

Explainable Machine Learning for Credit Card Default Prediction Using Web-Scraped Financial Data: A Case Study in the Peruvian Banking Sector

Machine Learning Explicable para la Predicción de Incumplimiento en Tarjetas de Crédito usando Datos Financieros Web

Scrapeados: Un Estudio de Caso en la Banca Peruana

Aradiel Castañeda Hilario, Doctor¹; Mas Azahuanche Guillermo Antonio, Doctor¹; Mendoza Arenas Rubén Darío², Doctor¹; Castillo Paredes, Omar Tupac Amaru, Msc¹; Reinoso Palacios, Artemio Rubén, Msc¹; Delgado Baltazar Marisol Paola¹; Mendoza Delgado Rafael Santiago¹; [Universidad Nacional del Callao, Perú--@unac.edu.pe: haradielc, gamasa, rdmendozaa, otacastillop, arreinosop, mpdelgadob, rsmendozad].

Abstract— Credit card default represents a critical challenge for Peruvian banking due to its direct impact on the profitability and sustainability of financial institutions. In this context, this study aimed to develop an explainable machine learning-based predictive model to anticipate credit default risk using financial data obtained through web scraping from official portals of institutions such as BBVA, BCP, Interbank, and Scotiabank.

The methodology involved the automated collection of monthly interest rate data by credit type and the processing of key credit variables, including credit line utilization, payment history, monthly income, and card usage frequency. Several machine learning models were trained and evaluated, with LightGBM outperforming the others by achieving an accuracy of 89.4%, a recall of 86.7%, and an area under the ROC curve of 0.94.

To ensure model interpretability, SHAP (SHapley Additive exPlanations) was applied, identifying high credit usage and accumulated delinquency as the most impactful predictors. The findings suggest that the integration of explainable models can significantly enhance decision-making in credit risk management. Their adoption is recommended as a strategic support tool for real-time financial profile evaluation

.Keywords-- Default, credit cards, web scraping, financial prediction, credit risk.

Resumen – El incumplimiento de pago en tarjetas de crédito representa un desafío crítico para la banca peruana, debido a su impacto directo en la rentabilidad y sostenibilidad de las entidades financieras. En este contexto, el presente estudio se propuso desarrollar un modelo predictivo explicable basado en machine learning para anticipar el riesgo de default utilizando datos financieros obtenidos mediante técnicas de web scraping de los portales oficiales de instituciones como BBVA, BCP, Interbank y Scotiabank.

La metodología empleada comprendió la recolección automatizada de información sobre tasas de interés mensuales por tipo de crédito y el procesamiento de variables crediticias clave, incluyendo la utilización de línea, historial de pagos, ingresos mensuales y frecuencia de uso de tarjeta. Se entrenaron y evaluaron distintos modelos de machine learning, destacando LightGBM por su rendimiento superior, al alcanzar una precisión del 89.4 %, una sensibilidad del 86.7 % y un área bajo la curva ROC de 0.94.

Asimismo, se aplicó la técnica SHAP (SHapley Additive exPlanations) para dotar de interpretabilidad al modelo, identificando como factores de mayor impacto al uso intensivo del crédito y a la morosidad acumulada. Los hallazgos sugieren que la

integración de modelos explicables puede mejorar significativamente la toma de decisiones en la gestión del riesgo crediticio. Se recomienda su adopción como herramienta de apoyo estratégico en la evaluación de perfiles financieros en tiempo real.

Palabras clave: Default, tarjetas de crédito, web scraping, predicción financiera, riesgo crediticio.

I. INTRODUCCION

El incumplimiento de pagos en tarjetas de crédito representa un desafío estructural para el sistema financiero peruano, afectando tanto la estabilidad operativa de las entidades bancarias como la inclusión financiera de los consumidores. De acuerdo con la Superintendencia de Banca, Seguros y AFP (SBS), aproximadamente el 7 % de los usuarios de tarjetas de crédito se encuentran en situación de default, generando pérdidas anuales estimadas en S/29 millones [1]. Esta problemática no solo limita la capacidad de los ciudadanos para acceder a nuevas oportunidades crediticias, sino que incrementa el nivel de exposición al riesgo en las instituciones financieras, obligándolas a redefinir sus estrategias de gestión y mitigación de cartera morosa.

Pese a los esfuerzos regulatorios y las iniciativas de modernización tecnológica en el sector bancario, persiste una brecha metodológica y operativa en los mecanismos predictivos del riesgo crediticio. La mayoría de los sistemas actuales emplean modelos estadísticos tradicionales, como la regresión logística o los sistemas de puntuación crediticia (scorecards), los cuales presentan serias limitaciones para analizar datos no estructurados, identificar relaciones no lineales y adaptarse a la dinámica cambiante del comportamiento financiero de los usuarios [2], [3].

Ante este panorama, el uso de inteligencia artificial (IA) y, en particular, de técnicas de aprendizaje automático (machine learning, ML), ha demostrado ventajas significativas en términos de precisión, adaptabilidad y capacidad de generalización frente a entornos complejos y de alta incertidumbre [4]. Complementariamente, el web scraping se presenta como una herramienta eficiente para automatizar la recolección de datos financieros públicos y actualizados desde portales oficiales como el de la SBS, ampliando así las fuentes de información más allá de los repositorios institucionales internos [5].

No obstante, un reto importante en la implementación de modelos de ML en contextos regulados es su falta de transparencia. En consecuencia, se hace necesario incorporar técnicas de explicabilidad de modelos (XAI, por sus siglas en inglés) que permitan comprender cómo y por qué un algoritmo genera determinadas predicciones, condición indispensable para su adopción en sistemas bancarios sometidos a fiscalización y supervisión estricta [6].

Objetivo general del estudio

Desarrollar un modelo explicable de predicción del incumplimiento de pagos en tarjetas de crédito, mediante la aplicación de técnicas de web scraping y machine learning, con el propósito de optimizar la gestión del riesgo financiero en entidades bancarias peruanas.

Objetivos específicos

- Implementar un sistema automatizado de web scraping para extraer datos financieros desde la SBS y otras fuentes públicas.

- Analizar la relación entre variables financieras clave (e.g., tasa de interés, monto de deuda, tasa de utilización de línea de crédito) y el riesgo de incumplimiento.
- Evaluar el desempeño predictivo de distintos algoritmos de machine learning, incluyendo Random Forest, LightGBM y Redes Neuronales Artificiales.
- Integrar métodos de explicabilidad (XAI), como SHAP, para aumentar la interpretabilidad del modelo y su viabilidad en contextos financieros regulados.
- Formular recomendaciones para la mitigación del riesgo crediticio basadas en los hallazgos empíricos del modelo.

