



**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE GUAYAQUIL
CARRERA DE COMPUTACION**

Estado del arte de Modelos de IA en asignación de créditos bancarios

Trabajo de titulación previo a la obtención del
Título de Ingeniero en Ciencias de la Computación

AUTORES: KELVIN ORLANDO SOLANO PADILLA

CARLOS BRYAN QUIMI ANDRADE

TUTOR: JOE FRAND LLERENA IZQUIERDO

Guayaquil – Ecuador

2024

CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Nosotros, KELVIN ORLANDO SOLANO PADILLA con documento de identificación N° 0921572350 y CARLOS BRYAN QUIMI ANDRADE con documento de identificación N° 0955362082 manifestamos que:

Somos los autores y responsables del presente trabajo; y, autorizamos a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

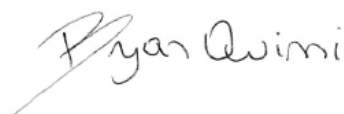
Guayaquil, 20 de enero del año 2024

Atentamente,



KELVIN ORLANDO SOLANO PADILLA

0921572350



CARLOS BRYAN QUIMI ANDRADE

0955362082

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Nosotros, KELVIN ORLANDO SOLANO PADILLA con documento de identificación N° 0921572350 y CARLOS BRYAN QUIMI ANDRADE con documento de identificación N° 0955362082, expresamos nuestra voluntad y por medio del presente documento cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del Artículo Académico: “**Estado del arte de Modelos de IA en asignación de créditos bancarios**”, el cual ha sido desarrollado para optar por el título de: Ingeniero en Computación, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribimos este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

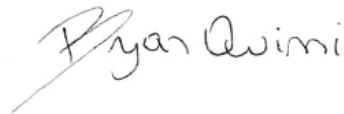
Guayaquil, 20 de enero del año 2024

Atentamente,



KELVIN ORLANDO SOLANO PADILLA

0921572350



CARLOS BRYAN QUIMI ANDRADE

0955362082

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, JOE FRAND LLERENA IZQUIERDO con documento de identificación N° 0914884879, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: **Estado del arte de Modelos de IA en asignación de créditos bancarios**, realizado por KELVIN ORLANDO SOLANO PADILLA con documento de identificación N° 0921572350 y CARLOS BRYAN QUIMI ANDRADE con documento de identificación N° 0955362082, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Guayaquil, 20 de enero del año 2024

Atentamente,



JOE FRAND LLERENA IZQUIERDO

0914884879

DEDICATORIA

Dedico este trabajo a quienes han sido un pilar fundamental, A mi familia, por su gran comprensión, en especial a mi madre la cual me apoyo con mis estudios para que sea un profesional, a mi esposa y mi hija por su tiempo y amor, a mis profesores, cuya sabiduría y orientación han iluminado mi camino académico, a mis amigos, cuya amistad ha sido mi fuente de fortaleza. Que este artículo sirva de apoyo para conocimiento como pequeño aporte académico que enriquece nuestras vidas.

KELVIN ORLANDO SOLANO PADILLA

AGRADECIMIENTO

Agradezco de corazón a todos quienes han contribuido a la realización de este artículo académico. En primer lugar, a mis profesores, quienes fueron una guía experta y valiosas sugerencias han sido fundamentales para dar forma a este trabajo. A mi familia, por su apoyo incondicional y por ser mi fuente constante de inspiración. Este artículo no hubiera sido posible sin la colaboración y el estímulo de todos ustedes, y les expreso mi profunda gratitud.

KELVIN ORLANDO SOLANO PADILLA

DEDICATORIA

Primeramente darle gracias a Dios por permitirnos llegar hasta aquí y nuestros mentores, cuyo apoyo y orientación fueron la luz en nuestro camino hacia la exploración científica. A nuestras familias, por su constante amor y comprensión durante las largas horas dedicadas a la investigación. Y a la comunidad científica, por su incansable búsqueda de conocimiento y colaboración constante.

CARLOS BRYAN QUIMI ANDRADE

AGRADECIMIENTO

Nos gustaría expresar nuestra profunda gratitud a ING. Joe Llerena por su valioso aporte y apoyo durante el desarrollo de este trabajo. Sus conocimientos, orientación y asesoramiento fueron fundamentales para el logro de nuestros objetivos. Además, queremos agradecer a Nuestros familiares por su colaboración y aportes significativos que enriquecieron este estudio. Sus contribuciones fueron clave para el desarrollo y la finalización de esta investigación.

CARLOS BRYAN QUIMI ANDRADE

RESUMEN

Actualmente, la IA está en crecimiento rápido y sus algoritmos son elementos importantes de investigación; la combinación de IA y crédito bancario es una alternativa para resolver el problema en la decisión crediticia. Existe un gran interés en la predicción de la calificación crediticia, y es considerado una necesidad el optimizar la predicción de la calificación crediticia; el problema de créditos para las personas tiene mucha atención, algunos servicios como compartir recursos se basa en la información del crédito de una persona. El objetivo general es desarrollar un estado del arte acerca de los modelos de Inteligencia Artificial utilizados en la asignación de Créditos Bancarios en Ecuador para proporcionar una visión integral y actualizada de los modelos de inteligencia artificial en este contexto y contribuir a la comprensión. La metodología utilizada en esta investigación es la Revisión Sistemática de la Literatura que incluye la recopilación, análisis e integración de investigaciones cuantitativas y cualitativas. Se utiliza este método mixto porque se necesita comprender mejor el problema de investigación y se pueda proporcionar cada método por separado. A nivel global la primera tendencia es el Análisis de datos en 55%, y la primera recomendación es la Toma de Decisiones en 58%. En el contexto ecuatoriano la primera tendencia es el Análisis de Datos en 83%, y la primera recomendación para utilizar IA es la Toma de Decisiones en 83%.

Palabras claves: Inteligencia Artificial, Créditos Bancarios, Machine Learning, Deep Learning.

ABSTRACT

Currently, AI is growing rapidly and its algorithms are important elements of research; the combination of AI and bank credit is an alternative to solve the problem in the credit decision. There is a great deal of interest in credit rating prediction, and it is considered a necessity to optimize credit rating prediction; The credit problem for people gets a lot of attention, some services like resource sharing are based on a person's credit information. The general objective is to develop a state-of-the-art about the Artificial Intelligence models used in the allocation of Bank Credits in Ecuador to provide a comprehensive and updated view of the Artificial Intelligence models in this context and contribute to the understanding. The methodology used in this research is the Systematic Review of the Literature, which includes the collection, analysis and integration of quantitative and qualitative research. This mixed method is used because there is a need for a better understanding of the research problem and for each method to be provided separately. Globally, the first trend is Data Analysis at 55%, and the first recommendation is Decision Making at 58%. In the Ecuadorian context, the first trend is Data Analysis in 83%, and the first recommendation to use AI is Decision Making in 83%.

Palabras claves: Inteligencia Artificial, Créditos Bancarios, Machine Learning, Deep Learning.

ÍNDICE DE CONTENIDO

1. INTRODUCCIÓN	12
2. REVISIÓN DE LITERATURA	16
2.1. Crédito bancario	16
2.2. Modelo de calificación crédito (MCC)	16
2.3. Otros Modelos de calificación.....	17
2.4. Datos utilizados en crédito bancario	17
2.5. Modelos de créditos bancarios basados en IA	17
3. METODOLOGÍA	19
4. RESULTADOS.....	21
5. DISCUSIÓN	41
6. CONCLUSIÓN.....	42
REFERENCIAS	43

1. INTRODUCCIÓN

Los Créditos Bancarios utilizan algún modelo de calificación crediticia que son herramientas de evaluación manejadas durante el proceso de toma de decisiones para aceptar o negar una solicitud de crédito (M. A. Reyes Sarmiento, 2022; T. P. Reyes Sarmiento, 2022) Los modelos de calificación se basan en un modelo matemático que consideran la posibilidad que los clientes puedan pagar o no pagar, generalmente se calcula por puntuación crediticia (Ordóñez-Granda et al., 2020); un puntaje más alto es menor probabilidad de incumplimiento o mejor probabilidad de cumplimiento (Sánchez Peña & others, 2023). Los modelos de calificación crediticia tienen factores de medición y obedecen al tipo de crédito o al préstamo; algunos factores son: la edad del cliente, historial de pagos, manejo de la tarjeta de crédito, manejo de cuentas, historial laboral, pago inicial, valor del préstamo (Mining et al., 2019). Entonces, el resultado del modelo estadístico se basa en información sobre el cliente bancario, que permite diferenciar entre “créditos buenos” y “créditos malos”, y dar una probabilidad sobre el incumplimiento. Los modelos de asignación de crédito bancario se forman de dos herramientas estadísticas: regresión logística y análisis discriminante lineal. Además, existen otras técnicas de clasificación y modelado predictivo que pertenecen al área de Inteligencia Artificial (IA) (Alvarado-Salazar & Llerena-Izquierdo, 2022; Okesola et al., 2019).

La economía basada en el crédito está en desarrollo en forma rápida, las transacciones de endeudamiento y préstamos de las organizaciones establecen una buena influencia sobre la economía de un país. Los créditos bancarios, tienen en cuenta el riesgo crediticio, los bancos brindan diversos productos y servicios para diversos tipos de clientes, esto concuerda con la teoría del racionamiento crediticio; y otros bancos brindan productos y servicios más limitados. Actualmente, la IA está en crecimiento rápido y sus algoritmos son elementos importantes de la investigación. La combinación de IA y crédito bancario es una alternativa para resolver el problema en la decisión crediticia. Los algoritmos IA tienen buena capacidad de aprendizaje que es adaptativo. Se considera que el mercado crediticio es afectado por componentes inesperados en todos los escenarios de la economía y la sociedad; es posible que la estrategia crediticia basada en un modelo de decisión se acople para lograr una decisión más justa que éste de acuerdo con las particularidades propias del banco (L. Zhang, 2022).

El problema de créditos para las personas tiene mucha atención, algunos servicios como compartir recursos se basa en la información del crédito de una persona. Además, existe un

gran interés en la predicción de la calificación crediticia, y es considerado una necesidad el optimizar la predicción de la calificación crediticia. En el pasado, el crédito bancario se basaba en métodos estadísticos, pero son resultados subjetivos y la información es retrasada e inoportuna. En cambio hoy, los algoritmos IA pueden procesar mucha cantidad de datos que son generados por internet y sistemas subyacentes (You et al., 2021).

