

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ

FACULTAD DE CIENCIAS E INGENIERÍA



**VIABILIDAD DE MODELOS DE MACHINE LEARNING EN EL
SECTOR FINTECH CREDITICIO PERUANO: UNA
APROXIMACIÓN A TRAVÉS DE LA VIGILANCIA
TECNOLÓGICA**

Tesis para obtener el título profesional de Ingeniero Industrial

AUTOR:

RYAN ANDRÉ HERRERA ORTEGA

ASESOR:

CARLOS HERNANDEZ CENZANO

Lima, junio, 2024

INFORME DE SIMILITUD

Yo, Carlos Guillermo Hernández Cenzano,
docente de la Facultad de Ciencias e Ingeniería de la Pontificia Universidad Católica del
Perú, asesor(a) de la tesis titulada(o)


VIABILIDAD DE MODELOS DE MACHINE LEARNING EN EL SECTOR FINTECH
CREDITICIO PERUANO: UNA APROXIMACIÓN A TRAVÉS DE LA VIGILANCIA
TECNOLÓGICA

Del/de la autor(a)/de los autores(as)
Ryan André Herrera Ortega

dejo constancia de lo siguiente:

- El mencionado documento tiene un índice de puntuación de similitud de 12%. Así lo consigna el reporte de similitud emitido por el software Turnitin el 10/07/2024.
- He revisado con detalle dicho reporte y confirmo que cada una de las coincidencias detectadas no constituyen plagio alguno.
- Las citas a otros autores y sus respectivas referencias cumplen con las pautas académicas.

Lugar y fecha: Lima, 10 de julio del 2024

Apellidos y nombres del asesor/de la asesora: HERNANDEZ CENZANO, CARLOS GUILLERMO	
DNI: 07534817	Firma 
ORCID: 0000-0001-6819-2270	

RESUMEN EJECUTIVO

El presente trabajo de investigación desarrolla un estudio de vigilancia tecnológica aplicado a la búsqueda de nuevas formas de detectar casos de fraude y de mejorar la calificación crediticia de clientes dentro del ecosistema fintech de créditos, además de ofrecer un marco general de oportunidades y desafíos para su implementación en dicho sector. Dicho procedimiento toma como referencia artículos científicos, los cuales se someterán a análisis para detectar aportes clave para el objetivo en cuestión.

Respecto del macroentorno nacional descrito por el análisis PESTEL, la población nacional está mostrando una tendencia marcada al uso de la banca digital como herramienta para realizar actividades financieras, desde transferencias hasta la solicitud de créditos, así como la construcción de modelos de negocio disruptivos a partir de la explotación de nuevas tecnologías y del conocimiento de segmentos de valor con demanda insatisfecha de servicios financieros, como en el caso de las PyMEs y la población no bancarizada. No obstante, los elevados casos de fraudes digitales y porcentajes de morosidad elevados, observados sobre todo en la banca empresarial y en delitos como la usura en los préstamos gota a gota, limitan el crecimiento sostenido de la tendencia descrita, ocasionando cierta aversión a la adopción de tecnologías digitales en la banca y la temprana desaparición de modelos de negocio disruptivos. Asimismo, la poca investigación a nivel Perú respecto del tema limita las oportunidades de explotación de información y conocimiento, lo cual se traduce en la escasez de capital humano especializado en tareas de investigación y desarrollo.

Sobre el análisis bibliométrico y de patentes, se determinó que modelos de clasificación como redes neuronales, árboles de decisión (junto a su variante de bosques aleatorios) y las máquinas de vectores de soporte (SVM) son las mejores herramientas para la detección de fraudes y la clasificación crediticia. Asimismo, la combinación de estos modelos con potenciadores como los algoritmos genéticos y el uso de técnicas de boosting otorga mejores resultados de eficiencia y permite minimizar los falsos positivos y negativos dentro del análisis. Por otro lado, el uso de algoritmos generativos de información, como las redes neuronales generativas (GNN) y sus variantes, permite mitigar riesgos de sobreajuste en los modelos antes descritos mediante la reducción de sesgo con la generación de nuevas muestras a partir de la información existente.

Finalmente, es necesario destacar que conceptos de ingreso reciente, como el modelo GPT desarrollado por OpenAI y los nuevos sectores de negocio (a nivel de fintech) que Perú puede integrar, como el caso de cambio de divisas y las criptomonedas, deben funcionar como impulso para fomentar la investigación y la inversión en dichos campos por parte del ecosistema startup peruano, tanto para actualizar sus propuestas de valor como para incrementar el capital humano especializado en dichos temas.