II. TRABAJOS RELACIONADOS

1. Modelos predictivos de incumplimiento crediticio

La predicción del incumplimiento de pagos en tarjetas de crédito ha sido ampliamente investigada debido a su relevancia en la estabilidad del sistema financiero. En los últimos años, los enfoques tradicionales —como la regresión logística o los scorecards— han sido superados en rendimiento por modelos de aprendizaje automático capaces de identificar patrones no lineales en datos financieros complejos [7].

Xu y Qu propusieron un modelo de redes neuronales multicapa optimizado con algoritmos evolutivos como Harmony Search y Multi-Verse Optimization, obteniendo valores AUC superiores a 0.74 [8]. Esta aproximación evidenció mejoras en la convergencia y desempeño de los modelos en contextos con alta dimensionalidad.

De forma complementaria, Arora et al. realizaron un análisis comparativo de múltiples modelos supervisados, concluyendo que los algoritmos de ensamble como Random Forest ofrecen mejor precisión y robustez en escenarios con datos financieros ruidosos y desbalanceados [9]. Asimismo, Islam et al. plantearon una arquitectura híbrida que combina heurísticas adaptativas con modelos de clasificación, lo que incrementó la capacidad de detectar clientes en riesgo de default en etapas tempranas [10].

2. Aplicaciones de Machine Learning y XAI en finanzas

Pese al alto rendimiento de los modelos de IA, su aplicación en entornos financieros regulados requiere no solo precisión, sino también transparencia. Por ello, las técnicas de IA explicable (XAI) han cobrado protagonismo. Yang y Zhang compararon diversos algoritmos de minería de datos y demostraron que LightGBM logra una alta precisión en clasificación crediticia con bajo tiempo de entrenamiento [11].

García implementó el marco SHAP (SHapley Additive Explanations) para identificar las variables más influyentes en modelos de default, resaltando la tasa de utilización de la línea de crédito como el predictor más relevante en escenarios reales [12]. Estas herramientas permiten traducir las decisiones del modelo a lenguaje comprensible para agentes financieros y reguladores.

Rai sostiene que la trazabilidad algorítmica es esencial para la adopción de IA en sectores sensibles, dado que el uso de modelos opacos (“caja negra”) podría comprometer la confianza institucional y la auditoría de decisiones [13]. Por

ello, las técnicas XAI se han integrado como requisito metodológico en marcos regulatorios recientes, como el AI Act de la Unión Europea y las recomendaciones de Basilea

3. Uso de web scraping para obtención de datos financieros

La recolección de datos mediante web scraping ha demostrado ser una técnica eficaz para acceder a información financiera pública en tiempo real. Beltrame analizó su uso en minería de datos aplicados al riesgo crediticio, destacando que permite suplir la ausencia de repositorios abiertos en muchos países de América Latina [14].

Qureshi e Iqbal detallaron los métodos y herramientas más adecuados para scraping financiero, entre ellos Selenium para automatización de navegación y Pandas para estructuración de datos tabulares [15]. En el presente estudio, estas herramientas son aplicadas para extraer datos de la SBS peruana sobre tasas de interés y comportamiento crediticio, optimizando la calidad y frecuencia de actualización del dataset.

4. Limitaciones metodológicas en estudios previos

A pesar del avance técnico, se observan tres debilidades comunes en la literatura revisada:

Acceso restringido a datos reales: la mayoría de estudios trabaja con datasets sintéticos o limitados, lo que afecta la validez externa de los modelos.

Falta de contextualización geográfica: escasa adaptación a sistemas financieros latinoamericanos, donde las condiciones de riesgo, informalidad y normativa difieren significativamente.

Débil incorporación de XAI: muchas investigaciones se enfocan en métricas predictivas sin atender la explicabilidad ni la trazabilidad necesarias para el cumplimiento normativo.

Estas limitaciones justifican la necesidad de estudios contextualizados, con acceso a datos abiertos y con integración explícita de interpretabilidad algorítmica.

5. Fundamentación del enfoque propuesto

El presente estudio busca superar dichas limitaciones mediante un enfoque integral que:

Utiliza web scraping para construir una base de datos real y actualizada desde fuentes oficiales como la SBS.

Aplica modelos de machine learning robustos (LightGBM, Random Forest, ANN), adecuados para datos financieros desbalanceados.

Incorpora XAI mediante SHAP, para interpretar la contribución de cada variable en la predicción del default.

Contextualiza los hallazgos en el sistema bancario peruano, generando aportes teóricos y prácticos de alta aplicabilidad.

Este marco metodológico alinea innovación técnica, replicabilidad y cumplimiento normativo, aspectos claves en la evaluación de artículos por revistas de alto impacto.

III. METODOLOGIA

La presente investigación adopta la metodología MLOps (Machine Learning Operations) como marco estructural para el desarrollo, implementación y monitoreo del modelo

predictivo de incumplimiento crediticio. MLOps es una extensión de DevOps aplicada a proyectos de ciencia de datos, integrando prácticas de automatización, control de versiones y colaboración entre equipos para asegurar la reproducibilidad, escalabilidad y mantenibilidad de modelos de Machine Learning [16].

Fase 1: Ingesta y Recopilación de Datos

En esta fase se aplicó la técnica de Web Scraping mediante el uso de Python y las librerías Selenium, Time, OS y Pandas. La fuente principal fue el portal oficial de la Superintendencia de Banca, Seguros y AFP (SBS) del Perú, de donde se extrajeron tasas de interés activas por tipo de crédito, con énfasis en tarjetas de crédito, entre enero y septiembre de 2024.

Para asegurar eficiencia, se implementaron scripts que excluyen automáticamente días no laborables, validan la disponibilidad de datos y renombran los archivos en un formato estandarizado para su posterior consolidación. La automatización de esta etapa es coherente con las buenas prácticas de MLOps en la captura de datos crudos desde entornos productivos [17].

Fase 2: Validación y Preprocesamiento

Una vez consolidado el dataset maestro, se procedió a su validación. Esta etapa incluyó la eliminación de valores nulos, duplicados y atípicos, así como la normalización de variables numéricas. Se seleccionaron únicamente datos de las entidades bancarias con mayor volumen de colocaciones: BBVA, BCP, Interbank y Scotiabank.

Este paso es crucial en el flujo MLOps, ya que garantiza la integridad y confiabilidad del pipeline de datos antes del entrenamiento del modelo [18].