De acuerdo a (Kotb, 2023) el crédito bancario es una ocupación principal en la industria bancaria, por supuesto que sobrelleva riesgos. Para minimizar los riesgos, los bancos utilizan las calificaciones crediticias que valoran la solvencia de los clientes. Los puntajes crediticios son una medida estándar para conocer la capacidad de pago de los clientes a tiempo, además esto genera entorno justo para todos los clientes. Las calificaciones crediticias hacen más sencillas, rápidas, seguras y equitativas a las prácticas crediticias. Puede ser que los clientes con mejor puntaje reciban tasas de interés más bajas con montos más altos; en cambio los clientes con menor puntaje reciban tasas más altas. Se destaca que las empresas financieras dependen de múltiples fuentes de datos, como informes crediticios, fechas de deuda e historial de pagos.

Los principales algoritmos que se utilizan en créditos bancarios sobre IA son: Support Vector Machine **SVM**, K-Nearest Neighbor **KNN**, Naive Bayes **NB**, Convolutional Neural Network **CNN** (You et al., 2021), Decision Tree **DT** (Okesola et al., 2019), LightGBM, XGBoost, AdaBoost, RGF, Random Forest **RF** (Kotb, 2023), Logistic Regression **LR**, Linear Regression **LiR** (Wu, 2022), Multilayer Perceptron (MLP), Extreme Learning Machine (ELM) (Riffi et al., 2020).

El uso de Internet mantiene a muchos usuarios con tendencia a la banca en línea y en ritmo exponencial; la banca por Internet facilita la transacción y elimina el traslado físico al banco. Las transacciones se realizan desde cualquier lugar y desde cualquier dispositivo entre cualquier tipo de cuenta bancaria; así como los créditos bancarios que el cliente los recibe con una transferencia hacia su cuenta. Por otra parte, las transacciones sin efectivo son una norma en empresas y tiendas, esto forma parte del comercio electrónico. Aunque, el fraude en Internet también aumenta de acuerdo con las transacciones en línea, que causan pérdidas de dinero a los clientes y empresas bancarias. Los algoritmos de IA también son utilizados para detectar el fraude enlazado con las transacciones en línea (Singla, 2020).

Los bancos también emiten créditos por medio de una tarjeta de crédito, y está en constante aumento el uso de este tipo de crédito, existen dos maneras de hacer una transacción en este

crédito. En la primera transacción se presenta la tarjeta de crédito en forma física para realizar un retiro o pago o transferencia. En la segunda transacción se realizan compras o pagos por Internet. Aunque el fraude es común en este tipo de crédito por el robo de identificaciones o números (Riffi et al., 2020). Por otra parte, el análisis bancario puede utilizar métodos automatizados que se enfocan en las leyes o regulación, y analizan los datos y transacciones para asignar una puntuación. Los sistemas de análisis pueden estar de acuerdo con reglas regidas por expertos o reglas enfocadas en datos o una combinación de este par. Las sugerencias de los expertos ayudan a examinar diferentes casos (Babu & Pratap, 2020).

El objetivo general es, desarrollar un estado del arte acerca de los modelos de inteligencia artificial utilizados en la asignación de créditos bancarios en Ecuador, mediante una revisión sistemática de la literatura, para proporcionar una visión integral y actualizada de los modelos de inteligencia artificial en este contexto y así contribuir a la comprensión de su eficacia y limitaciones.

Objetivos Específicos son:

- Revisar la literatura enfocada en los modelos de inteligencia artificial aplicados a la asignación de créditos bancarios en Ecuador.
- Identificar las tendencias y avances tecnológicos recientes en inteligencia artificial dentro del ámbito financiero a nivel global, con el propósito de evaluar su aplicabilidad y relevancia en el contexto ecuatoriano.
- Establecer los resultados de la revisión sistemática para ofrecer recomendaciones concretas y estratégicas.

Este proyecto se justifica porque existe una necesidad de entregar el conocimiento sobre diseño y desarrollo de mejores técnicas y dinámicas que se adapten a los rápidos cambios del mercado o negocio; existen otras técnicas de minería de datos para solucionar el problema del crédito bancario, sin embargo, se debe aprovechar la IA en los créditos bancarios.

Los créditos bancarios para consumo o comerciales o hipotecarios tienen un aumento a nivel del mundo; existen consecuencias por el incumplimiento por parte de los clientes, por ello los bancos necesitan otro método válido para gestionar los créditos bancarios. En la actualidad, la forma más sencilla es recurrir a una lista blanca o lista negra de acuerdo con préstamos anteriores, con esto deciden ofrecer el préstamo o negarlo. De acuerdo con un umbral fijo para

seleccionar los clientes. Si el cliente tiene una cantidad de violaciones mayor que el umbral, entonces el banco lo adiciona a la lista negra, y no puede ser sujeto de crédito por su mal historial. Este umbral es manual y no es sensible a datos masivos. Los algoritmos de IA son convenientes para maniobrar grandes cantidades de datos y realizar predicciones precisas (Sanchez-Romero & Llerena-Izquierdo, 2023; Xiangjian, 2021).

Para afrontar el desafío en la asignación de créditos bancarios, otros autores afirman que las técnicas de IA son una “opción natural” por la capacidad de identificar y extraer información valiosa desde grandes cantidades de datos, las soluciones son prometedoras, y también utilizan clasificación de datos (Yan et al., 2023).

La industria bancaria aprovecha la evolución tecnológica y la adopta de acuerdo con sus necesidades y actividades, la tecnología mejora los servicios al cliente, pero si existe alguna crisis financiera se afecta en forma negativa las nuevas capacidades del banco. Al mismo tiempo, varias tecnologías que son nuevas cambian los lineamientos del juego para transformar el entorno bancario hacia bancos apegados al cliente. Puede existir una brecha entre los ofrecimientos del banco para sus clientes y su práctica y representación de conveniencia (Achary & Shelke, 2023; Zerega-Prado & Llerena-Izquierdo, 2022).

En los créditos bancarios, el éxito del banco obedece en su capacidad de toma de decisiones durante la evaluación sobre el riesgo de entregar un crédito al cliente. Si la verificación sobre la credibilidad del cliente es manual entonces la aprobación del crédito es muy difícil, se necesita mucho tiempo y es arriesgado. Con la tecnología IA, los bancos pueden minimizar los riesgos crediticios de impago.

Esta investigación analiza artículos científicos sobre modelos de Inteligencia Artificial que son utilizados en la asignación de créditos bancarios a nivel global y en Ecuador; para poder entender las posibles tendencias y avances tecnológicos, evaluar que algoritmos pueden ser aplicados al contexto ecuatoriano, y además posibles entregar posibles recomendaciones concretas y estratégicas. Esto basado en la revisión sistemática.

2. REVISIÓN DE LITERATURA

En esta sección se describen los conceptos que son utilizados durante el desarrollo de esta investigación.

2.1. Crédito bancario

El crédito en las empresas financieras se fundamenta en evaluar y reconocer las posibilidades de riesgo potencial de incumplimiento de los clientes antes de entregar préstamos. En la economía de mercado moderno se encuentra la industria crediticia que es una significativa fuente de capital para personas y empresas; el crédito bancario es un apalancamiento para lograr objetivos comerciales y generar bienestar en las actividades económicas. Los bancos están en expansión hacia diferentes iniciativas crediticias por el aumento del consumo y negocios; la probabilidad de créditos por pago en mora o impagos aumenta en caso de que los riesgos de los créditos se salen de control. El control sobre créditos bancarios evita el riesgo financiero y la económica irracional. Los bancos o instituciones financieras analizan los riesgos crediticios en forma eficiente y precisa sobre el cliente, además predecir las operaciones antes del crédito y reconocer los riesgos en la entrada. El no pago de los créditos se puede minimizar o evitar al calificar el riesgo que un cliente incumpla su crédito y luego se decide si se entrega el crédito basado en los hallazgos de la evaluación. La gestión del crédito bancario en las empresas financieras inicia con la evaluación e identificación del riesgo por incumplimiento del cliente antes de entregar un crédito (Wu, 2022).

2.2. Modelo de calificación crédito (MCC)

Un MCC es diseñado e implementado por instituciones o bancos de crédito para optimizar su proceso de evaluación crediticia y constituir la capacidad crediticia de los acreedores, y determinar riesgos crediticios. La estimación se sustenta en modelos de la probabilidad que un cliente bancario presente alguna conducta indeseable en el futuro. El crédito potencial es clasificado como “bueno” o “malo” a través de datos históricos, características demográficas y técnicas estadísticas. El Riesgo Crediticio es malo si la puntuación es una alta probabilidad de incumplir las obligaciones financieras, y es bueno si la puntuación es una alta probabilidad de reembolso. Un MMC también se utiliza en empresas de seguros, clubes recreativos, telecomunicaciones y bienes raíces para pronosticar los pagos atrasados. La capacidad de un MMC en la asignación de calificación para un crédito es adaptable a varias áreas de intereses.

Por ejemplo, asignar una puntuación de salud en caso que el cliente no realice un pago, esto permite a la empresa acordar sus riesgos y revisión de su cartera por cobrar (Okesola et al., 2019)

2.3. Otros Modelos de calificación

Existe un enfoque de juicio que también es utilizado por bancos y se sustenta en 3C, 4C o 5C que son: Capital, Carácter, Capacidad, Colateral y Condición (Okesola et al., 2019).

Otro método de calificación es la Lista blanca o lista negra de acuerdo a préstamos anteriores, con esto deciden ofrecer el préstamo o negarlo, es de acuerdo a un umbral fijo para seleccionar los clientes, además este umbral es manual (Xiangjian, 2021).

2.4. Datos utilizados en crédito bancario

Datos de personas son: Género, edad en años, sector, estado civil, dirección de domicilio, años como residente, estado crediticio bueno/malo, valor de vehículos, valor de casa, valor de terrenos, nivel de educación (Okesola et al., 2019). Datos de empresas son: facturación, calificación, cumplimientos, cantidad de clientes y tasa de interés de otros préstamos (L. Zhang, 2022).

2.5. Modelos de créditos bancarios basados en IA

En la investigación (Okesola et al., 2019) se utiliza el algoritmo NB en créditos bancario por medio de tarjetas de crédito, utilizan indicadores demográficos como variables de entrada, además lo compara con KNN, el modelo utiliza el clasificador bayesiano para determinar un modelo de calificación crediticia. La investigación de (L. Zhang, 2022) propone un modelo de evaluación del riesgo crediticio basado en Redes Neuronales para brindar un modelo de decisión crediticia; el modelo se ajusta a la estrategia crediticia de acuerdo a las situaciones comerciales de la empresa y los factores que impactan en el mercado. El artículo de (You et al., 2021) utiliza cinco modelos de SVM, KNN, NB, CNN y DT, que son en algoritmos de Machine Learning para predicción de la calificación crediticia de las personas; de acuerdo a los resultados presentados la precisión del DT para la predicción crediticia es la más alta y la más estable.

La investigación de (Kotb, 2023) realizaron pruebas con algoritmos Boosting, XGBoost, LightGBM que son mejoras con alto rendimiento basados en Árbol de Decisión.

