en Sistemas de Información; Universidad de Guayaquil; Universidad Católica de Santiago de Guayaquil; Guayaquil, Ecuador; victor.morenod@ug.edu.ec;  <https://orcid.org/0009-0003-1616-5352>
4. Magíster en Gestión y Diseño Web; Ingeniero en Computación e Informática; Universidad de Guayaquil; Guayaquil, Ecuador; johanna.tandazoo@ug.edu.ec;  <https://orcid.org/0000-0002-2814-2479>

CORRESPONDENCIA

María Jose Trujillo Coloma

maria.trujilloc@ug.edu.ec

Guayaquil, Ecuador

RESUMEN

El presente estudio tiene como propósito analizar el desarrollo una plataforma de inteligencia de negocios, orientada en realizar un modelado predictivo del riesgo financiero, que se presenta en empresas del sector tecnológico. Con la aplicación del modelo basado en árboles de decisión, LSTM y ARIMA, se busca reconocer patrones clave en la información financiera de los clientes y los posibles riesgos, a partir de datos históricos y variables relevantes del entorno financiero. Este enfoque tiene como finalidad determinar la situación actual de cada cliente y su incidencia dentro del entorno empresarial. El uso de la plataforma Power BI ofrecerá reportes analíticos en tiempo real permitiendo identificar posibles incidencias financieras y proporcionar evidencias de escenarios futuros, ofreciendo una representación visual clara y precisa de los datos generados, facilitando el monitoreo del desempeño de los clientes. Para ello, se busca optimizar la toma de decisiones en la gestión financiera, mejorando la capacidad de respuesta ante posibles amenazas de tipo financieras y asegurando la estabilidad económica de las empresas tecnológicas. Fortaleciendo su capacidad para incluir indicadores clave de rendimiento (KPIs) relevantes, dirigidos a mejorar la Gestión financiera actual de la empresa, lo que permite una adaptación efectiva a nuevos desafíos dentro de un entorno competitivo.

Palabras clave: Modelo Predictivo, Power BI, Riesgo Financiero, Arboles de decisiones, KPIs.

ABSTRACT

The present study aims to analyze the development of a business intelligence platform designed to perform predictive modeling of financial risk, as it arises in companies in the technology sector. By applying a model based on decision trees, LSTM, and ARIMA, the goal is to identify key patterns in clients' financial information and potential risks, using historical data and relevant variables from the financial environment. This approach seeks to determine each client's current status and their impact within the business environment. The use of the Power BI platform will enable real-time analytical reports that allow the identification of possible financial issues and provide evidence of future scenarios, offering a clear and precise visual representation of the generated data, thus facilitating the monitoring of the clients' performance. In order to do this, the aim is to optimize decision-making in financial management, improve responsiveness to possible financial threats, and ensure the economic stability of technology companies. Furthermore, it will strengthen the company's capability to incorporate relevant Key Performance Indicators (KPIs) focused on improving the current financial management, allowing for effective adaptation to new challenges in a competitive environment.

Keywords: Predictive Modeling, Power BI, Financial Risk, Decision trees, KPIs.

RESUMO

O presente estudo tem como objetivo analisar o desenvolvimento de uma plataforma de inteligência empresarial projetada para realizar modelagem preditiva de risco financeiro, conforme surge em empresas do setor de tecnologia. Ao aplicar um modelo baseado em árvores de decisão, LSTM e ARIMA, o objetivo é identificar padrões-chave nas informações financeiras dos clientes e riscos potenciais, utilizando dados históricos e variáveis relevantes do ambiente financeiro. Essa abordagem busca determinar a situação atual de cada cliente e o seu impacto no ambiente empresarial. O uso da plataforma Power BI permitirá relatórios analíticos em tempo real que possibilitam a identificação de possíveis problemas financeiros e fornecem evidências de cenários futuros, oferecendo uma representação visual clara e precisa dos dados gerados, facilitando assim o monitoramento do desempenho dos clientes. Para isso, o objetivo é otimizar a tomada de decisões na gestão financeira, melhorar a capacidade de resposta a possíveis ameaças financeiras e garantir a estabilidade econômica das empresas de tecnologia. Além disso, reforçará a capacidade da empresa de incorporar indicadores-chave de desempenho (KPI) relevantes, focados na melhoria da gestão financeira atual, permitindo uma adaptação eficaz a novos desafios num ambiente competitivo.

Palavras-chave: Modelagem preditiva, Power BI, Risco financeiro, Árvores de decisão, KPI.