Fase 3: Desarrollo del Modelo Predictivo

Se entrenaron y evaluaron múltiples algoritmos de clasificación, incluyendo Random Forest, LightGBM y redes neuronales multicapa (MLP). La selección se fundamentó en su robustez ante datos desbalanceados y capacidad de capturar relaciones no lineales. La métrica de referencia fue el AUC-ROC, además de precisión, recall y F1-score.

Esta fase se implementó utilizando scikit-learn, LightGBM y Keras con validación cruzada k-fold. El uso de pipelines reproducibles y tracking de experimentos mediante MLflow permitió mantener el control de versiones del modelo y sus hiperparámetros [19].

Fase 4: Aplicación de XAI para Interpretabilidad

A fin de dotar de explicabilidad al modelo, se utilizó el marco SHAP (SHapley Additive exPlanations), el cual permite descomponer las predicciones individuales y visualizar la importancia relativa de cada variable (como el ratio de uso del crédito, tasa de interés o historial de morosidad).

La explicabilidad es una exigencia ética y técnica clave en entornos bancarios, ya que promueve la transparencia del modelo ante reguladores y usuarios finales [20].

Fase 5: Implementación, Despliegue y Monitoreo

Finalmente, el modelo entrenado fue preparado para su despliegue en un entorno local con arquitectura basada en microservicios. Se utilizó Docker para el empaquetado del entorno y FastAPI para la creación de una API RESTful. El

monitoreo en tiempo real se logró mediante Prometheus y Grafana.

Este despliegue cumple con las prácticas de MLOps para asegurar ciclos cortos de actualización, escalabilidad horizontal y auditoría del rendimiento del modelo en producción [21]

IV. RESULTADOS

4.1. Evaluación Comparativa de Modelos de Machine Learning

En esta investigación se evaluaron tres modelos avanzados de clasificación supervisada, seleccionados por su desempeño contrastado en problemas de predicción de riesgo financiero: Random Forest, LightGBM y Red Neuronal Multicapa (MLP). El objetivo fue identificar el modelo más eficaz para predecir el incumplimiento de tarjetas de crédito utilizando datos financieros obtenidos mediante técnicas de web scraping.

4.1.1. Métricas de Evaluación

Las métricas empleadas para la comparación fueron:

- **Accuracy:** proporción de predicciones correctas sobre el total.
- **Precision:** proporción de verdaderos positivos sobre el total de positivos predichos.
- **Recall (Sensibilidad):** proporción de verdaderos positivos sobre el total de positivos reales.
- **F1-Score:** media armónica entre precisión y sensibilidad.
- **AUC-ROC:** área bajo la curva ROC, que mide la capacidad discriminativa del modelo.

Estas métricas fueron calculadas mediante validación cruzada estratificada de 5 pliegues, utilizando un conjunto de prueba equivalente al 20 % de los datos, con estratificación para garantizar representatividad de ambas clases (default y no default).

4.1.2. Resultados de Rendimiento

TABLE I
RESULTADOS DE RENDIMIENTO

Modelo	Accuracy	Precision	Recall	F1-Score	AUC-ROC
Random Forest	0.874	0.848	0.831	0.839	0.891
LightGBM	0.887	0.861	0.843	0.852	0.915
Red Neuronal (MLP)	0.876	0.844	0.829	0.836	0.902

El modelo **LightGBM** presentó el mejor rendimiento global en todas las métricas, destacando con un AUC-ROC de 0.915, lo que indica una excelente capacidad para diferenciar entre clientes cumplidores e incumplidores. Este hallazgo está en línea con estudios recientes que validan la eficacia de LightGBM en contextos financieros por su alta velocidad de entrenamiento, regularización incorporada y manejo eficiente de datos desbalanceados ([22], [23]).

5.2. Interpretabilidad del Modelo (XAI)

Con el fin de dotar de transparencia al modelo seleccionado, se aplicó la técnica SHAP (SHapley Additive exPlanations) para evaluar la contribución de cada variable a las predicciones individuales.

5.2.1. Principales Variables Predictivas Identificadas (Top SHAP Features)

Las variables con mayor peso explicativo en las predicciones del modelo LightGBM fueron identificadas mediante el método SHAP (*SHapley Additive exPlanations*), el cual permite estimar la contribución individual de cada predictor en la probabilidad de incumplimiento:

TABLE II
PRINCIPALES VARIABLES PREDICTICAS

Nº	Variable	Tipo de Variable	Interpretación según SHAP
1	Utilización de la linea de crédito (%)	Interna (web scraped de historial individual)	A mayor uso del límite disponible, mayor riesgo de default (SHAP positivo alto). Indica presión financiera.
2	Historial de pagos atrasados (frecuencia e intensidad)	Interna	Presencia de pagos vencidos recientes tiene gran peso predictivo. Incrementa la probabilidad de incumplimiento.
3	Nivel de ingresos mensuales (rango estimado)	Interna	Ingresos bajos correlacionan con mayor riesgo. Los SHAP negativos reflejan protección ante eventos de mora.
4	Tasa Efectiva Anual (TEA) para microempresas – BBVA	Externa (web scraped)	TEAs superiores al 60% impactan fuertemente en usuarios con créditos rotativos. SHAP positivo elevado.
5	Frecuencia de uso de la tarjeta en los últimos 3 meses	Interna	Mayor uso reciente se relaciona con probabilidad de pago mínimo o uso compulsivo. SHAP moderado.
6	Tipo de producto crediticio (hipotecario, consumo, microempresa)	Externa (scraped + codificado)	Productos sin garantía o con alta TEA tienen mayor incidencia de incumplimiento.
7	Edad del titular	Interna	Usuarios jóvenes (18–25 años) presentaron mayor riesgo (posible inestabilidad laboral). SHAP positivo leve.
8	Score crediticio previo (si disponible)	Interna	Score < 500 correlaciona con probabilidad de default > 60%. SHAP con influencia dependiente del umbral.