El algoritmo RF es utilizado para desarrollar un modelo de predicción en incumplimiento de créditos bancarios basado en datos históricos; de acuerdo a los autores RF supera a algoritmos de clasificación DT y LR, en la precisión y tasa de recuperación. Los autores recomiendan RF para predecir el riesgo crediticio y controlar el riesgo antes de la entrega del crédito por medio de características significativas (Wu, 2022).

En la investigación de (Riffi et al., 2020) utilizan CNN, Multilayer Perceptron (MLP) y Extreme Learning Machine (ELM) sobre un conjunto de datos que tienen créditos bancarios por medio de tarjeta de crédito; evalúan la precisión, la exactitud y tiempo de clasificación (Demertzi & Demertzis, 2023).

Este trabajo (Azhan & Meraj, 2020) analiza el Machine Learning y Redes Neuronales para determinar errores en los datos, los algoritmos utilizados son NB, RF, LR, LiR, SVM y CNN (Wang et al., 2023).

Este artículo analiza los algoritmos de ML sobre datos sesgados o desequilibrados, se realizan pruebas y cotejan modelos ML como LR, SVM, DT, RF. El algoritmo RF tiene mejor precisión entre todos los modelos (Janet et al., 2022; Parhizkar et al., 2023).

En el artículo (Zhou et al., 2019) se propone un algoritmo para control de riesgos que combina el análisis de componentes y utiliza DT y el algoritmo Adaboost, los autores adicionan el control de riesgos para datos particulares. Las pruebas de datos que pertenecen a un banco comercial muestran una alta tasa de precisión (Kotb, 2023; Parhizkar et al., 2023).

De acuerdo a las características de los créditos, el algoritmo determina ofrecer el préstamo o negarlo, se utiliza algoritmos LR, CNN y RF (Xiangjian, 2021). El artículo analiza los modelos IA sobre transacciones bancarias con alta precisión, utilizan DT, autoencoder y RBM, aquí evaluaron la exactitud, precisión, especificidad, sensibilidad, matriz de confusión; el algoritmo RBM tiene un rendimiento superior (Mubalalike & Adali, 2019). Los autores analizaron los algoritmos LR, KNN, SVM, DT, RF, NB sobre un conjunto de datos públicos para definir la correlación de factores en los créditos, se busca disminuir el alto grado de desequilibrio de los datos y se estudia la precisión (Achary & Shelke, 2023).

Los autores afirman que los modelos de predicción son adaptables al sistema bancario para minimizar el riesgo crediticio y las tasas de incumplimiento de los créditos, y que esta clase de

componente es adaptable a otros sistemas. Los algoritmos probados son LR, DT y RF. LR tiene mejor rendimiento (Lohani et al., 2022).

3. METODOLOGÍA

La metodología utilizada en esta investigación incluye la recopilación, análisis e integración de investigaciones cuantitativas y cualitativas. Se utiliza este método mixto porque se necesita comprender mejor el problema de investigación y se pueda proporcionar cada método por separado (Sánchez, 2021). Los datos cuantitativos incluyen informes cerrados, similares se utilizan para medir actitudes, como las escalas de calificación, entre otros. La revisión de estos datos incluye el análisis estadístico de los resultados recopilados.

De acuerdo con la investigación se realiza seis pasos que se detallarán a continuación:

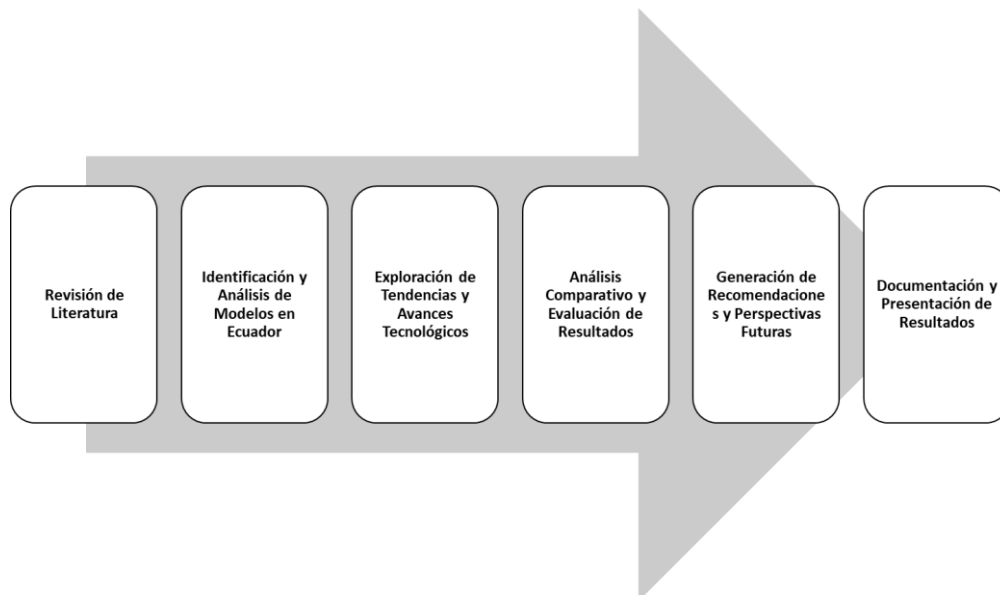


Figura 1. Proceso en la revisión de literatura

3.1. Revisión de Literatura

Se lleva a cabo una revisión sistemática de la literatura relacionada con modelos de inteligencia artificial en la asignación de créditos bancarios, centrándose específicamente en estudios y documentos pertinentes a la realidad ecuatoriana. Se utilizan bases de datos académicas, bibliotecas electrónicas y repositorios especializados para recopilar información relevante.

3.2. Identificación y Análisis de Modelos en Ecuador

Se realiza un análisis detallado de los modelos de Inteligencia Artificial utilizados en la asignación de créditos en Ecuador. Este proceso implica la recopilación de estudios, seguido de una evaluación crítica de las características de cada modelo identificado.

3.3. Exploración de Tendencias y Avances Tecnológicos

Se investiga las tendencias y avances tecnológicos más recientes en Inteligencia Artificial aplicada a la asignación de créditos a nivel mundial. Este análisis se realiza para identificar innovaciones que puedan ser relevantes para el contexto ecuatoriano, proporcionando una visión global de las mejores prácticas y tecnologías emergentes.

3.4. Análisis Comparativo y Evaluación de Resultados

Se lleva a cabo un análisis comparativo de los modelos identificados, considerando métricas de rendimiento y eficacia. Se evalúa los resultados obtenidos por estos modelos en el contexto ecuatoriano, identificando patrones y desafíos específicos.

3.5. Generación de Recomendaciones y Perspectivas Futuras

A partir de los hallazgos, se generan recomendaciones prácticas de los modelos existentes y se identifican posibles áreas de investigación futura. Estas recomendaciones se basan en la comprensión de las limitaciones y oportunidades específicas del entorno financiero ecuatoriano.

3.6. Documentación y Presentación de Resultados

Los resultados obtenidos se documentan de manera clara y concisa en un informe final. Además, se realiza una presentación para compartir los hallazgos con partes interesadas, fomentando la discusión y la retroalimentación. Este enfoque asegura la transparencia y utilidad práctica de los resultados de la investigación.

Las preguntas de investigación son las siguientes:

(1) ¿Qué algoritmos de Inteligencia Artificial son utilizados? (2) ¿Qué datos demográficos analizan los algoritmos IA? (3) ¿Qué datos de empresas analizan los algoritmos IA? (4) ¿Qué datos históricos analizan los algoritmos IA? (5) ¿Los artículos presentan procesos como diseño y pruebas de los algoritmos? (6) ¿Qué tipos de actividades ejecutan los algoritmos IA

utilizados? (7) ¿Cuáles son los indicadores que presentan en los créditos bancarios? (8) ¿Qué software se utiliza para realizar las pruebas o implementaciones de los algoritmos?

4. RESULTADOS

Literatura enfocada en los modelos de Inteligencia Artificial sobre la asignación de créditos.

Para explorar el estado del arte sobre artículos científicos en el campo de IA y su conocimiento generado sobre créditos bancarios, se utilizó la Biblioteca Digital de Association for Computing Machinery (ACM), IEEE Xplore y Google Scholar para recolectar publicaciones desde enero del 2019 hasta Julio del 2023, se utilizó términos de búsqueda: “Intelligence Artificial”, “Credit Bank”, “IA”, “Banking”. Esta revisión se enfoca en estos medios de publicación porque son fuentes de revistas y conferencias internacionales.

La búsqueda previa presenta más de 5000 artículos, pero nos enfocamos en los títulos que contienen los términos de búsqueda. El primer paso del procedimiento llevó a un conjunto inicial de 117 preseleccionados, es decir títulos con términos de búsqueda. Esta revisión siguió una adaptación de la declaración PRISMA (Page et al., 2021), que está estructurada en tres fases que son Identificación, Examinados y Final, ver figura 2.

En la Fase Identificación, se obtuvieron 8 artículos ACM, 73 artículos de IEEE y 36 artículos de Google Scholar, en total 117 artículos; entre estos artículos existían 2 duplicados y se removieron 42 artículos por pedir solicitud de acceso o pago por el artículo.

En la Fase Examinados, se pasó a verificar el resumen de 73 artículos, y se excluyeron 22 porque: no están apegados al objetivo de esta investigación o tratan sobre fraude en las transacciones bancarias o tratan sobre créditos no bancarios o tratan sobre créditos en comunidades de usuarios. Por consiguiente, se empezaron a bajar o recuperar los 51 artículos para leer el detalle de cada documento, pero 6 documentos no fue posible recuperarlos. Los autores leyeron el título y resumen de cada artículo que se distribuyeron. Se excluyó un artículo si es una revisión de literatura o semejante. En caso de que un autor este inseguro de excluir un artículo el otro autor lo revisaba, y se llegaba a un acuerdo. Luego quedaron 45 artículos digitales para su lectura integra, pero 7 artículos fueron descartados por ser documentos de solo resumen o documentos de 1 página. Existe una sesión de discusión iterativa entre los actores para realizar una exclusión final. Un artículo fue excluido por razones como: no ser un artículo

completo (conferencia magistral, taller o resumen ampliado); los términos de búsqueda no se especifican ni en el resumen, ni en la introducción, ni en la contribución, ni en la conclusión, que se realizó sobre IA en créditos bancarios o nombre similar; solo se refiere a una sección de trabajo relacionado con los términos de búsqueda. Los 45 artículos restantes se dividieron en dos conjuntos de artículos. Estos artículos se asignaron en forma aleatoria a los dos autores. Cada autor leyó sus artículos asignados en forma total, es decir, 22 artículos un autor y 23 artículos el otro autor; y fueron analizados de acuerdo con los criterios de exclusión.