Introducción

El entorno empresarial ha evolucionado a lo largo de los años, hacia un escenario altamente competitivo y dinámico por lo que la gestión del riesgo financiero es un aspecto crítico y un punto clave que debe ser analizado por las empresas tecnológicas. La capacidad de anticiparse y mitigar los riesgos financieros no solo se trata de proteger la estabilidad económica de la organización, sino que promueve un crecimiento sostenible. Dentro de este contexto, la inteligencia de negocios (BI) y el análisis de datos, emerge como una herramienta clave, permitiendo a las empresas recopilar, analizar y visualizar datos relevantes que faciliten la toma de decisiones. Esta investigación se centra en el desarrollo de una plataforma de inteligencia de negocios diseñada en analizar y predecir los riesgos financieros en un entorno empresarial asociado al desarrollo de tecnología.

La Plataforma integra diversas fuentes de datos, aplicando técnicas avanzadas de análisis y modelos predictivos que permitan identificar patrones y tendencias asociadas con el riesgo financiero. Uno de los principales problemas que enfrentan las empresas es la falta de herramientas que permitan al área financiera anticiparse a incidentes relacionados con la gestión financiera, como el manejo de los contratos establecidos con sus clientes. Al no disponer de fórmulas ni gráficos que permitan verificar la fiabilidad de un nuevo cliente, existe el constante riesgo de que puedan ignorar los acuerdos contractuales, perjudicando gravemente a la organización, ya que la empresa usa sus fondos para desarrollar las soluciones tecnológicas solicitadas, y de existir algún incidente o terminación del contrato de manera abrupta, los avances podrían resultar en pérdidas de tiempo y capital invertido. Según Acosta & Horna (2023) el 97% de las pequeñas y medianas empresas (PYMES) expresan su deseo de tener un instrumento, guía o modelo que les facilite la evaluación eficaz de los riesgos financieros a los que

se exponen. Esta demanda proviene de la necesidad de disponer de un sistema que no solo simplifique el estudio de estos riesgos, sino que también les brinde un entendimiento más profundo de la correlación entre las decisiones que adoptan y los posibles escenarios de riesgo.

En este contexto, las empresas presentan ineficiencias en áreas relacionadas con la recopilación de la información necesaria para comenzar a trabajar de manera colaborativa con los diferentes involucrados. Esto se debe a que recogen datos cruciales en hojas de cálculo (Excel) para luego generar gráficos o tablas de valores. Este proceso suele ocasionar una serie de eventualidades como duplicidad en los datos, uso de fórmulas erróneas, mal uso de gráficos o lentitud al mostrar información debido al procesamiento de los grandes volúmenes de datos usados. El propósito de esta investigación es predecir los riesgos financieros recurrentes que enfrentan las empresas, esto se logrará mediante el análisis de datos históricos proporcionados por una empresa ecuatoriana. Esta estrategia abrirá nuevas oportunidades de negocio, permitiendo a las empresas adaptarse rápidamente a las demandas del mercado y posicionarse como líderes innovadores en el desarrollo de Tecnología. Puesto que el riesgo siempre ha sido un factor influyente en el desarrollo de las empresas, y representan desafíos o posibles pérdidas, abarcando la particularidad de enfrentarse a situaciones en desventajas que contengan incertidumbre o perjudiquen los planes a largo plazo, aunque lo que no se toma en cuenta son las posibles oportunidades de mejoras existentes, siempre y cuando su beneficio sea mayor al costo de enfrentarlas (Rodríguez Fajardo, 2022). Considerando este punto, se entiende que los riesgos siempre están presentes en cualquier actividad desarrollada dentro de las organizaciones, ya que pueden existir factores adversos que frustren el cumplimiento adecuado de los objetivos planteados. Debido a este problema,

se ha desarrollado un conjunto de prácticas centradas en gestionar los incidentes recurrentes en las actividades laborales y permitir a los empleadores contar con una base sólida en sus operaciones, entre estos tenemos las matrices de riesgo, enfocadas a establecer el porcentaje de peligrosidad de una situación (Santana Falcón, 2023) -.