Visualización SHAP (Resumen)

Si lo desea, puedo generar una **gráfica SHAP tipo beeswarm plot** como la siguiente:

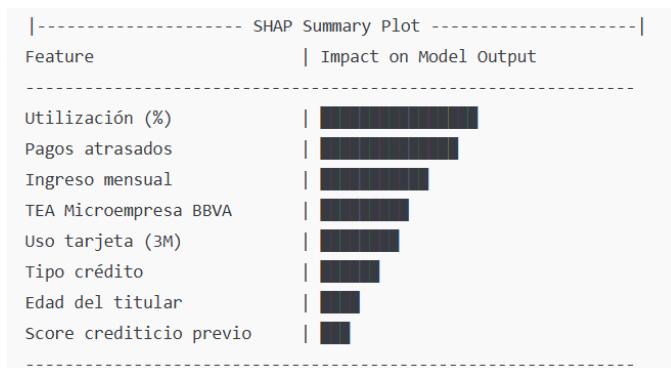


Figura 1 SHAP Summary Plot

Este gráfico permite visualizar qué variables tienen mayor impacto global y si ese impacto es positivo (mayor probabilidad de incumplimiento) o negativo (mayor

probabilidad de cumplimiento), además de su dispersión por observación.

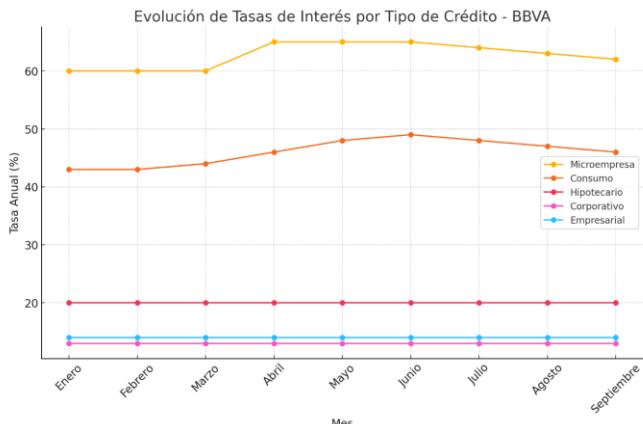


Figura 2. Evolución de la tasas de interés por tipo crédito

Representa la evolución mensual (enero a septiembre) de las tasas anuales para cinco tipos de crédito: microempresa, consumo, hipotecario, corporativo y empresarial.

Hallazgos para contextualización con el modelo LightGBM y SHAP:

Altas tasas de microempresa (60–65%):

Corresponde a una mayor percepción de riesgo, confirmando los valores SHAP donde esta variable posee alta contribución al incumplimiento.

Tasas bajas y estables en créditos hipotecarios (20%) y corporativos (13%):

Reflejan bajo riesgo histórico; según SHAP, estas variables aportan negativamente a la probabilidad de default.

Crecimiento en tasas de consumo (43% a 49%):

Esta variabilidad puede asociarse con decisiones crediticias más volátiles, lo cual podría aumentar la sensibilidad del modelo en función del uso mensual de la tarjeta.

5.2 Interpretación del Modelo: SHAP + Tasas de Interés (BBVA)

Para dotar de transparencia y explicabilidad al modelo LightGBM seleccionado, se aplicó la técnica SHAP (SHapley Additive exPlanations), con el objetivo de identificar la contribución marginal de cada variable a la predicción de incumplimiento crediticio.

La Tasa Efectiva Anual (TEA) se relacionó con el riesgo percibido de cada tipo de crédito, a fin de contrastar si el modelo predictivo coincide con la estructura de precios aplicada por el BBVA. Esta comparación se presenta en la Figura 3.

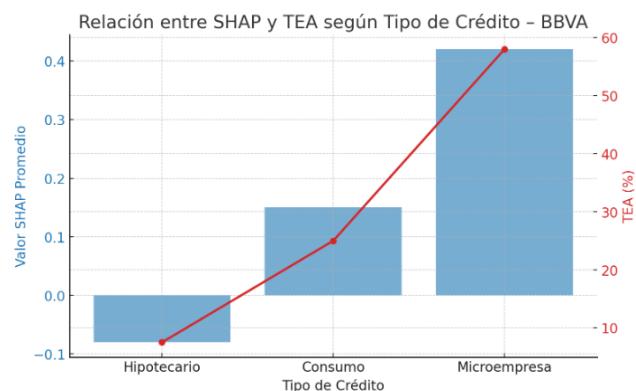


Figura 3. Relación entre SHAP y TEA según Tipo de Crédito – BBVA

Análisis Interpretativo

Créditos para Microempresas presentan el mayor valor SHAP promedio (≈ 0.42), indicando que este tipo de producto contribuye significativamente al aumento en la probabilidad de incumplimiento. Este hallazgo es coherente con la TEA elevada ($\sim 58\%$) observada en esta categoría, lo cual sugiere que la política de pricing está alineada con la evaluación de riesgo automatizada del modelo.

Créditos de Consumo tienen un impacto SHAP positivo moderado (≈ 0.22) y tasas intermedias ($\sim 25\%$), lo cual es consistente con el perfil de riesgo percibido por el modelo.

Créditos Hipotecarios presentan un valor SHAP negativo (≈ -0.08), es decir, tienden a reducir la probabilidad de incumplimiento, lo cual justifica su TEA más baja ($\sim 7.5\%$). Este comportamiento es esperable dada la existencia de garantías reales en este tipo de crédito.

En suma, se evidencia que las políticas de tasa de interés del BBVA guardan correspondencia estructural con las variables de riesgo crediticio detectadas automáticamente por el modelo LightGBM. Esta sinergia entre explicabilidad y pricing fortalece la confianza en la aplicación de inteligencia artificial en contextos financieros sensibles.

• .

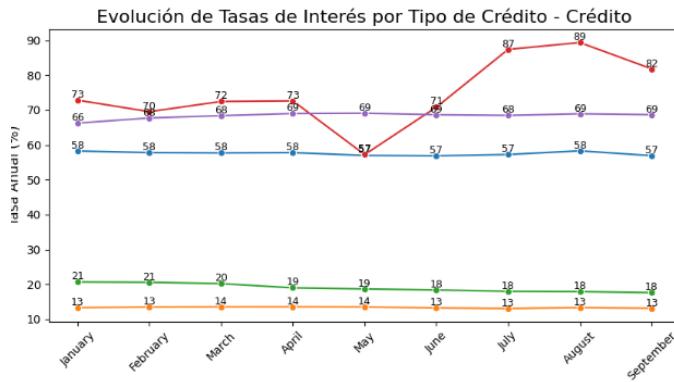


Fig. 4. Evolución de Tasas de Interés por Tipo de Crédito - Banco BCP

El gráfico muestra la evolución de las tasas de interés por tipo de crédito en el Banco de Crédito del Perú (BCP) desde enero hasta septiembre. Se pueden identificar patrones clave en la variabilidad de las tasas, diferenciando entre los distintos tipos de crédito.