En la Fase Final, la última actividad del proceso de selección llevó a un corpus final de 38 artículos incluidos. En esta fase, los artículos completos se analizaron para llenar la hoja electrónica en caso de que cumplan las propiedades.

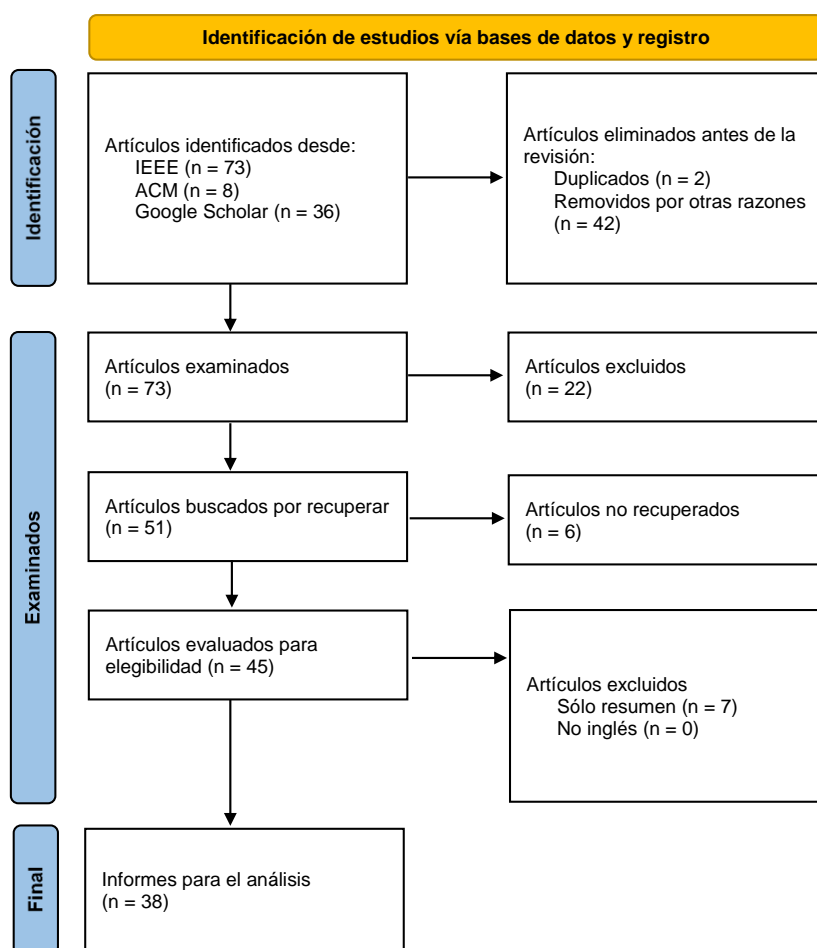


Figura 2. Identificación de trabajos relevantes con el modelo de flujo PRISMA

Los 38 artículos seleccionados se dan a conocer en la tabla 1, se describe las revisiones bibliográficas con respecto al tema de esta investigación, están agrupados por país, en esta caso se encontraron 12 artículos de Ecuador, 8 de China, 8 de India, 2 de Estados Unidos, 2 de

Turquía, los demás países Egipto, Perú, Nigeria, Arabia Saudita, Moroco, Romania tienen un artículo cada uno.

Tabla 1. Artículos seleccionados

N	Artículos	País	Cant
1	(Uquillas & Flores, 2020), (Uquillas, 2020), (Elizabeth et al., 2019), (I et al., 2019), (Barredo-ibáñez, 2021), (Zúñiga, 2021), (Ordóñez-Granda et al., 2020), (Valdiviezo-Abad, Cesibel and Altamirano-Benítez, Verónica and Abendaño-Ramírez, 2020), (Torres-pereira, 2020), (De la A-Muñoz, 2023), (Barragán-Martínez, 2023), (Mining et al., 2019)	Ecuador	12
2	(You et al., 2021), (Shi et al., 2022), (Zhou et al., 2019), (Xiangjian, 2021), (Yan et al., 2023), (L. Zhang, 2022), (T. Zhang & Sun, 2022), (Li, 2021),	China	8
3	(Singla, 2020), (Babu & Pratap, 2020), (Azhan & Meraj, 2020), (Janet et al., 2022), (Achary & Shelke, 2023), (Lohani et al., 2022), (Yadav et al., 2021), (N et al., 2023),	India	8
4	(De la Fuente et al., 2019), (Wu, 2022)	USA	2
5	(Mubalaike & Adali, 2019), (Ogme et al., 2021)	Turquía	2
6	(Kotb, 2023)	Egipto	1
7	(Panduro-Ramírez et al., 2022)	Perú	1
8	(Okesola et al., 2019)	Nigeria	1
9	(Cherif et al., 2022)	Arabia Saudita	1
10	(Riffi et al., 2020)	Moroco	1
11	(Matora, n.d.)	Romania	1
Total			38

Fuente: Autores.

Se clasificó cada artículo como una contribución empírica al momento de analizar su corpus con un enfoque en detalles específicos. Este enfoque sobre los artículos mediante la revisión de literatura empírica está en el análisis basado en datos cualitativos, por ejemplo, algoritmos utilizados, datos de los clientes/empresas/históricos. Muchos de los artículos sobre IA se centraron en uso de algoritmos específicos, otros se centran en transacciones, fraudes, grado de riesgo, predicción de anomalías, análisis, entre otros. La mayoría de los análisis se revisan los algoritmos IA utilizados, se exploraron los aspectos clave del artículo para entender la propuesta y mapear las tendencias y recomendaciones que pueden ajustarse al contexto ecuatoriano, o visualizar una descripción general de las características que proponen los artículos.

En cada artículo analizado se encuentran factores que IA procesa en el campo de crédito bancario, estos factores se muestran en la tabla 2, para gestionar y responder las preguntas de investigación se agruparon en: Algoritmos, Datos demográficos, Datos de empresas, Datos históricos, Procesos, Actividades de los algoritmos, Indicadores, Software utilizado.

Tabla 2. Factores en los artículos

N	Grupo	Factores	Cant
1	Algoritmos de Inteligencia Artificial	Naïve Bayes (NB), Convolutional Neural Networks (CNN), Decision Tree (DT), Linear Regression (LiR), Logistic Regression (LR), K-Nearest Neighbors (KNN), Support Vector Machine (SVM), LightGBM, XGBoost, AdaBoost, RGF, Autoencoder, Multilayer Perceptron (MLP), Extreme Learning Machine (ELM), Restricted Boltzmann Machines (RBM), Random Forest (RF)	16
2	Datos demográficos	Género, Edad en años, Domicilio, Estado civil, Años como residente, Estado crediticio, Valor de vehículos, Valor de casa, Valor de terrenos, Ingresos, Origen de transacción, Tipo de cliente, Código postal, Nivel de educación	14
3	Datos de empresas	Ventas o Facturación, Compras, Calificación de riesgo, Cumplimientos, Clientes, Tasa de interés	6
4	Datos históricos	Pagos, Créditos, Uso de cuentas, Empleos, Fecha, Valores de préstamos	6
5	Procesos	Diseño, Pruebas	2
6	Actividades de los algoritmos	Clasificación, Agrupación, Predicción, Análisis, Precisión	5
7	Indicadores	Estabilidad, Volumen de negocios, Probabilidad, Solvencia, Rotación, Fracaso, Precisión	7
8	Software	Matlab, AttrList, SPSS, Python, R, EDA, Kaggle, IBM PowerAI	8
		Total	64

Fuente: Autores.

En esta sección se informa sobre los resultados del análisis. El resto de esta sección Resultados está organizada de acuerdo con las preguntas de investigación. Se presentan las diferentes características de contribución identificados en los artículos científicos sobre IA en créditos bancarios. Para responder a las preguntas de investigación, se utiliza un enfoque de análisis. En este análisis, se aplicó un enfoque asentado en el consenso de los dos autores. Si el artículo cumple la propiedad en la hoja de cálculo, entonces se anota como 1 punto. Cada factor se suma y la suma total del factor se representa en el porcentaje de los 38 artículos.

(1) ¿Qué algoritmos de Inteligencia Artificial son utilizados?

En los artículos seleccionados se hallaron un total de 16 algoritmos utilizados en diseños o pruebas. Los algoritmos son: NB en 13%, CNN en 32%, DT en 32%, LiR en 18%, LR en 32%,

KNN en 21%, SVM en 26%, LightGBM en 3%, XGBoost en 11%, AdaBoost en 5%, RGF en 3%, Autoencoder en 8%, MLP en 3%, ELM en 3%, RBM en 3%, y RF en 24%, ver figura 3.

Las cifras indican que CNN, DT y LR son los algoritmos más utilizados en créditos bancarios. De acuerdo a (L. Zhang, 2022) el algoritmo CNN toma menos tiempo en realizar el entrenamiento con los datos, y lo eligen para edificar un entorno de decisión crediticia, este algoritmo es estable, objetivo y escalable, además afirman que necesita alguna optimización para escenarios empresariales.

De acuerdo a (You et al., 2021) el algoritmo DT, la predicción de créditos bancarios es alta en relación a KNN, NB, SVM y CNN, porque DT extrae reglas y construye un árbol de decisión de acuerdo a características. Además, solo es necesario almacenar la estructura del árbol, el valor de salida del nodo hoja y los parámetros del nodo de decisión; con esto el conjunto de entrenamiento no es necesario almacenarlo.

De acuerdo a (Lohani et al., 2022) el algoritmo LR es útil por su simplicidad y mantiene un gran rendimiento; y afirman que un modelo de predicción pueda integrarse al entorno bancario para minimizar el riesgo crediticio y las tasas de incumplimiento.

En este grupo de factores son máximo 12 artículos que nombran los algoritmos IA.




Figura 3. Algoritmos de inteligencia artificial

(2) ¿Qué datos demográficos de los clientes analizan los algoritmos IA?

En los artículos seleccionados se hallaron un total de 14 datos demográficos que están distribuidos de la siguiente manera. Género en 53%, Edad en años en 66%, Domicilio en 58%, Estado civil en 58%, Años como residente en 55%, Estado crediticio en 58%, Valor de vehículos en 50%, Valor de casa en 50%, Valor de terrenos en 50%, Ingresos de Dinero en 66%, Origen de transacción en 50%, Tipo de cliente en 29%, Código postal 21%, y Nivel de educación en 21%.

Las cifras indican que la Edad en años y los Ingresos de Dinero son los datos más analizados o clasificados o importantes en los créditos bancarios. Luego se siguen en importancia el Domicilio, el Estado Civil y el Estado Crediticio, ver figura 4.

De acuerdo a (Okesola et al., 2019) un modelo de calificación crediticia considera varios factores como medidas reales y obedecen al tipo de crédito; sin embargo, los factores para un crédito corriente son la edad e ingresos, pero para una crédito hipotecario los factores son historial laboral, primer pago y el monto del crédito. Aquí el algoritmo NB puede diferenciar entre “créditos buenos” y “créditos malos” con la probabilidad de incumplimiento.