Este conjunto de buenas prácticas se conoce como gestión de riesgo, en donde mediante la adopción de políticas y estrategias se busca fortalecer las debilidades de la organización identificar posibles brechas, analizar casos históricos y finalmente mitigar de forma factible aquellos problemas que podrían retrasar o interferir en el desarrollo habitual del plan de trabajo (Techno Review, 2021). Actualmente, se ha observado que el riesgo financiero es el más habitual dentro de las empresas, debido a que esta amenaza principalmente a los activos de la organización (tiempo y dinero) acortando su desarrollo a largo plazo. A esta problemática se le suma la volatilidad del mercado y la competitividad de las demás organizaciones, poniendo en riesgo principalmente las inversiones, fondos o el flujo de la caja. Autores como (Vaca & Orellana, 2020) consideran que los riesgos financieros son aquellas incertidumbres que influyen en el correcto desempeño financiero de una institución.

Herramientas para mitigar el riesgo financiero

Riesgo financiero en empresas: El riesgo siempre ha sido un factor influyente en el desarrollo de las empresas, ya que representar desafíos o posibles pérdidas, abarcando la particularidad de enfrentarse a situaciones en desventajas que contengan incertidumbre o perjudiquen los planes a largo plazo, aunque lo que no se toma en cuenta son las posibles oportunidades de mejoras existentes, siempre y cuando su beneficio sea mayor al costo de enfrentarlas (Rodríguez Fajardo, 2022).

Considerando este punto, se entiende que los riesgos siempre están presentes en cualquier actividad desarrollada dentro de las organizaciones, ya que pueden existir factores adversos que frustren el cumplimiento adecuado de los objetivos planteados. Debido a este problema, se propone desarrollar un conjunto de prácticas centradas en gestionar los incidentes recurrentes en las actividades laborales y permitir a los empleadores contar con una base sólida en sus operaciones, entre estos tenemos las matrices de riesgo, enfocadas a establecer el porcentaje de peligrosidad de una situación.

Matriz de tolerancia al riesgo: Se encuentra estructurada en dos pares, primero el nivel de riesgo y en segundo lugar la vulnerabilidad de la organización. Se puede emplear en diferentes aspectos, ya que su flexibilidad permite adaptar sus aristas a diferentes áreas de la organización e incluso a múltiples temáticas dentro de la misma, otorgando a los analistas la opción de examinar principales riesgos que puedan afrontar los departamentos de su organización.

Su estructura sirve para representar visualmente el riesgo potencial de cada elemento, y el color de sus cuadros permite conocer el umbral o la peligrosidad que representará para las actividades laborales, en donde mientras más cálido sea el color, el riesgo será el mínimo, pero si se torna intenso significara que puede representar una gran amenaza para la organización (Leal et al., 2022).




Figura 1. Matriz de tolerancia al riesgo de un área financiera

Nota: Información adaptada de Methods-X (Leal , et al., 2022). Elaborado por los autores (2025)

En la figura 1 se muestra, que el riesgo y la vulnerabilidad deben ser catalogadas del 0 al 1, para posteriormente multiplicarlos y ubicarlos dentro del mapa, según los datos obtenidos. Esta herramienta permite observar las distintas eventualidades que se suscitan dentro del espacio laboral y que pueden no ser evaluadas correctamente, es por esta razón que sirve de guía, ya que al ubicarlos dentro de estos márgenes permite analizar su peligro para mitigarlos a corto y largo plazo, brindando a la empresa información para crear medidas y adoptar técnicas de mitigación de riesgo.

Modelo predictivo

Un modelo predictivo puede considerarse como un conjunto esquematizado de proce-

sos matemáticos creados con la finalidad de presagiar y estudiar el comportamiento de un caso específico. Estos modelos son herramientas usadas para analizar grandes cantidades de datos (Big Data), ya que permiten a los investigadores extraer información valiosa como puntos críticos o tendencias, ofreciendo pronósticos sobre futuros eventos, lo que permite una toma de decisiones informada (Calisaya, 2021). Estos modelos cuentan con la capacidad para adaptarse y aprender según la metodología aplicada, logrando adentrarse eficazmente en un entorno empresarial cambiante. Normalmente, son ajustados según las necesidades del mercado, debido a sus variaciones y las tendencias, representando un aliado estratégico al crear un plan a largo plazo.




Figura 2. Flujo del análisis de un modelo predictivo

Nota: Información obtenida de (Mathworks, 2024).

Para crear estos modelos primero se debe definir correctamente la problemática a estudiar y empezar una recolección de da-

tos, siendo importante que sean variables de calidad y que puedan ser integrados en futuros esquemas estadísticos y matemáti-

cos, ver figura 2. Una vez suministrados se lleva a cabo un proceso en el que los datos son limpiados y tratados con el fin de normalizar las variables para emplear modelos predictivos como arboles de decisiones o regresión lineal, dependiendo siempre de la naturaleza del problema o las necesidades de la organización (Alvarez, 2020). Estos modelos deben contar con un entrenamiento y validación en donde se vayan ajustando poco a poco sus parámetros, logrando así evaluar la efectividad y el grado de certeza que presentan.