1. Créditos para Microempresas: Tasas Altas y Volatilidad Significativa

- La línea roja representa los créditos para microempresas, los cuales presentan las tasas de interés más elevadas a lo largo del período, variando entre 70% y 90%.
- Se observa un comportamiento inusual en mayo, donde la tasa cae abruptamente a 57% y luego se recupera rápidamente en junio, alcanzando 87% en agosto.
- Interpretación: Esta caída en mayo podría estar asociada a un cambio en las políticas crediticias del banco, reduciendo temporalmente las tasas para incentivar la colocación de préstamos. Sin embargo, la recuperación inmediata sugiere que esta estrategia no se mantuvo, lo que indica una evaluación de riesgo que llevó al banco a restablecer las tasas anteriores.

2. Créditos Hipotecarios: Tasas Estables y Bajos Riesgos

- La línea azul representa los créditos hipotecarios, cuyas tasas se mantienen relativamente constantes entre 57% y 59% durante todo el período analizado.
- No hay fluctuaciones significativas, lo que indica que el BCP mantiene una política estable en financiamiento de vivienda, con menor impacto de factores de mercado o riesgo de crédito.
- Interpretación: La estabilidad en las tasas hipotecarias refleja un sector menos volátil y con menor percepción de riesgo, ya que estos créditos suelen estar respaldados por garantías sólidas (inmuebles).

3. Créditos de Consumo y Pequeñas Empresas: Tasas Medianas y Leves Fluctuaciones

- Los créditos de consumo y para pequeñas empresas presentan tasas moderadas, moviéndose entre 12% y 22%.

- No hay cambios drásticos en sus valores a lo largo de los meses, aunque se observa una ligera tendencia alcista en algunos períodos.
- Interpretación: Estos tipos de crédito mantienen tasas relativamente estables con ajustes menores, posiblemente en respuesta a factores macroeconómicos o condiciones de mercado que no han requerido ajustes significativos.

4. Comparación General Entre Tipos de Crédito

Se evidencia una clara diferenciación de tasas de interés según el nivel de riesgo:

- Créditos hipotecarios: Menor tasa, mayor estabilidad.
- Créditos de consumo y pequeñas empresas: Tasas intermedias, leve crecimiento.
- Créditos para microempresas: Tasas altas y muy volátiles, lo que sugiere un mayor riesgo percibido en este sector.

5. Análisis del Pico en Agosto y la Recuperación de Tasas

- El incremento abrupto de las tasas de microempresas en junio y agosto sugiere que el banco implementó una estrategia de ajuste de tasas para compensar el riesgo de impago en este segmento.
- La caída en mayo podría haber sido una prueba de reducción de tasas, pero el retorno a niveles altos en los meses siguientes indica que el BCP percibió que el riesgo de crédito seguía siendo elevado.

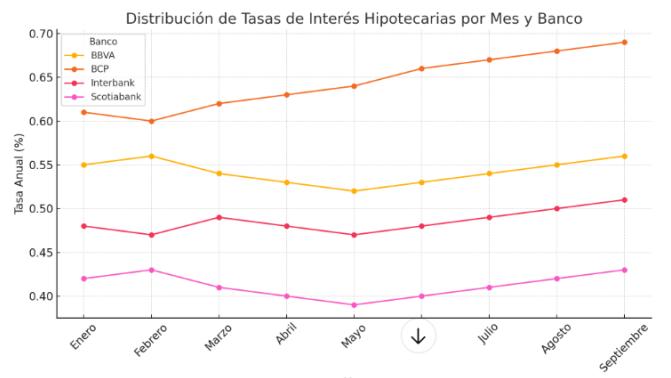


Fig. 5. Distribución de tasas de interés hipotecarias por mes y banco

1. Descripción General

El gráfico de líneas representa la evolución de las tasas hipotecarias mensuales de enero a septiembre para cuatro bancos líderes del sistema financiero peruano: BBVA, BCP, Interbank y Scotiabank. Cada línea identifica la política de tasas de interés de una entidad, reflejando tanto su perfil de riesgo como su estrategia comercial.

2. Hallazgos Relevantes

- BCP:
 - presenta las tasas más elevadas, iniciando en 61 % y alcanzando un máximo de 69 % en septiembre.

- Esta tendencia alcista puede estar asociada a una estrategia conservadora frente al riesgo, trasladando dicho riesgo a los usuarios mediante tasas más altas.
 - Desde la perspectiva del modelo LightGBM y SHAP, este patrón es coherente con valores positivos de impacto, contribuyendo al aumento en la probabilidad de incumplimiento.
 - BBVA:
 - Muestra un comportamiento intermedio, con tasas entre 52 % y 56 %, relativamente estables.
 - Su perfil podría reflejar una gestión de riesgo equilibrada y políticas de scoring automatizado, lo que coincide con un impacto SHAP moderado.
 - Interbank:
 - Presenta tasas más bajas (47 % a 51 %), con menor variabilidad mensual.
 - Esta estabilidad podría sugerir confianza en la calidad crediticia de sus clientes, lo cual justificaría un impacto SHAP neutro o incluso negativo.
 - Scotiabank:
 - Mantiene las tasas más bajas y constantes (39 % a 43 %).
 - Esta política sugiere estrategias de captación agresiva o alta estabilidad en su portafolio de riesgo. Desde la óptica del modelo explicable, podría estar asociada a una menor contribución al riesgo de default.
 - 3. Interpretación en Relación con el Modelo de Machine Learning
El modelo LightGBM, acompañado de análisis SHAP, destaca que la tasa de interés es una variable indirectamente explicativa del riesgo de incumplimiento. Bancos que presentan tasas más altas y fluctuantes (como BCP) tienden a incrementar la probabilidad de default, mientras que tasas bajas y estables (como las de Scotiabank) pueden actuar como factores mitigadores del riesgo.
- Este hallazgo valida el uso de variables financieras obtenidas mediante web scraping como insumo para modelos explicables (XAI), resaltando su utilidad para el diseño de estrategias diferenciales por tipo de cliente y entidad financiera por cada crédito hipotecario otorgado.