Existen varios desafíos para detectar el fraude en la información del cliente o en las transacciones; y el respecto a la privacidad es una preocupación de los bancos. Los clientes pueden entregar datos falsos para obtener un crédito bancario, y por esta razón las entidades piden declaraciones juramentadas y de libre acceso para el banco, otras entidades realizan verificación física como el domicilio y estado crediticio.

Los artículos que presentan datos demográficos y también nombran los algoritmos NB, CNN, KNN, LiR, LR, SVN, AdaBoost, Autoencoder, RF. En este grupo de factores son mínimo 8 artículos y máximo 25 artículos que tratan sobre datos demográficos.




Figura 4. Datos demográficos

(3) ¿Qué datos de empresas analizan los algoritmos IA?

En los artículos seleccionados se hallaron un total de 6 datos empresariales que están distribuidos de la siguiente manera. Ventas o Facturación en 18%, Compras en 16%, Calificación de Riesgo en 21%, Cumplimientos en 21%, Clientes en 21%, y Tasa de interés en 5%. Las cifras indican que la Calificación de Riesgo y el Cumplimiento son factores importantes procesados por los bancos sobre clientes empresariales; además el factor Clientes indica que la empresa puede ser un cliente nuevo en un banco para acceder a un crédito; otros bancos son necesario que el cliente sea un cliente antiguo o con historial de transacciones dentro del banco, ver figura 5.

El rápido avance de la globalización económica ha generado una pequeña escasez de capital a menudo se convierte en un factor importante para las empresas. El tamaño de las empresas y la baja tolerancia al riesgo, conllevan al incremento del riesgo crediticio empresarial, y esto hace más difícil la evaluación crediticia por parte de los bancos. Por ello, es necesario adoptar modelos que evalúen el riesgo crediticio de las empresas y definir nuevas estrategias de crédito bancario para incentivar a las empresas de cualquier tamaño (Shi et al., 2022).

Los artículos que presentan datos empresariales y también nombran los algoritmos CNN, DT, LiR, LR, KNN y SVM. Son pocos los artículos que tratan sobre créditos bancarios para empresas son mínimo 2 artículos y son máximo 8 artículos.




Figura 5. Datos empresariales

(4) ¿Qué datos históricos analizan los algoritmos IA?

En los artículos seleccionados se hallaron un total de 6 datos históricos que están distribuidos de la siguiente manera. Pagos en 55%, Créditos en 66%, Uso de Cuentas en 34%, Empleos en 39%, Fecha en 61%, y Valores de Préstamos en 63%. Las cifras indican que el historial crediticio de una empresa es el factor principal de procesamiento en los créditos bancarios, luego los Valores de Préstamos y Fecha de los Préstamos son importantes para conocer la rotación de créditos que mantiene una empresa. También, es importante conocer los pagos de los préstamos realizados por las empresas para conocer su puntualidad en los abonos de las obligaciones contratadas, ver figura 6.

Los datos históricos abarcan las transacciones con su marca de tiempo, esta historia ayuda en el rendimiento predictivo para posiciones futuras. Los algoritmos IA utilizan conjunto de datos para Entrenamiento y otro para Pruebas, las pruebas utilizan varias métricas de rendimiento, tales como exactitud, precisión y recuperación. El historial de los clientes es utilizado para asignar puntajes crediticios y además son una medida estandarizada que calcula la capacidad de los clientes para pagar sus deudas a tiempo, esto es justo para los bancos prestatarios. Los datos históricos generan calificaciones crediticias que facilitan un proceso seguro y equitativo. Algunos bancos aplican a sus clientes con puntajes altos les dan una tasa de interés más baja y mayor valor de crédito, y los clientes con puntajes bajos les dan una tasa de interés más alta (Kotb, 2023).

De acuerdo a (Xiangjian, 2021) son más las personas y empresas que buscan el crédito para enfrentar sus costos e inversiones, y resulta en un aumento significativo en la cantidad de

créditos bancarios. Los créditos fortalecen el poder adquisitivo y la capacidad de inversión de todo público.

Los artículos que presentan datos históricos y también nombran los algoritmos CNN, DT, LiR, LR, KNN, SVM, LightGBM, XGBoost, AdaBoost, RGF. En este grupo de factores son mínimo 13 artículos y máximo 25 artículos que tratan sobre datos históricos.

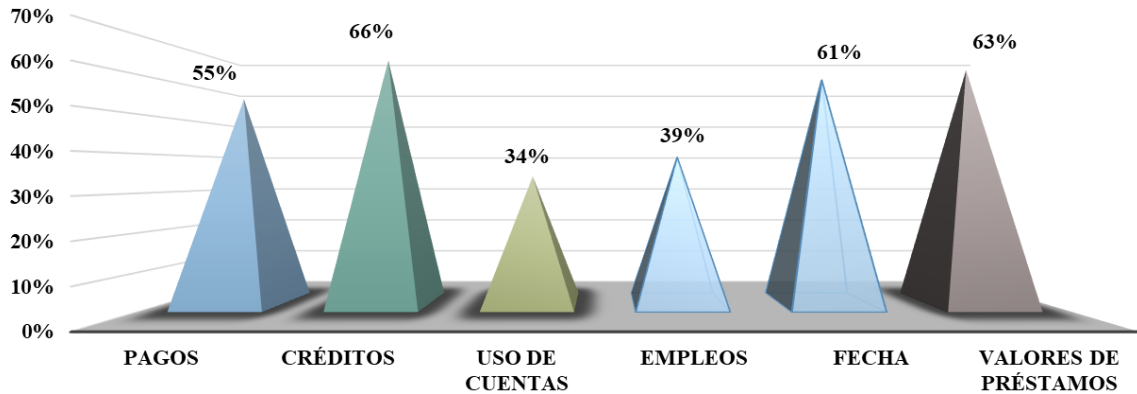


Figura 6. Datos históricos

(5) ¿Los artículos presentan procesos como diseño y pruebas de los algoritmos?

En este grupo se refiere como diseño a la presentación de modelos basados en algoritmos IA, y pruebas se refiere a las respectivas simulaciones o implementaciones o ejecución de los modelos basados en algoritmos IA. En los artículos seleccionados, el 71% presenta diseños de los algoritmos y 63% presenta las simulaciones. Es decir 27 artículos mantienen solo el diseño y 24 realizaron simulaciones en varias herramientas de software. Cabe señalar que los 24 artículos han realizado simulaciones en los 16 algoritmos IA nombrados en la primera pregunta de investigación, ver figura 7. Los algoritmos que más simulaciones tienen son CNN, LR y RF.




Figura 7. Procesos

(6) ¿Qué tipos de actividades ejecutan los algoritmos IA utilizados?

En los artículos seleccionados se hallaron un total de 5 actividades que ejecutan los algoritmos IA que están distribuidos de la siguiente manera. Clasificación en 68%, Agrupación en 21%, Predicción en 47%, Análisis en 55%, y Precisión en 50%. Las cifras indican que la Clasificación es la actividad más ejecutada por los algoritmos, le sigue el Análisis de datos, ver figura 8.

Los algoritmos LR para optimizar la solidez de la clasificación en datos desequilibrados, de acuerdo a pruebas de los artículos existe eficacia para “mejorar el rendimiento de tareas de clasificación de datos desequilibrados”, además, las empresa financieras seleccionan el clasificador de LR por su capacidad explicativa (Yan et al., 2023).

El algoritmo NB tiene un buen clasificador por su velocidad y uso de memoria, son excelentes para distribuciones simples. El algoritmo SVM tiene un clasificador con buena precisión de clasificación y mantiene menor cantidad de variables de entrada (Okesola et al., 2019).

En cuanto al factor Clasificación, se acuerdo a las pruebas realizadas por (Achary & Shelke, 2023) los algoritmos LR, KNN, SVM, DT, RFC y NB tienen buenos componentes de clasificación de datos, pero NB es mejor en precisión para clasificación.

De acuerdo a (Panduro-Ramirez et al., 2022) el algoritmo RF se utiliza para afrontar los problemas de regresión y clasificación; se ejecuta en paralelo, y genera árboles de decisión para gran cantidad de muestras y recobra gran cantidad de los votos para la clasificación y el promedio para la regresión. Por otra parte, RF es excelente para la predicción porque genera y entrega resultados de clasificación muy altos.

En cuanto al factor Análisis, cada vez es más aplicable por la disponibilidad de grandes conjuntos de datos e incremento del rendimiento informático que favorecen a la productividad y la toma de decisiones. Aquí, las simulaciones son aprovechadas para el análisis por las características de aprendizaje automático, minería de datos y modelados (De la Fuente et al., 2019).

En cuanto al factor Predicción, de acuerdo a (Wu, 2022) los algoritmos RF, DT y LR. RF es superior en rendimiento de predicción porque construye múltiples árboles de decisión para optimizar la cobertura y precisión de todos los datos de la muestra, y el algoritmo se ajusta mejor. Además, para datos desequilibrados, RF es un “representante del método de clasificación no lineal” y mantiene una efectiva aplicación para resolver la clasificación de datos

desequilibrados. En otras palabras, desde el enfoque científico, RF es mejor para “pronosticar comportamientos crediticios riesgosos”.

En cuanto al factor Precisión, algunos artículos realizan ajustes de parámetros en los algoritmos, y comparan datos como especificidad, precisión, sensibilidad y puntuación, para evaluar los algoritmos en las fases de prueba. En este grupo de factores son mínimo 8 artículos y máximo 26 artículos que tratan sobre estas actividades.

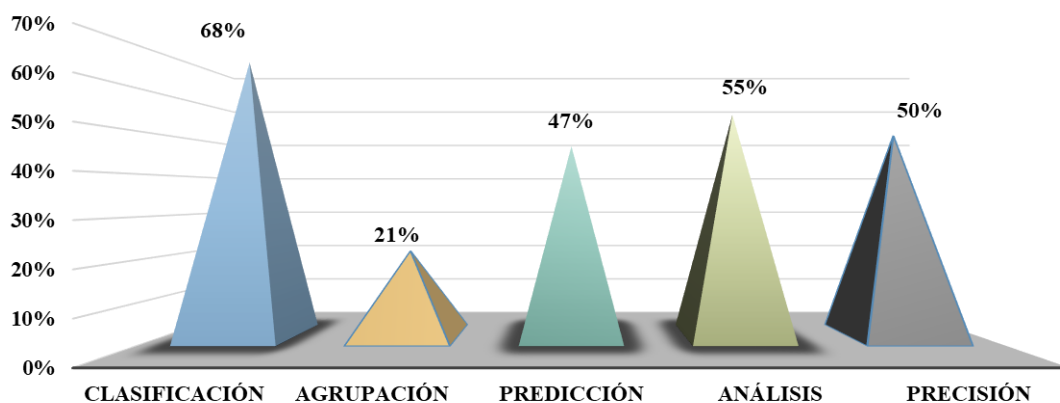


Figura 8. Actividades

(7) ¿Cuáles son los indicadores que presentan en los créditos bancarios?