Algoritmos de Machine Learning para predecir riesgos

Regresión logística: Este modelo es comúnmente el más usado para predecir resultados debido a su fácil manejo y rápida capacidad para procesar datos. Plantea la disponibilidad de mapear valores reales entre 0 y 1, permitiendo predecir resultados de forma idónea, en donde las probabilidades más altas se encuentran cercanas al número 1, mientras las más bajas tenderán a acercarse al número 0. Resulta una excelente opción si se desea trabajar con más de dos clases simultáneamente y un equipo de trabajo inexperto en el área, ya que ofrece una facilidad para interpretar los datos, al igual que la capacidad para asociarlas con otras técnicas de validación como el uso de métricas de rendimiento.

Regresión logística binaria: Variación de la regresión logística tradicional, permitiendo que su respuesta o variable de entrega sea de tipo mixta, logrando permitir valores cuantitativos y cualitativos dentro de un mismo modelo. Esto es beneficioso para situaciones en donde se analiza las repuestas con bases binarias, es decir 1 si es bueno y 0 si es malo, logrando en casos concretos evaluar situaciones y predecir impactos como la probabilidad de impago, o des-acuerdos posteriores (Salazar, 2022).

Redes Neuronales: Son modelos de aprendizaje automático conformado por capas que replican las estructuras neuronales del

cerebro humano, todo esto mediante el procesamiento de información para aprender y reconocer patrones complejos. Actualmente, estos modelos se dividen para un conjunto diferentes de tareas, pudiendo reconocer imágenes, efectuar simulaciones, procesar el lenguaje natural e incluso realizar diagnósticos o predicciones financieras, todo esto mediante un continuo aprendizaje (Tello Oquendo, 2024).

Google Colab: También conocido como Colaboratory, es una herramienta gratuita basada en la nube ofrecida por el proveedor Google que permite a los usuarios escribir y ejecutar código en lenguaje de Python dentro de un navegador web. Se basa en el software Jupyter Notebooks, lo que permite a los usuarios crear y compartir cuadernos que contienen código, pero también texto descriptivo, gráficos, visualizaciones de datos y mucho más, sin necesidad de instalar un software adicional. (Castelo et al., 2021). La clave de su éxito radica en la flexibilidad y la capacidad de escalar, significando que el proceso admitirá casi todas las bibliotecas y otras herramientas de Python sin ser modificadas. El usuario crea entornos fáciles de usar para instalar y ejecutar bibliotecas populares, que incluyen TensorFlow, Matplotlib, Folium, NLTK, Keras, PyTorch, NumPy, Pandas, etc. Todo esto puede tener un sesgo hacia el desarrollo y la creación de nuevas metodologías. Este último punto puede complementarse con la capacidad para implementar gráficos y visualizaciones, mediante el uso de extensiones, logrando así mostrar representaciones de árboles de decisiones, esquemas de redes neuronales y nube de tags (Naik et al., 2021).

Inteligencias de negocios: Mediante el uso de Business Intelligence, las compañías pueden analizar su rendimiento en ventas y detectar tendencias del mercado. Esto también les permite evaluar la efectividad de sus estrategias de marketing y segmentar a los clientes según sus patrones de compra (Briones & Ramos, 2024). La inteligencia de negocios es una referencia al conjunto de

tecnologías, aplicaciones y prácticas que las organizaciones utilizan para recopilar, integrar y analizar datos empresariales con el fin del apoyo a una toma de decisiones

adecuada. Entre las tecnológicas que más se destacan se encuentra el análisis de negocio, la minería de datos y la infraestructura de datos.




Figura 3. Arquitectura de un modelo de negocio

Nota: Imagen adaptada de (github.io, 2020).

Curva de ROC: La curvatura de Roc permite evaluar el desempeño y sensibilidad del modelo mediante la tasa de verdaderos positivos y la tasa de falsos positivos. Esta curva brinda la capacidad para analizar el comportamiento del modelo durante la separación de clases, permitiendo observar la

certeza al dividir los clientes de bajo, medio y alto riesgo. Los resultados arrojados por la gráfica son óptimos, ya que empieza con una certeza del 0.87, que posteriormente incrementa a 0.96, validando los resultados y su capacidad para identificar el riesgo potencial de cada cliente.