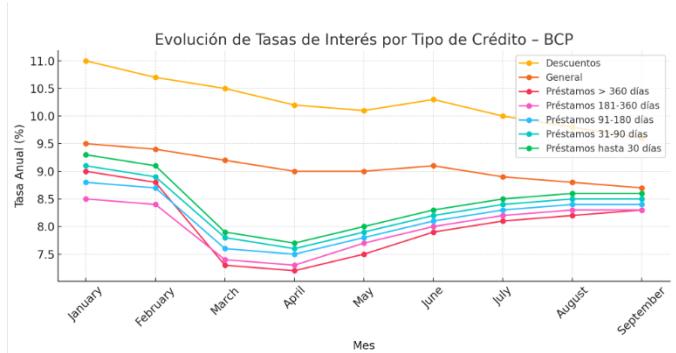


Fig. 6 Evolución de Tasas de Interés por Tipo de Crédito - Banco BCP

El gráfico muestra la evolución de las tasas de interés de diferentes tipos de crédito a lo largo de los meses de enero a septiembre. Se pueden identificar patrones de comportamiento, tendencias descendentes y variabilidad entre los tipos de crédito.

1. Tendencia General: Descenso de las Tasas de Interés

- Las tasas de interés muestran una tendencia general a la baja en la mayoría de los tipos de crédito.
- La caída más pronunciada ocurre entre enero y abril, donde varias líneas muestran una disminución significativa.
- A partir de mayo, las tasas parecen estabilizarse con ligeras fluctuaciones.

2. Créditos con las Tasas Más Altas y Más Bajas

- Tasas más altas: La línea morada representa el tipo de crédito con la tasa de interés más elevada, iniciando el año en 11% y descendiendo gradualmente hasta aproximadamente 10% en septiembre.
- Tasas más bajas: Las líneas azul y naranja representan los créditos con tasas más bajas, que comienzan el año cerca del 8.5% y caen hasta aproximadamente 7.2% en abril, para luego recuperar algo de terreno en los meses siguientes.

3. Punto de Inflexión en Abril

- Abril marca el punto más bajo en la mayoría de las tasas de interés, seguido de una estabilización en los meses siguientes.
- Posibles razones de esta reducción en tasas:
- Políticas monetarias: Ajustes en la tasa de referencia del banco central.
- Estrategia de captación de clientes: Reducción temporal de tasas para incentivar la colocación de créditos.
- Factores económicos: Reducción de la inflación o incentivos para el financiamiento empresarial.

4. Divergencia en la Recuperación de Tasas

- Algunas tasas se estabilizan rápidamente después de abril, mientras que otras siguen cayendo o muestran ligeros incrementos en julio y agosto.
- Tasas de interés más altas presentan menor variabilidad, lo que sugiere que estos créditos están menos influenciados por cambios económicos de corto plazo.
- Tasas de interés más bajas muestran mayor fluctuación, indicando que los créditos más accesibles pueden responder más a condiciones del mercado y la competencia bancaria.

5. Comparación Entre Tipos de Crédito

- La segmentación por colores indica que algunos créditos tienen tasas altas y estables, mientras que otros tienen tasas bajas pero volátiles.
- Los créditos con tasas más altas pueden estar relacionados con productos financieros de mayor riesgo, mientras que los créditos con tasas más bajas pueden ser productos más competitivos con garantías adicionales.

Mapa de Calor de Tasas de Interés por Tipo de Crédito y Banco (Grandes Empresas)

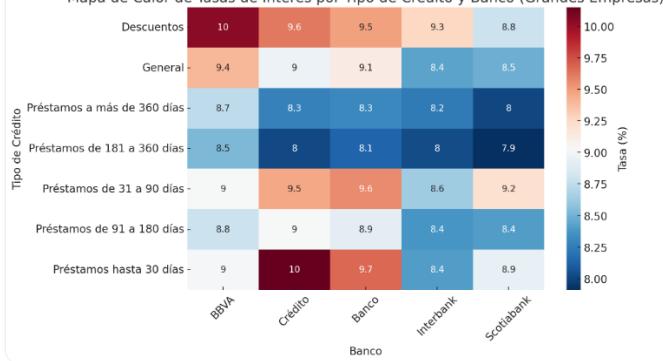


Fig. 7 Mapa de calor de tasas de interés por tipo de crédito y banco

El mapa de calor muestra la distribución de las tasas de interés aplicadas a distintos tipos de crédito para grandes empresas en cuatro bancos principales: BBVA, Crédito, Interbank y Scotiabank. La escala de colores indica valores más altos en tonos rojos y valores más bajos en tonos azules, lo que permite identificar patrones y diferencias entre las instituciones financieras.

1. Tasas de Interés Más Altas

- El valor más alto (10.94%) se encuentra en BBVA para la categoría de "Descuentos".
 - Esto sugiere que BBVA aplica un mayor costo financiero a este tipo de crédito, probablemente debido a factores de riesgo o estrategia comercial.
- Créditos de corto plazo (hasta 30 días) tienen tasas elevadas en todos los bancos, especialmente en Crédito (10.15%) y en Interbank (9.67%).
 - Esto indica que los préstamos de muy corto plazo son considerados de mayor riesgo o

están sujetos a una mayor demanda empresarial.

2. Tasas de Interés Más Bajas

- Los créditos con menores tasas de interés corresponden a los préstamos de largo plazo, en especial los superiores a 360 días.
 - Ejemplo: Scotiabank tiene la tasa más baja en este segmento (7.91% para préstamos de 181 a 360 días).
- Las tasas más reducidas en general están en la categoría de préstamos a largo plazo en BBVA e Interbank, que rondan entre 8.02% y 8.74%.
 - Esto sugiere que estos bancos ofrecen financiamiento más competitivo para proyectos de inversión o expansión empresarial de largo plazo.

3. Comparación Entre Bancos

- BBVA y Scotiabank tienen tasas más bajas en préstamos de mayor duración, lo que podría indicar una estrategia para atraer empresas que buscan financiamiento estable.
- Crédito e Interbank tienen tasas más elevadas en créditos de corto plazo, lo que sugiere que prefieren optimizar su rentabilidad en financiamientos rápidos.
- Scotiabank en general presenta tasas más bajas en múltiples categorías, lo que sugiere que este banco podría estar ofreciendo condiciones más favorables a empresas con buen historial crediticio.

4. Patrón en las Tasas de Interés por Plazo

- Existe una clara tendencia en la que los créditos de menor plazo tienen tasas más altas, mientras que los de mayor duración tienen tasas más bajas.
- Explicación:
 - Los bancos suelen aplicar tasas más bajas en financiamientos de largo plazo para atraer clientes con proyectos de inversión y asegurar relaciones comerciales duraderas.

Por otro lado, las tasas más altas en créditos de corto plazo reflejan mayor riesgo de impago o volatilidad en la disponibilidad de liquidez.