En los artículos seleccionados se hallaron un total de 7 indicadores que están distribuidos de la siguiente manera. Estabilidad en 21%, Volumen de Negocios en 11%, Probabilidad en 18%, Solvencia en 34%, Rotación en 26%, Fracazos en 5%, y Precisión en 58%. Las cifras indican que la Precisión es el factor más presentado en los artículos científicos por las pruebas o simulaciones realizadas, le sigue en menor escala Solvencia y Rotación, ver figura 9.

De acuerdo a (Kotb, 2023) los modelos basados en algoritmos IA se entrenan utilizando un conjunto de datos y se evalúan con otro un conjunto de prueba a través de varias métricas de rendimiento tales como Exactitud, Precisión y Recuperación. Con esto, se puede optimizar el proceso de Calificación de Crédito Bancario (CCB) y mejorar la Precisión en las predicciones de CCB. Además, las etiquetas de los datos del conjunto de pruebas se utilizan para calcular la precisión de cualquier modelo basado en algoritmo IA, este proceso se conoce como puntuación de precisión.

La investigación de (Panduro-Ramirez et al., 2022) afirma que los modelos basados en algoritmos IA se evalúan de acuerdo a métricas como precisión, exactitud y recuperación. La

Exactitud revela qué tan educada es el pronóstico de los modelos; la Precisión revela la cantidad de clases positivas verdaderas; la Recuperación muestra la cantidad de clases positivas verdaderas reales. De acuerdo con pruebas, el algoritmo RF tiene mayor precisión que KNN con menor precisión.




Figura 9. Indicadores

De acuerdo a (Babu & Pratap, 2020) la Precisión es la medida del desempeño. Afirman que en las pruebas, CNN alcanzó una precisión del 99,62%. CNN mantiene una precisión del modelo muy estable. En este caso, CNN es utilizado para la detectar fraude en las transacciones de los clientes.

En este grupo de factores son mínimo 2 artículos y máximo 22 artículos que tratan sobre estos indicadores.

(8) ¿Qué software se utiliza para realizar las pruebas o implementaciones de los algoritmos?

En los artículos seleccionados se hallaron un total de 8 herramientas de software utilizados para entrenamiento y pruebas de los algoritmos IA, están distribuidos de la siguiente manera. Matlab en 11%, AttrList en 3%, SPSS en 3%, Python en 8%, R en 3%, EDA en 3%, Kaggle en 18%, IBM PowerAI en 3%. Las cifras indican que Kaggle es la opción más utilizada en entrenamiento-pruebas en 7 artículos; le sigue Matlab como software utilizado en 4 artículos. Una tercera herramienta es Python utilizada en 3 artículos, ver figura 10.

Kaggle es una plataforma que ofrece conjunto de datos, competencias, modelos y código para comunidades que trabajan en AI dirigido a algoritmo Machine Learning (Kaggle, 2023).

Matlab es una plataforma de computación y programación numérica que se utiliza para desarrollar algoritmos, análisis de datos y creación de modelos basados en AI (Llerena Izquierdo, 2023; Matlab, 2023).

Python permite integrar otros sistemas en forma efectiva (Llerena Izquierdo, 2020; Python, 2023).




Figura 10. Software

Identificar las tendencias y avances tecnológicos recientes en IA dentro del ámbito financiero.

En los artículos seleccionados se hallaron 6 posibles tendencias que se muestran en la tabla 3. Aplicaciones móviles en 21%, Servicios Bancarios en 50%, Aumento de la Seguridad en 53%, Análisis de datos en 55%, Identificar fraudes en 39%, y Marketing dirigido a clientes en 29%.

Tabla 3. Directrices

Tendencias	Cant
Aplicaciones móviles, Servicios Bancarios, Aumento de la Seguridad, Análisis de datos, Identificar fraudes, Marketing dirigido a clientes	6

Fuente: Autores.

Las cifras indican que el Análisis de Datos es la principal tendencia seguida del Aumento de la Seguridad sobre la información.

Los algoritmos IA realizan análisis de los datos recopilados, mediante el entrenamiento y pruebas para predecir nuevas entradas. Además, es posible que los datos sean analizados en tiempo real, mediante un proceso único. Los algoritmos pueden monitorear y aprender para entender y presentar el análisis de datos de acuerdo a la información disponible (Cherif et al., 2022).




Figura 11. Tendencias

Es muy importante mantener en forma segura a las plataformas de almacenamiento de datos que hoy son muy dimensionadas por la vulnerabilidad de los datos de los clientes, que pueden sufrir robos e infracciones. Algunos autores insisten en la identidad digital, para realizar el depósito en línea de información personal o empresarial, además sirve para identificación y verificación, y hoy en día es trascendental la autenticación en transacciones financieras. Los bancos tienen múltiples fuentes de información para identificar a sus clientes, como historial de pagos, informes crediticios, nombres de parientes o fechas (Kotb, 2023).

Los avances tecnológicos se dirigen a: Uso de Chatbot. Reconocimiento facial. Biometría. Asistente virtual. Clientes digitales. Análisis de información. Servicios personalizados. Seguridad de datos. Inversión algorítmica. Aprobaciones automatizadas.

Establecer los resultados de la revisión sistemática para ofrecer recomendaciones.

En los artículos seleccionados se hallaron 6 recomendaciones que se muestran en la tabla 4. Mejorar experiencia de clientes en 47%, Toma de decisiones en 58%, Fortalecer infraestructura en 26%, Automatización de créditos en 18%, Control de impagos en 32%, Cambiar a un modelo operativo en 24%, ver figura 12.

Las cifras indican que la Toma de decisiones es la principal comisión al utilizar los algoritmos IA, seguida de Mejorar la experiencia de clientes.

Tabla 4. Representaciones

Recomendaciones	Cant
-----------------	------

Mejorar experiencia de clientes, Toma de decisiones, Fortalecer infraestructura, Automatización de créditos, Control de impagos, Cambiar a un modelo operativo	6
----------------------------------------------------------------------------------------------------------------------------------------------------------------	---

Fuente: Autores.

Los algoritmos IA analizan los datos para aprender y Tomar Decisiones Informadas fundamentadas en lo aprendido; el algoritmo CNN que está estructurado en capas puede aprender y tomar decisiones en forma inteligente (De la Fuente et al., 2019). Los resultados de (Kotb, 2023) presentan el algoritmo RF que tiene eficacia y mejor precisión de la predicción de calificaciones crediticias; lo convierte en una buena herramienta de capacidad en la entrega de crédito y mejorar la transparencia en la toma de decisiones crediticias e informadas.

La toma de decisiones realizadas por los bancos utilizan como herramienta la calificación crediticia para entregar o negar solicitudes de crédito hechas por sus clientes; existen enfoques tradicionales o IA para generar modelos de calificación crediticia bancaria y evalúan el riesgo del crédito (Okesola et al., 2019). Algunos de los algoritmos que apoyan la toma de decisiones son: DT, LR, RF, SVM, CNN.

Por otra parte, la experiencia de clientes es mejor por las herramientas digitales que generan conveniencia y comodidad; las herramientas entregan información en cualquier tiempo a los clientes en forma personalizada, pero se considera que existe resistencia de los clientes en momentos de automatizar todas las transacciones financieras; por esta razón algunos prefieren el acercamiento humano para ejecutar ciertas operaciones (Ordóñez-Granda et al., 2020).




Figura 12. Recomendaciones

De acuerdo a (Torres-pereira, 2020) los esfuerzos de la banca ecuatoriana se centran en el avance digital sobre los servicios bancarios mediante el uso de TIC, esta es una estrategia que beneficia el desarrollo de la banca virtual o física o en línea, y adiciona nuevos tipos de clientes. Estas adaptaciones de servicios bancarios al mercado de hoy requieren de estrategias que generen nuevas experiencias y que sean experiencias personalizadas para el cliente para obtener su preferencia hacia determinado banco o financiera.

Contexto Ecuatoriano

Las siguientes respuestas pertenecen solo a los 12 artículos hallados, direccionados y de autores de Ecuador.

(1) ¿Qué algoritmos de Inteligencia Artificial son utilizados?

En los 12 artículos ecuatorianos, los algoritmos están distribuidos de la siguiente manera. Convolutional Neural Networks (CNN) en 8%, Decision Tree (DT) en 25%, Linear Regression (LiR) en 25%, Logistic Regression (LR) en 33%, K-Nearest Neighbors (KNN) en 25%, Support Vector Machine (SVM) en 42%. Los otros algoritmos no son nombrados ni utilizados. El algoritmo más nombrado es SVM, ver figura 13.




Figura 13. Algoritmos en contexto ecuatoriano

(2) ¿Qué datos demográficos analizan los algoritmos IA?

En los 12 artículos ecuatorianos, los datos demográficos están distribuidos de la siguiente manera. Género en 50%, Edad en Años en 50%, Domicilio en 50%, Estado civil en 50%, Años como residente en 50%, Estado crediticio en 50%, Valor de vehículos en 75%, Valor de

casa en 75%, Valor de terrenos en 75%, Ingresos en 83%, Origen de transacción en 58%, Tipo de cliente en 58%, Código postal en 50%, y Nivel de educación en 17%. Los ingresos y propiedades son los datos de mayor consideración en Ecuador, ver figura 14.

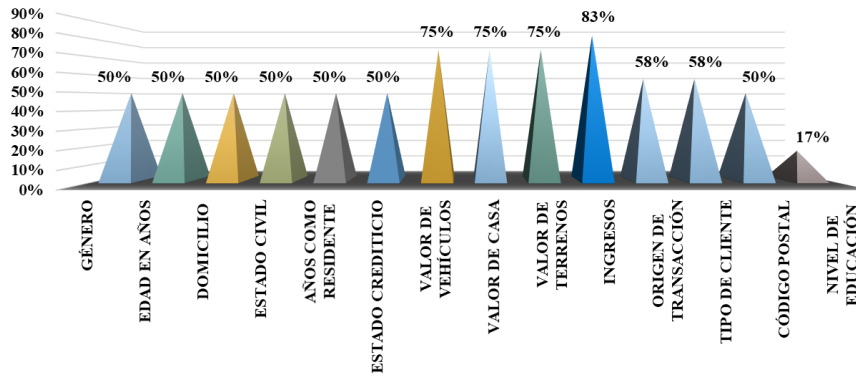


Figura 14. Datos demográficos en contexto ecuatoriano

(3) ¿Qué datos de empresas analizan los algoritmos IA?