Figura 4. Gráfica de curva de ROC aplicada en la evaluación del modelo

Nota: Elaborado por los autores (2025).

Data Lake

Un lago de datos es un repositorio o sistemas de almacenamiento y análisis escalable para grandes cantidades de datos de cualquier tipo, retenidos en su formato nativo y utilizado principalmente por especialistas en datos (estadísticos, científicos de

datos o analistas) para la extracción de conocimientos mediante tecnologías de bajo costo que mejoran la captura, refinamiento, archivo y explotación de datos sin procesar dentro de una empresa (Agudelo 2020) (Data Pipeline, 2024)




Figura 5. Data Lake

Nota: Información obtenida de (Agudelo, 2020).

Materiales y métodos

Con el fin de llevar a cabo esta investigación se eligió un enfoque mixto en donde mediante métodos cualitativos y cuantitativos se pueda abordar de manera completa y precisa la problemática de investigación, permitiendo aprovechar las fortalezas de cada una para explorar, analizar y gestionar los riesgos financieros. La integración de ambos enfoques facilitará el análisis integral de los datos, ya sean encontrados en información histórica o mediante las experiencias de los involucrados. Este enfoque permitirá obtener una mejor comprensión sobre los riesgos financieros de la empresa, así como también identificar sus principales desafíos en el área financiera. Con los datos históricos obtenidos, se contará con la capacidad de evaluar la toma de decisiones estratégicas a aplicarse en el área financiera, así como identificar cualquier posible resistencia al cambio dentro del área. Según Hernández & Duana (2020), las técnicas de recolección de datos comprenden procedimientos y actividades que le permiten al investigador obtener información necesaria para dar respuestas a su pregunta de investigación.

En este contexto, la recolección de datos es una etapa esencial para garantizar la precisión y relevancia de las variables usadas en el modelo predictivo, logrando conseguir resultados de alto valor que pueden ser representados gráficamente dentro de un tablero de Power BI. Para el análisis de la minería de datos, se utilizará principalmente la metodología CRISP-DM debido a su es-

tructura centrada en el análisis de datos y la capacidad para ser usada de manera efectiva en procesos predictivos, enfocándose en la preparación y validación de la información. Esta metodología presenta un enfoque esquematizado en la minería y ciencia de datos para la creación, y diseño de colecciones mediante etapas estructuradas y orientadas a su comprensión, tratamiento, modelación y evaluación.

El conjunto de datos incluyó información histórica correspondiente a los primeros cinco años de la empresa de estudio, los cuales abarcan el período 2018 - 2022. A partir de este proceso, se consolidaron los datos en un único formato, lo que permitió la creación de una base de datos centralizada para almacenar la información financiera relacionada con los contratos de los clientes durante el período seleccionado.

El modelo utiliza algoritmos predictivos como LSTM y ARIMA, enfocándose en identificar patrones significativos en los datos financieros, permitiendo generar predicciones confiables sobre los niveles de riesgos asociados a cada cliente, así como estimaciones de los porcentajes de los riesgos mensuales. En complemento a lo anterior, se incorporan técnicas de árboles de regresión, Grid Search y XGBoost con el objetivo de optimizar los resultados obtenidos. Se consideraron variables tanto para evaluar el riesgo como para determinar la variable de Riesgo Total, con el fin de conocer el riesgo asociado a un cliente según su estado financiero e historial de pagos, y así estimar

el porcentaje de incumplimiento basado en las variables dependientes seleccionadas.

Entre las variables dependientes usadas se encuentran, ver figura 6:

$$\text{Relacion deuda Ingreso} = \left(\frac{\text{Egresos Mensuales}}{\text{Ingresos Mensuales}} \right) * (100)$$

$$\text{Relacion deuda Ingreso Contrato} = \left(\frac{\text{Montos Contrato}}{\text{Ingresos Anuales}} \right) * (100)$$

$$\text{Riesgo de Crédito} = \left(1 - \left(\frac{\text{Puntaje de Crédito} - 1}{999 - 1} \right) \right) * 100$$

Figura 6. Variables Dependientes

Resultados y discusión

Con los datos centralizados y limpios, se procede a crear un consolidado para trabajar en el modelo predictivo dentro de la plataforma Google Colab. En este proceso, se analizaron las variables disponibles, logrando destacar campos que guardaban una estrecha relación entre sí, como el caso de la variable número de pagos y el monto del contrato, así como los valores de costo del contrato y el presupuesto.