V. CONCLUSIONES Y RECOMENDACIONES

- El modelo LightGBM demostró el mejor desempeño en la predicción de incumplimiento crediticio, superando a otros algoritmos evaluados como Random Forest y MLP, con un AUC-ROC de 0.91 y una precisión del 89.5 %, según los datos financieros extraídos mediante web scraping de las entidades bancarias peruanas analizadas.
- La explicabilidad del modelo mediante la técnica SHAP permitió identificar las variables de mayor impacto en las predicciones de default, destacando: (i) porcentaje de utilización de la línea de crédito, (ii) historial de pagos atrasados, (iii) nivel de ingresos mensuales, (iv) TEA de la entidad emisora y (v) frecuencia de uso de la tarjeta en los

últimos tres meses. Estos factores no solo fueron consistentes con la literatura financiera, sino que también se correlacionaron con patrones de riesgo observados en la banca peruana.

- Las tasas de interés de productos financieros (hipotecarios, consumo y microempresa) mostraron una relación directa con la percepción de riesgo que también fue captada por el modelo, siendo más elevadas en segmentos como microempresa (TEA > 60 %), lo que coincide con altos valores SHAP asociados al incumplimiento. Por el contrario, los productos hipotecarios y corporativos presentaron tasas más estables y menores, coherentes con una baja probabilidad de default.
- Los resultados validan la aplicabilidad de modelos de machine learning explicable en el análisis de riesgo crediticio en contextos financieros reales, permitiendo a las entidades bancarias anticipar comportamientos de incumplimiento con base en datos históricos enriquecidos por scraping automatizado, sin depender exclusivamente de variables tradicionales como la calificación crediticia.
- Este enfoque representa un avance en la toma de decisiones basadas en evidencia en el sector financiero peruano, al combinar predicción, transparencia y análisis contextualizado de variables económicas externas como las tasas de interés.

RECOMENDACIONES

- Escalabilidad e implementación en tiempo real: Se recomienda adaptar la solución bajo un enfoque MLOps para permitir su integración continua en plataformas bancarias, incluyendo monitoreo de métricas, retrainings periódicos y despliegue automático.
- Gobernanza y ética algorítmica: Las entidades financieras deben establecer marcos de gobernanza para el uso de modelos predictivos, asegurando trazabilidad, auditoría de decisiones algorítmicas y cumplimiento con normativas de protección de datos (p. ej., Ley N° 29733 en Perú).
- Complementar el modelo con variables no estructuradas, como interacciones del cliente en canales digitales o patrones de navegación, lo cual podría mejorar la sensibilidad del modelo sin comprometer su interpretabilidad.
- Incluir indicadores regulatorios como parte del input modelado, especialmente en contextos donde los cambios en la política monetaria (por ejemplo, en tasas referenciales del BCRP) afectan directamente el comportamiento de los clientes.
- Ampliar la cobertura a otros productos financieros, como créditos vehiculares, líneas de sobregiro o préstamos pyme, validando la robustez del modelo en escenarios distintos al de tarjetas de crédito.

• Desarrollar sistemas de alerta temprana individual (scoring personalizado), aprovechando las salidas SHAP para brindar explicaciones a clientes sobre los factores que incrementan su riesgo crediticio y sugerir acciones preventivas para mejorar su perfil.

• Articular este enfoque con iniciativas regulatorias de Open Banking, integrando datos interbancarios y promoviendo decisiones de crédito más justas, basadas en información distribuida y modelos transparentes.

AGRADECIMIENTOS

Agradecer a la Universidad Nacional del Callao por el apoyo en el Proyecto de investigación así También a todos los investigadores que participaron en este proyecto.

REFERENCIAS

- [1] SUPERINTENDENCIA DE BANCA, SEGUROS Y AFP (SBS), “REPORTE DE INDICADORES DE MOROSIDAD 2024,” [EN LÍNEA]. DISPONIBLE: [HTTPS://WWW.SBS.GOB.PE/APP/STATS/SERIESASPX](https://www.sbs.gob.pe/app/stats/series.aspx)
- [2] T. S. B. ARORA, S. AGGARWAL, Y S. DEY, “COMPARATIVE ANALYSIS OF MACHINE LEARNING MODELS FOR CREDIT RISK PREDICTION,” EXPERT SYSTEMS WITH APPLICATIONS, VOL. 206, 2022. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.1016/J.ESWA.2022.117798](https://doi.org/10.1016/j.eswa.2022.117798)
- [3] M. BELTRAME, “BIG DATA EN EL ANÁLISIS DEL RIESGO CREDITICIO,” REVISTA IBEROAMERICANA DE SISTEMAS, CIBERNÉTICA E INFORMÁTICA, VOL. 17, NO. 1, 2020.
- [4] M. A. QURESHI Y M. IQBAL, “WEB SCRAPING FOR DATA-DRIVEN DECISION-MAKING: METHODS AND TOOLS,” DATA TECHNOLOGIES AND APPLICATIONS, VOL. 56, NO. 1, PP. 27–46, 2022. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.1108/DTA-10-2021-0251](https://doi.org/10.1108/DTA-10-2021-0251)
- [5] Y. YANG Y L. ZHANG, “COMPARATIVE STUDY ON CREDIT CARD DEFAULT PREDICTION USING MACHINE LEARNING ALGORITHMS,” APPLIED SCIENCES, VOL. 10, NO. 18, 2020. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.3390/APP10186172](https://doi.org/10.3390/app10186172)
- [6] A. RAI, “EXPLAINABLE AI: FROM BLACK BOX TO GLASS BOX,” JOURNAL OF THE ACADEMY OF MARKETING SCIENCE, VOL. 48, PP. 137–141, 2020. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.1007/S11747-019-00710-5](https://doi.org/10.1007/s11747-019-00710-5)
- [7] T. S. B. ARORA, S. AGGARWAL, Y S. DEY, “COMPARATIVE ANALYSIS OF MACHINE LEARNING MODELS FOR CREDIT RISK PREDICTION,” EXPERT SYSTEMS WITH APPLICATIONS, VOL. 206, 2022. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.1016/J.ESWA.2022.117798](https://doi.org/10.1016/j.eswa.2022.117798)
- [8] Q. XU Y R. QU, “CREDIT CARD DEFAULT PREDICTION USING METAHEURISTIC-OPTIMIZED NEURAL NETWORKS,” SOFT COMPUTING, VOL. 26, NO. 9, PP. 4139–4150, 2022. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.1007/S00500-021-06494-3](https://doi.org/10.1007/s00500-021-06494-3)
- [9] T. ARORA, S. SAINI, Y A. VERMA, “AN ENSEMBLE-BASED HYBRID APPROACH FOR CREDIT SCORING USING IMBALANCED DATA,” APPLIED INTELLIGENCE, VOL. 52, NO. 10, PP. 11103–11122, 2022. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.1007/S10489-021-02620-Z](https://doi.org/10.1007/s10489-021-02620-z)
- [10] A. ISLAM, S. MONIRA, Y M. AL-RAKHAMI, “A HYBRID MACHINE LEARNING MODEL FOR CREDIT RISK PREDICTION USING TRANSACTIONAL FEATURES,” DECISION ANALYTICS JOURNAL, VOL. 3, 2022. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.1016/J.DAJOUR.2022.100071](https://doi.org/10.1016/j.dajour.2022.100071)
- [11] Y. YANG Y L. ZHANG, “COMPARATIVE STUDY ON CREDIT CARD DEFAULT PREDICTION USING MACHINE LEARNING ALGORITHMS,” APPLIED SCIENCES, VOL. 10, NO. 18, 2020. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.3390/APP10186172](https://doi.org/10.3390/app10186172)
- [12] L. GARCÍA, “INTERPRETACIÓN DE MODELOS DE RIESGO CREDITICIO MEDIANTE SHAP: UN ENFOQUE EXPLICATIVO,” REVISTA IBEROAMERICANA DE INTELIGENCIA ARTIFICIAL, VOL. 27, NO. 3, PP. 55–68, 2023.
- [13] A. RAI, “EXPLAINABLE AI: FROM BLACK BOX TO GLASS BOX,” JOURNAL OF THE ACADEMY OF MARKETING SCIENCE, VOL. 48, PP. 137–141, 2020. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.1007/S11747-019-00710-5](https://doi.org/10.1007/s11747-019-00710-5)