En los 12 artículos ecuatorianos, los datos empresariales están distribuidos de la siguiente manera. Ventas o Facturación en 42%, Compras en 42%, Calificación de Riesgo en 50%, Cumplimientos en 50%, Clientes en 50%, y Tasa de Interés en 8%. Aquí los rasgos de cumplimiento y calificación son muy importantes, ver figura 15.

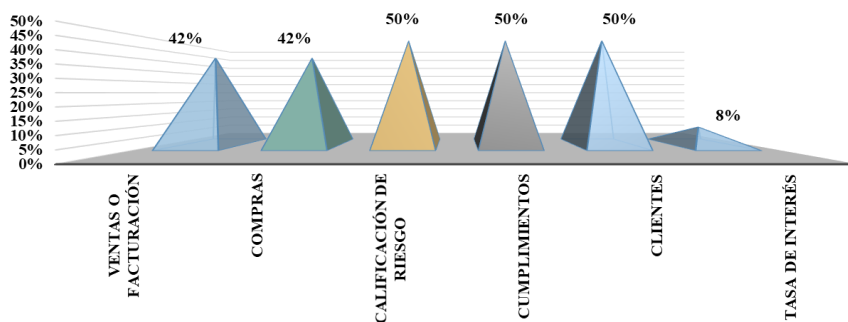


Figura 15. Datos empresariales en contexto ecuatoriano

(4) ¿Qué datos históricos analizan los algoritmos IA?

En los 12 artículos ecuatorianos, los datos históricos están distribuidos de la siguiente manera. Pagos en 75%, Créditos en 75%, Uso de cuentas en 58%, Empleos en 75%, Fecha en 75%, y Valores de préstamos en 83%. Aquí, los préstamos recibidos por los clientes tienen mucha importancia para conocer su evolución crediticia, ver figura 16.




Figura 16. Datos históricos en contexto ecuatoriano

(5) ¿Los artículos presentan procesos como diseño y pruebas de los algoritmos?

En los 12 artículos ecuatorianos, los procesos están distribuidos de la siguiente manera. El Diseño en 25% y las Pruebas en 17%. Solo 3 artículos presentaron diseño y solo 2 artículos presentaron pruebas, ver figura 17.




Figura 17. Procesos en contexto ecuatoriano

(6) ¿Qué tipos de actividades ejecutan los algoritmos IA utilizados?

En los 12 artículos ecuatorianos, las actividades de los algoritmos IA están distribuidas de la siguiente manera. El Clasificación en 75%, Agrupación en 0%, Predicción en 58%, Análisis en

83%, y Precisión en 17%. Los algoritmos son más utilizados para el análisis de los datos, ver figura 18.




Figura 18. Actividades en contexto ecuatoriano

(7) ¿Cuáles son los indicadores que presentan en los créditos bancarios?

En los 12 artículos ecuatorianos, los indicadores están distribuidos de la siguiente manera. Estabilidad en 42%, Volumen de negocios en 8%, Probabilidad en 33%, Solvencia en 75%, Rotación en 0%, Fracaso en 0%, y Precisión en 17%. Aquí, la solvencia o liquidez en dinero de los clientes es el factor más importante, ver figura 19.




Figura 19. Indicadores en contexto ecuatoriano

(8) ¿Qué software se utiliza para realizar las pruebas o implementaciones de los algoritmos?

En 2 artículos del contexto ecuatoriano que realizaron pruebas, ninguno nombra el software de ejecución, por esta razón no hay ningún resultado.

En cuanto a Tendencias marcadas por los 12 artículos ecuatorianos, son: Aplicaciones móviles en 58%, Servicios Bancarios en 67%, Aumento de la Seguridad en 58%, Análisis de Datos en 83%, Identificar fraudes en 42%, y Marketing dirigido a clientes en 42%. Aquí, la primera tendencia es el análisis de datos para conocer mejor el entorno del cliente bancario, ver figura 20.




Figura 20. Tendencias en contexto ecuatoriano

En cuanto a Recomendaciones marcadas por los 12 artículos ecuatorianos, son: Mejorar experiencia de clientes en 58%, Toma de decisiones en 83%, Fortalecer infraestructura en 42%, Automatización de créditos en 25%, Control de impagos en 33%, y Cambiar a un modelo operativo en 42%. Aquí, la Toma de Decisiones también es la principal causa para utilizar algoritmos IA en el contexto ecuatoriano, ver figura 21.




Figura 21. Recomendaciones en contexto ecuatoriano

5. DISCUSIÓN

De acuerdo con los artículos seleccionados. Los algoritmos más utilizados en créditos bancarios son CNN, DT y LR. Los datos más analizados son la Edad en años y los Ingresos de Dinero. Los factores importantes procesados sobre clientes empresariales son la Calificación de Riesgo y el Cumplimiento. El factor principal de procesamiento es el historial crediticio de una empresa. La actividad más ejecutada por los algoritmos es la Clasificación. El factor más presentado en los artículos científicos es la Precisión. Las herramientas de software más utilizadas son Kaggle y Matlab.

Algunos artículos construyeron modelos de calificación crediticia bancaria en unos casos son mejorados y en otros casos son efectivos en uso de memoria. Todos los artículos que realizaron implementaciones sobre conjunto de datos en entrenamiento y pruebas. Los créditos bancarios pueden ser calificados como bueno o malo, aprobado o no aprobado.

Los artículos utilizan diferentes métricas, como exactitud, precisión, recuperación, tasa de verdaderos positivos, tiempo de clasificación, tiempo de predicciones, matriz de tasas de falsos positivo. Además, utilizan diferentes tipos de datos, diferentes tamaños de datos, diferentes fuentes de datos, diferentes arquitecturas, entre otros; por esto no es posible comparar los resultados entre los artículos.

Si las emergencias externas afectan a nivel local o global entonces las empresas o clientes se ven afectados en su calificación crediticia bancaria, y esto inquieta la estrategia crediticia de los bancos. Esto pasó en el año 2020 con el virus Coronavirus que golpeó la economía de las empresas, y logró la disminución de facturación e incremento de deuda; muchas empresas tuvieron mala calificación crediticia sin importar el algoritmo IA que se utilice. Esto acarrea, que los bancos reciban mala calificación, alta tasa de interés y bajos créditos para los clientes; por otra parte, el incremento de la facturación y transacciones de los clientes generan una mejor calificación crediticia en cualquier algoritmo IA, por consiguiente, los bancos entregan mejor tasa de interés y altos créditos. Las afectaciones internacionales como epidemia o guerra generan una demanda de endeudamiento para las empresas, es cierto que la tasa de interés de los bancos puede aumentar o disminuir, pero los bancos incrementan sus ingresos con créditos de mayor monto.

6. CONCLUSIÓN

El estado del arte se desarrolló con 12 artículos científicos de Ecuador y 26 artículos de otros países, y tratan sobre créditos bancarios basados en algoritmos IA.

La revisión de la literatura dio a conocer 64 factores distribuidos en 8 grupos como: Algoritmos de Inteligencia Artificial, Datos demográficos, Datos de empresas, Datos históricos, Procesos, Actividades de los algoritmos, Indicadores y Software.

Las tendencias y avances tecnológicos están basadas en datos hallados en las referencias, aunque no son específicos si son cercanos a los términos. A nivel global la primera tendencia es el Análisis de datos en 55%, y la primera recomendación es la Toma de Decisiones en 58%. En el contexto ecuatoriano la primera tendencia es el Análisis de Datos en 83%, y la primera recomendación para utilizar IA es la Toma de Decisiones en 83%.

Las recomendaciones son tomadas de los mismos artículos seleccionados, Mejorar experiencia de clientes, Toma de decisiones, Fortalecer infraestructura, Automatización de créditos, Control de impagos, Cambiar a un modelo operativo. Se recuerda considerar que no todos los artículos se apegan a las recomendaciones.

REFERENCIAS

- Achary, R., & Shelke, C. J. (2023). Fraud Detection in Banking Transactions Using Machine Learning. *2023 International Conference on Intelligent and Innovative Technologies in Computing, Electrical and Electronics (IITCEE)*, 221–226. <https://doi.org/10.1109/IITCEE57236.2023.10091067>
- Alvarado-Salazar, R., & Llerena-Izquierdo, J. (2022). Revisión de la literatura sobre el uso de Inteligencia Artificial enfocada a la atención de la discapacidad visual. *Revista InGenio*, 5(1), 10–21. <https://doi.org/https://doi.org/10.18779/ingenio.v5i1.472>
- Azhan, M., & Meraj, S. (2020). Credit Card Fraud Detection using Machine Learning and Deep Learning Techniques. *2020 3rd International Conference on Intelligent Sustainable Systems (ICISS), Nov 2018*, 514–518. <https://doi.org/10.1109/ICISS49785.2020.9316002>
- Babu, A. M., & Pratap, A. (2020). Credit Card Fraud Detection Using Deep Learning. *2020 IEEE Recent Advances in Intelligent Computational Systems, RAICS 2020*, 32–36. <https://doi.org/10.1109/RAICS51191.2020.9332497>
- Barragán-Martínez, X. (2023). Situation of Artificial Intelligence in Ecuador in relation to the leading countries of the Southern Cone region. *FIGEMPA: Investigación y Desarrollo*, 16(2), 23–38. <https://doi.org/10.29166/revfig.v16i2.4498>
- Barredo-ibáñez, D. (2021). *Artificial intelligence , communication , and democracy in Latin America : a review of the cases of Colombia ,*. 1–15.
- Cherif, A., Alshehri, S., Kalkatawi, M., & Imine, A. (2022). Towards an intelligent adaptive security framework for preventing and detecting credit card fraud. *Proceedings of IEEE/ACS International Conference on Computer Systems and Applications, AICCSA, 2022-Decem*, 1–8. <https://doi.org/10.1109/AICCSA56895.2022.10017814>
- De la A-Muñoz, S. (2023). *Audit of the future, prospective and artificial intelligence to anticipate risks in organizations*. 6(1), 105–119.
- De la Fuente, R., Erazo, I., & Smith, R. L. (2019). Enabling intelligent processes in simulation utilizing the tensorflow deep learning resources. *Proceedings - Winter Simulation Conference, 2019-Decem*, 1108–1119. <https://doi.org/10.1109/WSC.2018.8632539>
- Demertzi, V., & Demertzis, K. (2023). A Hybrid Ontology Matching Mechanism for Adaptive Educational eLearning Environments. *International Journal of Information Technology & Decision Making*, 22(06), 1813–1841. <https://doi.org/10.1142/S0219622022500936>
- Elizabeth, L., Enríquez, R., & Politécnica, U. (2019). *Artificial intelligence and innovation : fields of application for Ecuador industry*. 163–172.
- I, A. L. Q., Ii, M. P., & Telot-, J. A. (2019). *Management information system for cajas solidarias of Ecuador*. XXXIV(1), 67–77.
- Janet, B., R, J. A. K., Phani, D., & Ganesh, S. (2022). Credit Card Fraud Detection with Unbalanced Real and Synthetic dataset using Machine Learning models. *2022 International Conference on Electronic Systems and Intelligent Computing (ICESIC)*, 73–78. <https://doi.org/10.1109/ICESIC53714.2022.9783529>
- Kaggle. (2023). *Kaggle*. <https://www.kaggle.com/>
- Kotb, M. O. (2023). Credit Scoring Using Machine Learning Algorithms and Blockchain Technology. *1st International Conference of Intelligent Methods, Systems and Applications, IMSA 2023*, 381–386. <https://doi.org/10.1109/IMSA58542.2023.10217411>
- Li, X. (2021). Application and influence of artificial intelligence technology in commercial banks. *Proceedings - 2021 2nd International Conference on Computer Science and Management Technology, ICCSMT 2021*, 455–458. <https://doi.org/10.1109/ICCSMT54525.2021.00089>