AGRADECIMIENTOS

A Dios y a mi abuelito, que me cuidan desde el cielo y me brindan calma.

A mi madre y mi familia, por el apoyo constante durante el desarrollo del presente trabajo.

A mi asesor, el Dr. Carlos Hernández, por su paciencia por los miles de correos enviados y el apoyo con su conocimiento y experiencia para el desarrollo de la presente tesis.

A mis profesores, por los conocimientos impartidos durante mi etapa en pregrado.

A mis colegas de trabajo y amigos, por sus recomendaciones y el apoyo durante esta etapa.



Dedicatoria

A mi madre y familia, por su amor y apoyo incondicional durante mi carrera y el desarrollo del presente trabajo.

A mis profesores, por sembrar en mí las semillas de la curiosidad y de la resiliencia.

A las amistades y personas que me acompañaron y brindaron su apoyo durante mi vida universitaria.



INDICE DE CONTENIDOS

CAPÍTULO 1: INTRODUCCIÓN	1
1.1 Definición del Problema:	1
1.2 Objetivos de la Investigación:	3
1.2.1 Objetivo General:	3
1.2.2 Objetivos Específicos:	3
1.2.3 Alcance de la Investigación:	3
CAPÍTULO 2: MARCO TEÓRICO - CONTEXTUAL	5
2.1 Vigilancia Tecnológica:	5
2.2.1 Definición	5
2.1.2 Inteligencia Competitiva y su relación con la VT:	6
2.1.3 Vigilancia Tecnológica en el Perú:	7
2.2 Bibliometría, Informetría y Cienciometría	8
2.3 Marco Contextual de las Fintechs	8
2.3.1 Definición y Contexto Histórico:	8
2.3.2 Clasificación de las Fintech:	9
2.4 Inteligencia Artificial (AI):	14
2.4.1 IA aplicada a las Fintechs:	24
CAPÍTULO 3: MARCO METODOLÓGICO	28
3.1 Despliegue del Método de Vigilancia Tecnológica:	28
3.1.2 Etapa 2: Selección de las fuentes de información a analizar:	29
3.1.3 Etapa 3: Búsqueda de información en las fuentes seleccionadas:	29
3.1.4 Etapa 4: Almacenamiento de la información obtenida:	30
3.1.5 Etapa 5: Análisis e Interpretación de la Información:	30
3.1.6 Etapa 6: Informes Concluyentes de la Investigación:	30
CAPÍTULO 4: DESARROLLO DE LA METODOLOGÍA DE VIGILANCIA TECNOLÓGICA	31
4.1 Desarrollo Etapa 1: Objetivos:	31
4.1.1 Razones para realizar VT de la IA en el sector <i>fintech</i> :	31
4.1.2 Objetivos del ciclo de VT:	33
4.2 Desarrollo Etapa 2: Fuentes de Información:	34
4.2.1 Selección de Fuentes de Información:	34
4.3 Desarrollo Etapa 3: Búsqueda en Fuentes de Información:	34
4.3.1 Búsqueda de Artículos Científicos sobre IA aplicadas a Fintechs:	34
4.3.2 Búsqueda de patentes sobre IA aplicadas a Fintechs:	35

4.3.3 Búsqueda en fuentes adicionales:	36
4.4 Desarrollo Etapa 4: Uso de herramientas de documentación:	36
4.5 Desarrollo Etapa 5: Análisis de Información de Artículos Científicos:	37
4.5.1 Entorno Estratégico de la VT:	37
4.5.2 Análisis de Publicaciones:	40
4.5.3 Países con mayor producción científica:	42
4.5.4 Organizaciones investigadoras:	43
4.5.5 Análisis de palabras clave en VOSViewer:	56
4.5.6 Redes de colaboración en publicaciones científicas:	57
4.5.7 Publicaciones científicas a destacar:	59
4.6 Desarrollo Etapa 6: Análisis de Información de Patentes:	64
4.6.1 Solicitudes de Patentes en WIPO:	64
4.6.2 Clasificación de las patentes solicitadas:	65
4.6.3 Patentes a destacar:	67
CAPÍTULO 5: CONCLUSIONES Y RECOMENDACIONES	68
5.1 Conclusiones:	68
5.2 Recomendaciones:	69
CAPÍTULO 6: REFERENCIAS BIBLIOGRÁFICAS	71