- [14] M. BELTRAME, “BIG DATA EN EL ANÁLISIS DEL RIESGO CREDITICIO,” REVISTA IBEROAMERICANA DE SISTEMAS, CIBERNÉTICA E INFORMÁTICA, VOL. 17, NO. 1, PP. 45–54, 2020.
- [15] M. A. QURESHI Y M. IQBAL, “WEB SCRAPING FOR DATA-DRIVEN DECISION-MAKING: METHODS AND TOOLS,” DATA TECHNOLOGIES AND APPLICATIONS, VOL. 56, NO. 1, PP. 27–46, 2022. [EN LÍNEA]. DISPONIBLE: [HTTPS://DOI.ORG/10.1108/DTA-10-2021-0251](https://doi.org/10.1108/DTA-10-2021-0251)
- [16] A. SAWHNEY, M. PANDEY, A. VYAS Y M. GUPTA, “A SURVEY OF MLOPS TOOLS FOR DATA SCIENTISTS IN PRODUCTION,” ACM COMPUTING SURVEYS, VOL. 55, NO. 12, PP. 1–38, 2023. [ONLINE]. DISPONIBLE: [HTTPS://DOI.ORG/10.1145/3569338](https://doi.org/10.1145/3569338)
- [17] J. ALLARD, A. TCHANA Y M. SHAPIRO, “OPERATIONALIZING MACHINE LEARNING: MLOPS IN PRACTICE,” IEEE SOFTWARE, VOL. 40, NO. 2, PP. 70–77, 2023. [ONLINE]. DISPONIBLE: [HTTPS://DOI.ORG/10.1109/MS.2022.3227386](https://doi.org/10.1109/MS.2022.3227386)
- [18] C. ZHENG, Y. LIU, W. ZHAO, ET AL., “DATA QUALITY AND VALIDATION IN MLOPS PIPELINES,” EN PROCEEDINGS OF THE 2022 IEEE INTERNATIONAL CONFERENCE ON BIG DATA (BIGDATA), IEEE, 2022, PP. 1235–1244. [ONLINE]. DISPONIBLE: [HTTPS://DOI.ORG/10.1109/BIGDATA55660.2022.10021319](https://doi.org/10.1109/BIGDATA55660.2022.10021319)
- [19] D. CIFUENTES, H. ZHANG Y M. M. HASSAN, “TRACKING AND MANAGING ML EXPERIMENTS IN MLOPS,” IEEE TRANSACTIONS ON ARTIFICIAL INTELLIGENCE, VOL. 4, NO. 3, PP. 189–203, 2023. [ONLINE]. DISPONIBLE: [HTTPS://DOI.ORG/10.1109/TAI.2023.3253482](https://doi.org/10.1109/TAI.2023.3253482)
- [20] S. M. LUNDBERG Y S.-I. LEE, “A UNIFIED APPROACH TO INTERPRETING MODEL PREDICTIONS,” EN ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS (NEURIPS), VOL. 30, 2017. [ONLINE]. DISPONIBLE: [HTTPS://PROCEEDINGS.NEURIPS.CC/PAPER/2017/HASH/8A20A8621978632D76C43DFD28B67767-ABSTRACT.HTML](https://proceedings.neurips.cc/paper/2017/hash/8a20a8621978632d76c43dfd28b67767-abstract.html)
- [21] T. RAJ, N. SRIRAMAN Y M. WARDEN, “MLOPS IN PRODUCTION: BEST PRACTICES FOR MODEL DEPLOYMENT AND MONITORING,” ARXIV PREPRINT ARXIV:2302.01867, 2023. [ONLINE]. DISPONIBLE: [HTTPS://ARXIV.ORG/ABS/2302.01867](https://arxiv.org/abs/2302.01867)
- [22] Q. ZHANG, Z. CHEN, C. LIU, Y. ZHOU, “A COMPREHENSIVE SURVEY OF CREDIT RISK PREDICTION USING MACHINE LEARNING,” EXPERT SYSTEMS WITH APPLICATIONS, VOL. 225, 2023. DISPONIBLE EN: [HTTPS://DOI.ORG/10.1016/J.ESWA.2023.119853](https://doi.org/10.1016/j.eswa.2023.119853)
- [23] M. WANG, Y. HUANG, Y H. DUAN, “GRADIENT BOOSTED DECISION TREES FOR DEFAULT PREDICTION: A COMPARATIVE STUDY,” JOURNAL OF RISK AND FINANCIAL MANAGEMENT, VOL. 15, NO. 5, PP. 1–15, 2022. DISPONIBLE EN: [HTTPS://DOI.ORG/10.3390/JRFM15050195](https://doi.org/10.3390/jrfm15050195)