- Llerena Izquierdo, J. (2020). *Codifica en Python*.
<http://dspace.ups.edu.ec/handle/123456789/19346>
- Llerena Izquierdo, J. (2023). *Guía de aprendizaje de programación*.
<http://dspace.ups.edu.ec/handle/123456789/24037>
- Lohani, B. P., Trivedi, M., Singh, R. J., Bibhu, V., Ranjan, S., & Kushwaha, P. K. (2022). Machine Learning Based Model for Prediction of Loan Approval. *2022 3rd International Conference on Intelligent Engineering and Management (ICIEM)*, 465–470.
<https://doi.org/10.1109/ICIEM54221.2022.9853160>
- Matlab. (2023). *Matlab* (p. 1). <https://www.mathworks.com/products/matlab.html>
- Mining, D., Linked, M., & Artificial, T. O. (2019). *Métodos de minería de datos ligados a la inteligencia artificial aplicables a riesgo crediticio*.
- Motora, P. (n.d.). Detecting Fraudulent Bank Transactions Using Deep Learning Enhanced with Genetic Programming. *2022 IEEE 18th International Conference on Intelligent Computer Communication and Processing (ICCP)*, 151–158.
<https://doi.org/10.1109/ICCP56966.2022.10053953>
- Mubalalike, A. M., & Adali, E. (2019). Deep Learning Approach for Intelligent Financial Fraud Detection System. *2018 3rd International Conference on Computer Science and Engineering (UBMK)*, 598–603. <https://doi.org/10.1109/UBMK.2018.8566574>
- N, H. P., Rathika, P. D., & Pushparaj, A. (2023). Privacy Preservation Using Federated Learning for Credit Card Transactions. *2023 International Conference on Intelligent Systems for Communication, IoT and Security (ICISCoIS)*, 398–403.
<https://doi.org/10.1109/ICISCoIS56541.2023.10100577>
- Ogme, F., Yavuz, A. G., & Guvensan, M. A. (2021). *Temporal Transaction Scraping Assisted Point of Compromise Detection With Autoencoder Based Feature Engineering*. 9.
- Okesola, O. J., Okokpujie, K. O., Adewale, A. A., John, S. N., & Omoruyi, O. (2019). An Improved Bank Credit Scoring Model: A Naïve Bayesian Approach. *International Conference on Computational Science and Computational Intelligence*, 228–233.
<https://doi.org/10.1109/CSCI.2017.36>
- Ordóñez-Granda, E. M., Narváez-Zurita, C. I., & Erazo-Álvarez, J. C. (2020). The financial system in Ecuador. Innovative tools and new business models. *Revista Arbitrada Interdisciplinaria Koinonía*, 5(10), 195. <https://doi.org/10.35381/r.k.v5i10.693>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, n71. <https://doi.org/10.1136/bmj.n71>
- Panduro-Ramirez, J., Akram, S. V., Reddy, C. S., Ruiz-Salazar, J. M., Kanwer, B., & Singh, R. (2022). Implementation of Machine Learning Techniques for predicting Credit Card Customer action. *Proceedings of the 2022 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems, ICSES 2022*, 1–5.
<https://doi.org/10.1109/ICSES55317.2022.9914238>
- Parhizkar, A., Tejeddin, G., & Khatibi, T. (2023). Student performance prediction using datamining classification algorithms: Evaluating generalizability of models from geographical aspect. *Education and Information Technologies*.
<https://doi.org/10.1007/s10639-022-11560-0>
- Python. (2023). *Python*. <https://www.python.org/>
- Reyes Sarmiento, M. A. (2022). *Modelo de seguridad y transparencia bancaria para transferencias basado en tecnología Blockchain*.

- <http://dspace.ups.edu.ec/handle/123456789/23336>
- Reyes Sarmiento, T. P. (2022). *Modelo de optimización de procesos bancarios o financieros para agilizar procedimientos relacionados mediante Business Intelligence*. <http://dspace.ups.edu.ec/handle/123456789/23337>
- Riffi, J., Yahyaouy, A. El, Mahraz, M. A., & Tairi, H. (2020). Credit Card Fraud Detection Based on Multilayer Perceptron and Extreme Learning Machine Architectures. *Department of Computer Science, Faculty of Sciences, University Sidi Mohammed Ben Abdellah*, 3–7.
- Sanchez-Romero, J., & Llerena-Izquierdo, J. (2023). Revisión de la literatura sobre el uso del aprendizaje profundo enfocado en sistemas de inspección ópticos automatizados para la detección de defectos superficiales en el sector de la manufactura. *Revista InGenio*, 6(2), 1–19. <https://doi.org/10.18779/ingenio.v6i2.680>
- Sánchez, H. B. M. E. L. E. M. V. P. J. C. M. A. L. S. M. O. A. A. A. C. C. R. (2021). Multidimensional research on university engagement using a mixed method approach. *Educación XXI: Revista de La Facultad de Educación*. <https://dialnet.unirioja.es/servlet/articulo?codigo=7917537>
- Sánchez Peña, D. A., & others. (2023). *Ciberseguridad de la identidad digital en las transacciones electrónicas bancarias en Colombia*.
- Shi, H., Wang, Z., & Wang, X. (2022). Credit Risk Intelligent Assessment Model Based on Machine Learning. *2022 IEEE 2nd International Conference on Electronic Technology, Communication and Information, ICETCI 2022*, 735–738. <https://doi.org/10.1109/ICETCI55101.2022.9832083>
- Singla, J. (2020). A Survey of Deep Learning based Online Transactions Fraud Detection Systems. *Conference, International Engineering, Intelligent*.
- Torres-pereira, G. (2020). *Analysis of the commercial management models of*. June, 24–27. www.ediloja.com.ec
- Uquillas, A. (2020). Economic and financial determinants of bankruptcy: evidence from Ecuador's private banks and the impact of dollarization on financial fragility. *Review of Business Management*, 22(4), 949–972. <https://doi.org/10.7819/rbgn.v22i4.4080>
- Uquillas, A., & Flores, F. (2020). Determinantes económicos y financieros de la quiebra bancaria: evidencia de los bancos privados del Ecuador e incidencia de la dolarización en la fragilidad financiera. *Revista Brasileira de Gestao de Negocios*, 22(4), 949–972.
- Valdiviezo-Abad, Cesibel and Altamirano-Benítez, Verónica and Abendaño-Ramírez, M. (2020). *Colección de Comunicación Estratégica 2020. Tendencias, influencers y comunicación interna*. www.ediloja.com.ec
- Wang, J., Yang, J., Lu, G., Zhang, C., Yu, Z., & Yang, Y. (2023). Adaptively Fused Attention Module for the Fabric Defect Detection. *Advanced Intelligent Systems*, 5(2), 2200151. <https://doi.org/https://doi.org/10.1002/aisy.202200151>
- Wu, Q. (2022). Real-time Predictive Analysis of Loan Risk with Intelligent Monitoring and Machine Learning Technique. *2022 IEEE 4th International Conference on Power, Intelligent Computing and Systems (ICPICS)*, 852–856. <https://doi.org/10.1109/ICPICS55264.2022.9873618>
- Xiangjian, J. (2021). Research on Computer Intelligent Risk Prediction Model and Identification Algorithm with Machine Learning. *Proceedings of 2021 IEEE International Conference on Emergency Science and Information Technology, ICESIT 2021*, 642–648. <https://doi.org/10.1109/ICESIT53460.2021.9696813>
- Yadav, R. K., Harwani, S., Maurya, S. K., & Kumar, S. (2021). Intelligent Chatbot Using GNMT, SEQ-2-SEQ Techniques. *2021 International Conference on Intelligent*

- Technologies*, *CONIT* 2021, *MI*, 1–5.
<https://doi.org/10.1109/CONIT51480.2021.9498485>
- Yan, Y., Xiang, Q., Li, Z., Xia, Y., Zhu, B., & Jiang, R. (2023). An Adversarial Learning with Sum of Top-K Loss Framework for Credit Card Fraud Detection. *Proceedings - 2023 15th International Conference on Intelligent Human-Machine Systems and Cybernetics, IHMSC 2023*, 214–217. <https://doi.org/10.1109/IHMSC58761.2023.00057>
- You, J., Li, G., & Wang, H. (2021). Credit Grade Prediction Based on Decision Tree Model. *2021 16th International Conference on Intelligent Systems and Knowledge Engineering (ISKE)*, 668–673. <https://doi.org/10.1109/ISKE54062.2021.9755326>
- Zerega-Prado, J., & Llerena-Izquierdo, J. (2022). Arquitectura de consolidación de la información para seguros de la salud mediante Big Data. *Memoria Investigaciones En Ingeniería, 0(23 SE-Artículos)*. <https://doi.org/10.36561/ING.23.3>
- Zhang, L. (2022). Credit Decision System for Micro , Small and Medium Enterprises (MSMEs) Based on Neural Network Algorithm and Nonlinear Programming. *2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP)*, 1500–1506. <https://doi.org/10.1109/ICSP54964.2022.9778636>
- Zhang, T., & Sun, W. (2022). Research on P2P Default Risk Prediction Based on Logistic Regression. *2022 4th International Conference on Intelligent Information Processing (IIP)*, 143–146. <https://doi.org/10.1109/IIP57348.2022.00036>
- Zhou, H., Wei, L., Chen, G., Lin, P., Lin, Y., & Preprocessing, A. D. (2019). Credit Card Fraud Identification Based on Principal Component Analysis and Improved Adaboost Algorithm. *2019 International Conference on Intelligent Computing, Automation and Systems (ICICAS)*, 507–510. <https://doi.org/10.1109/ICICAS48597.2019.00111>
- Zúñiga, C. P. C. R. C. J. M. (2021). Artificial intelligence : challenges for the ecuadorian labor. *Revista Científica de La Universidad de Cienfuegos, 13(S3)*, 340–345.