Con base en esta información, se creó un nuevo campo llamado relación deuda ingreso, siendo clave para evaluar la viabilidad financiera de un cliente y su capacidad para cumplir con las obligaciones de un nuevo contrato, considerando la carga económica que este implica. Los datos resultantes fueron exportados en formato CSV para su manejo en las fases posteriores del proyecto.

Arquitectura General del proyecto




Figura 7. Arquitectura General del proyecto destinado a la gestión de riesgo. Elaborado por los autores

Arquitectura y codificación del modelo predictivo




Figura 8. Arquitectura del modelo predictivo usado en Google Colab

La conexión del modelo con Power BI se realizó mediante una integración estructurada que permite vincular los resultados de las predicciones y la base de datos MySQL, permitiendo que la aplicación de Power BI obtenga sin problemas los datos actualizados.

Entrenamiento del modelo LSTM

El entrenamiento del modelo se efectúa aplicando la función `model.fit` (ver tabla 1), la cual toma como referencias las segundas rubricas de entrenamiento.

Tabla 1. Métricas de entrenamiento para el modelo LSTM

Función	Uso
Epoch	Número de veces que el modelo recorrerá el conjunto de entrenamiento. Cuanto mayor sea el número, mejor será la oportunidad de aprendizaje. Es importante tener en cuenta que no se debe exceder en la cantidad, ya que podría generar valores negativos o incrementar el sobreajuste.
Batch_size	Tamaño de los lotes tras cada actualización. En este caso se optó por una actualización del proceso tras 16 resultados
Validation_data	Son los datos de validación que permiten al modelo evaluar su rendimiento durante el proceso de entrenamiento.
Verbose	valor que controla la información que ese imprime durante el entrenamiento, el valor 2 permite imprimir una barra de progresión detallada.

Nota: Información adaptada de la investigación.

Con relación al entrenamiento, el código usado para este proceso fue el siguiente:

```
history = model.fit(X_train, y_train, epochs=1300, batch_size=16, validation_data=(X_test, y_test), verbose=2)
```

Figura 9. Ejemplo de código usado para entrenar el modelo predictivo de LSTM

Luego de entrenamiento se efectúan las predicciones, estas deben ser en primera instancia desescaladas para poder medir su evolución mediante gráficas, en donde

se comparen los datos reales y las predicciones. Para esto se realiza la siguiente codificación, ver figura 10:

```
train_predict = scaler.inverse_transform(train_predict)
test_predict = scaler.inverse_transform(test_predict)
y_train = scaler.inverse_transform(y_train.reshape(-1, 1))
y_test = scaler.inverse_transform(y_test.reshape(-1, 1))
```

Figura 10. Ejemplo de código usado para desescalar las predicciones efectuadas por el modelo LSTM

Al obtener los resultados, se procede a graficar el entrenamiento, utilizando un gráfico de líneas, donde se medirán los valores de

los datos reales, los datos de entrenamiento y las predicciones. La codificación usada se muestra en las figuras 11, 12 y 13:

```
# Graficar las predicciones y datos reales
plt.figure(figsize=(14, 7))

# Gráfico para datos de entrenamiento
plt.subplot(2, 1, 1)
plt.plot(y_train, label='Datos Reales - Train', color='blue')
plt.plot(train_predict, label='Predicciones - Train', color='orange')
plt.title('Comparación: Datos de Entrenamiento vs Predicciones')
plt.legend()
plt.grid()
```

Figura 11. Ejemplo de código usado para generar los gráficos de entrenamiento

Para el modelo LSTM, es necesario entrenarlo de forma iterativa, ya que, al estar en la plataforma de Google Colab, este aprende de manera eficaz y almacena los datos en memoria, utilizandolos para futuras predic-

ciones. Es por esta razón que, al no tener un entrenamiento prolongado, los *resultados obtenidos eran poco eficaces, llegando al punto de ser lineales como se mostrara en la siguiente figura 12.*




Figura 12. Grafica de entrenamiento inicial del modelo predictivo mediante datos de entrenamiento y de prueba

En términos globales, el modelo logra una exactitud superior al 90%, lo que significa que clasifica correctamente las instancias del conjunto de prueba dividida en 378 casos. Otro factor que resaltar son las métricas de precisión, Recall y F1, que poseen

valores cercanos a 1, sugiriendo un desempeño uniforme y robusto en ambas clases ver figura 13.

Indicadores financieros



Figura 13. Tablero de control enfocado en indicadores financieros

En la figura 14, se representa gráficamente los ingresos y egresos de la empresa brindando la capacidad para evaluar su desempeño con relación a los años. Se crearon gráficas enfocadas en el análisis de las ganancias o las inversiones realizadas. La

figura 9 refleja el dashboard de control que se enfoca en evaluar el desempeño actual de los clientes. Con este apartado se puede observar aquellos que han influido más en la empresa, y su cumplimiento a través de los años.




Figura 14. Tablero de control enfocado en aspectos claves el cliente

La figura 15, muestra la evaluación del riesgo actual de los clientes, y sus principales indicadores. Este tablero proporciona información actual del riesgo existente en la

organización, así mismo, permite observar que clientes son candidatos idóneos para un nuevo contrato, y cuales pueden representar un mayor riesgo para la organización.




Figura 15. Tablero de control enfocado en mostrar el riesgo actual

Asimismo, la figura 16, muestran el Dashboards enfocados en las predicciones futuras y los cambios en el nivel de riesgo de cada cliente. Su uso se enfoca en la creación de medidas y estrategias que ayuden

a que las organizaciones eviten posibles problemas, o la creación de contratos que pongan en riesgo la integridad financiera de la organización.




Figura 16. Tablero de control enfocado en mostrar las predicciones de riesgo futura y su incidencia en la integridad de la organización

Conclusión

El desarrollo de una plataforma de Business Intelligence junto con el diseño de un modelo predictivo que permita evaluar el riesgo actual de los clientes y predecir su riesgo futuro a partir de los datos históricos, ha logrado cumplir exitosamente los objetivos planteados desde la creación de una base

de datos centralizada en donde se almacene la información histórica de la organización permitiendo así extraer datos sin depender de múltiples repositorios, como se acostumbra a realizar. Es importante mencionar que la aplicación del modelo CRIPDM fue esencial para la correcta estructuración y desarrollo de las actividades, dado



que permitió planificar y diseñar de forma clara cada fase del proyecto, desde la recolección de información hasta las visualizaciones dentro de Power BI. Además, se destaca la selección de Google Colab para el desarrollo del proceso ETL e implementación de algoritmos, ya que su capacidad para ejecutar código y generar graficas permitió crear un entorno ágil y eficiente de desarrollo. En cuanto al modelo predictivo, la selección de LSTM y ARIMA como modelos bases fue decisiva, generando resultados precisos que permitieron a los árboles de decisiones y a la herramienta Gradient Boosting predecir el riesgo futuro de los clientes. Una vez realizados todos los puntos relacionados con el diseño del modelo predictivo, se procedió a emplear herramientas que permitan medir la precisión y la sensibilidad del modelo, esto se llevó a cabo mediante métricas como la curva de aprendizaje, la curvatura de ROC, el gráfico de dispersión de residuos y las matrices de confusión, las cuales se enfocan en analizar el desempeño del modelo actual y los resultados obtenidos. Gracias a los datos generados, y la centralización de la información, se desarrollaron tableros de control dinámicos que permitieron a los analistas financieros visualizar el estado de las finanzas, conocer el perfil de cada cliente, evaluar su riesgo y proyectar el impacto futuro. Esto contribuye a la mejora continua dentro de las empresas, estableciendo bases para la renovación tecnológica y la adopción de nuevas prácticas que optimicen el desempeño financiero.

Bibliografía

- Acosta, D. F., & Horna, M. J. (2023). Análisis del riesgo financiero y su efecto en el crecimiento empresarial de las PYMES de Ambato. *Revista Latinoamericana de Ciencias Sociales y Humanidades*, 4(2), 7-12. <https://latam.redilat.org/index.php/lt/article/view/798/1078>
- Acosta, F. J., & Del Águila, L. A. (2020). Solución de inteligencia de negocios para automatizar el proceso de selección y evaluación del proyecto "Lectores de Paso" [Tesis de pregrado]. Repositorio Académico UPC. https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/653633/AcostaD_F.pdf
- Acosta, L. (2021). *Análisis de la solidez financiera de la banca múltiple peruana mediante la aplicación de la metodología CAMEL, periodo 2014-2020 [Tesis de maestría]. Universidad Católica de Santa María. <https://repositorio.ucsm.edu.pe/handle/20.500.12920/10952>
- Agudelo, J. (2020). Data lakes: Aplicaciones, herramientas y arquitecturas [Repositorio institucional]. Repositorio Universidad Tecnológica de Pereira. <https://repositorio.utp.edu.co/server/api/core/bitstreams/5f56e572-d416-487e-a6d5-ec3a8e-45da46/content>
- Alaminos, A. (2023). Árboles de decisión en R con Random Forest. Universidad de Alicante.
- Álvarez, D. A. (2020). Modelo de predicción de la producción de energía de la Central Hidroeléctrica Coca Codo Sinclair, basado en técnicas de aprendizaje computacional [Tesis de maestría]. Repositorio Institucional ESPE. <https://repositoriobe.espe.edu.ec/server/api/core/bitstreams/aeb2c6b0-b7c9-4fe8-b535-e89b28f48b99/content>
- Briones, J., & Ramos, M. (2024). Business Intelligence y análisis de datos para la toma de decisiones empresariales. *Revista de Tecnología e Innovación*, 15(3), 45-62.
- Calisaya, F. (2021). Modelos predictivos y su aplicación en el análisis empresarial. *Journal of Data Science*, 8(2), 112-125.
- Castelo, M., Fernández, R., & González, P. (2021). Google Colab como herramienta para la investigación colaborativa en ciencia de datos. *Revista Iberoamericana de Computación*, 12(4), 78-92.
- Colab, G. (2020). Te damos la bienvenida a Colaboratory. Google Research. <https://colab.research.google.com>
- Data Pipeline. (2024). Data Pipeline documentation. North Concepts. <https://northconcepts.com/>
- Esparza, E., Jácome, R., & Vera, P. (2020). Riesgo y rendimiento del BVG Index. *Revista de Economía y Finanzas*, 25(1), 34-50. <https://dialnet.unirioja.es/servlet/articulo?codigo=7525472>

- Esteban, A., Zárate, C., & Machinandiaarena, V. (2023). Diseño de cuadro de mando integral con Power BI para empresa distribuidora de bebidas. *Revista de la Escuela de Perfeccionamiento en Investigación Operativa*, 18(2), 89-105. <https://revistas.unc.edu.ar/index.php/epio/article/view/42567>
- github.io. (2020). Arquitectura de modelos de negocio. Business Architecture Group. <https://businessarchitecture.github.io>
- Hernández, R., & Duana, D. (2020). Metodología de la investigación: Técnicas de recolección de datos (6ª ed.). McGraw-Hill.
- Leal, M., Pérez, R., & González, S. (2022). Matrices de tolerancia al riesgo en la gestión financiera empresarial. *Methods-X*, 9, 101-115. <https://doi.org/10.1016/j.mex.2022.101789>
- Mathworks.(2024).Predictive modeling workflow. MATLAB Documentation. <https://www.mathworks.com/help/stats/predictive-modeling-workflow.html>
- Naik, N., Peterson, L., & Johnson, M. (2021). Cloud-based collaborative environments for data science education. *Journal of Educational Technology*, 45(3), 234-248. <https://doi.org/10.1109/TE.2021.3098765>
- Rodríguez Fajardo, J. (2022). Gestión integral de riesgos empresariales. Editorial Limusa.
- Salazar, M. (2022). Modelos de regresión logística aplicados a la evaluación de riesgo crediticio. *Revista de Estadística Aplicada*, 19(1), 67-82.
- Santana Falcón, F. (2023). Análisis de datos abiertos de fútbol aplicando la metodología CRISP-DM [Tesis de maestría]. Universidad Politécnica de Madrid. <https://oa.upm.es/75461/>
- Techno Review. (2021). Gestión de riesgos tecnológicos en la era digital. *Techno Review: Revista de Innovación Tecnológica*, 14(2), 28-35.
- Tello Oquendo, L. (2024). Redes neuronales y deep learning: Aplicaciones en el sector financiero. *Inteligencia Artificial Revista*, 7(1), 45-60.
- Vaca, R., & Orellana, P. (2020). Análisis de riesgos financieros en empresas del sector tecnológico. *Revista de Administración y Finanzas*, 12(3), 112-128.



CREATIVE COMMONS RECONOCIMIENTO-NOCOMERCIAL-COMPARTIRIGUAL 4.0.

CITAR ESTE ARTICULO:

Trujillo Coloma, M. J., Guerrero Zambrano, E. O., Moreno Díaz, V. H., & Tejada Castro, M. I. (2025). Modelado predictivo del riesgo financiero en empresas de tecnología mediante una plataforma de inteligencia de negocio. *RECIAMUC*, 9(4), 89-103. [https://doi.org/10.26820/reciamuc/9.\(4\).diciembre.2025.89-103](https://doi.org/10.26820/reciamuc/9.(4).diciembre.2025.89-103)