ÍNDICE DE TABLAS

Tabla 1: Variables recurrentes en modelos de calificación crediticia.....	11
Tabla 2: Desglose de fuentes por su origen	29
Tabla 3: Fuentes seleccionadas para el análisis bibliométrico.....	34
Tabla 4: Fórmula de búsqueda de artículos científicos en SCOPUS.....	35
Tabla 5: Fórmula de búsqueda de patentes en WIPO	36
Tabla 6: Herramientas de análisis bibliométrico y de citado.....	36
Tabla 7: Organizaciones involucradas en aportes científicos	43
Tabla 8: Países involucrados en aportes científicos.....	44
Tabla 9: Listado de instituciones involucradas en aportes científicos.....	45
Tabla 10: Indicadores comparativos de los modelos estudiados	60
Tabla 11: Indicadores comparativos de eficiencia del modelo contra dos datasets distintos..	61
Tabla 12: Indicadores comparativos de eficiencia entre árboles de decisión y modelos SVM	62
Tabla 13: Indicadores comparativos de eficiencia del modelo BDT contra otros modelos para los dos datasets propuestos	63
Tabla 14: Listado de códigos de patentes detectados	66

ÍNDICE DE FIGURAS

Figura 1: Registro de denuncias y detenidos por delitos informáticos en Perú	2
Figura 2: Modelo intuitivo de un árbol de decisión	17
Figura 3: Modelo intuitivo de una red neuronal artificial	18
Figura 4: Representación gráfica de una SVM	19
Figura 5: Representación gráfica de la matriz de confusión de un modelo	23
Figura 6: ROC correspondiente a un modelo de machine learning	24
Figura 7: Desglose por etapas de la metodología de vigilancia tecnológica	28
Figura 8: Evolución del número de fintechs de créditos y pagos del ecosistema peruano	31
Figura 9: Evolución del monto en operaciones del sistema financiero nacional	32
Figura 10: Proporción de los medios de pago de empresas minoristas	32
Figura 11: Evolución del número de publicaciones científicas del tema en cuestión	41
Figura 12: Recuento de aportes científicos por país de origen	42
Figura 13: Desglose de países involucrados en publicaciones por año	43
Figura 14: Agrupación por palabras clave de los artículos encontrados	56
Figura 15: Análisis temporal de la agrupación por palabras clave de los artículos encontrados	57
Figura 16: Primera agrupación de países líderes en aportes científicos	58
Figura 17: Segunda agrupación de países líderes en aportes científicos	58
Figura 18: Flujo del modelo DGHNL.....	63
Figura 19: Evolución del número de solicitudes de patentes registradas	64
Figura 20: Países involucrados en solicitudes de patentes.....	65

CAPÍTULO 1: INTRODUCCIÓN

En este primer capítulo, se plantea la incógnita central sobre la cual se desarrollará el presente trabajo, así como el contexto del cual se parte para el mismo. Tras ello, se plantean los objetivos que rigen la investigación presentada.

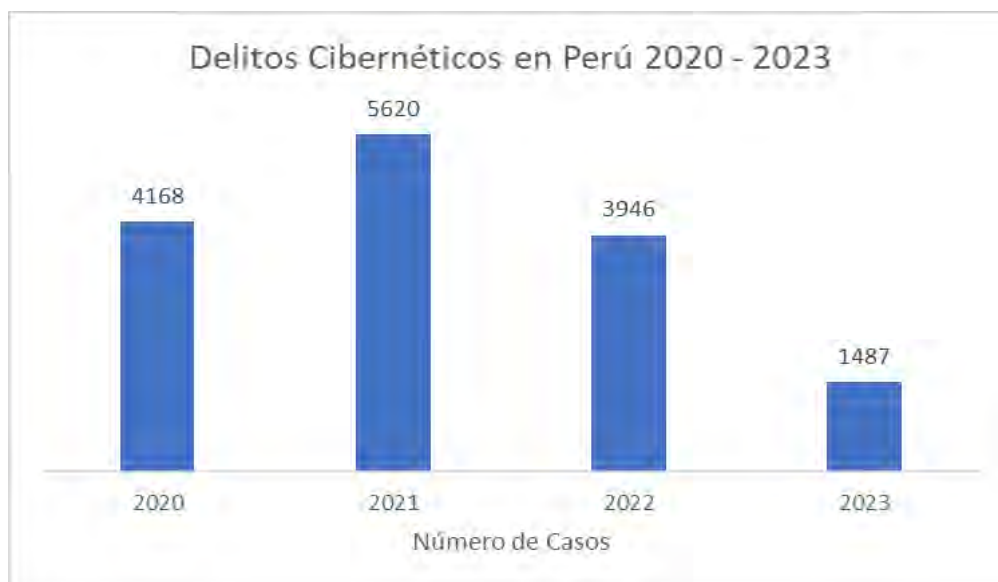
1.1 Definición del Problema:

Palomino et al. (2019) afirman que, pese al acelerado crecimiento del ecosistema *fintech* (definido por el mismo autor como el conjunto de empresas que utilizan recursos tecnológicos para ofrecer servicios financieros) nacional, una de las principales preocupaciones respecto a dicho crecimiento es la alta tasa de mortalidad, la cual asciende a 19%, siendo la segunda más alta de la región. Dentro de las causas que giran en torno a este indicador, la más visible es la falta de sistematización en materia de innovación que presentan estos modelos de negocio. Es decir, no se muestra un enfoque proactivo a la hora de buscar soluciones afines con las nuevas tecnologías e invenciones que se despliegan en el mercado.

Un problema alarmante, y potencialmente relacionado con lo anterior, corresponde a la ciberseguridad. Según la División de Investigación de Delitos de Alta Tecnología (DIVINDAT) de la Policía Nacional del Perú, se han registrado 2382 casos de fraude cibernético durante el 2022, de un total de 3946 denuncias (60.3%). Asimismo, durante el 2023, la División de Estafas de la PNP (DIVIEOD) ha registrado un total de 1487 denuncias por ilícitos digitales, cuyo monto asciende a aproximadamente 54 millones de soles. Además, el coronel PNP José Cruz afirmó que el número total de casos puede ascender a más de 6000, e incluso se han detectado situaciones en las que se utilizan modelos de Inteligencia Artificial (IA) para generar voces falsas de los familiares de las víctimas y así realizar llamadas fraudulentas solicitando dinero por esos falsos rescates (INFOBAE, 2023).

Lo anterior representa un problema de credibilidad y seguridad para estas empresas. Debido a ello, los potenciales clientes prefieren evitar el uso de estos servicios digitales al considerarlos inseguros, lo que puede ocasionar, en algunos casos, la prematura desaparición de estas empresas debido a la disminución de ingresos y la falta de confianza. La figura 1 ilustra lo mencionado:

Figura 1: Registro de denuncias y detenidos por delitos informáticos en Perú



Fuente: DIVINDAT (2023)

Por otro lado, el tratamiento de los ratios de morosidad en los productos crediticios ofrecidos por las *fintechs* representa otro factor problemático. Aunque este indicador no representa una amenaza seria para la banca tradicional, a nivel de estos modelos de negocio representa un riesgo importante. Según datos del BRCP mostrados por el diario GESTION (2023), las ratios de morosidad han aumentado de 3.97% a 4.07% en la banca de personas (créditos personales) y de 5.09% a 5.24% en la banca de empresas, siendo el sector de pequeña y mediana empresa (PyME) el de mayor participación.

En este sentido, una característica señalada por Vodanovic Legal (2019) es la incipiente consolidación del ecosistema *fintech* peruano, lo que resulta en que pocas empresas implementen tecnologías de última tendencia y, como consecuencia, exista una limitada cantidad de registros al respecto (escasez de fuentes primarias). Además, según Vargas (2021), Perú ocupa el puesto 89 de 105 países en el índice de preparación para tecnologías de vanguardia, elaborado por la ONU, lo que dificulta, en cierta medida, su implementación.

Con base en lo expuesto anteriormente, la pregunta a resolver en el presente trabajo de investigación es: ¿de qué forma el uso de tecnologías de *machine learning* (ML) y sus derivados en *fintechs* de tipo crediticio puede contribuir a la mitigación de estos riesgos y a la consecuente reducción de la temprana mortalidad de dichas empresas?

1.2 Objetivos de la Investigación:

1.2.1 Objetivo General:

Evaluar, a través de la metodología de vigilancia tecnológica, el estado actual del uso y diseño de sistemas basados en *machine learning* y sus derivados en empresas *fintech* especializadas en servicios crediticios y financieros en general. El enfoque de la evaluación se centra en las funciones de detección de fraudes y calificación crediticia, particularmente en los segmentos de valor de estas empresas. El propósito de este análisis es analizar el entorno actual, con miras a una posible implementación a nivel local.

1.2.2 Objetivos Específicos:

1. Identificar las principales novedades en cuanto a modelos y sistemas basados en *machine learning* y sus ramas afines aplicadas a las *fintechs* crediticias y empresas de servicios financieros.
2. Definir los aspectos técnicos y factores críticos de éxito que giran en torno a dichas herramientas.
3. Definir oportunidades y amenazas para su implementación a nivel Perú tanto en las *fintechs* ya existentes, como las nuevas que busquen ingresar al ecosistema.

1.2.3 Alcance de la Investigación:

Según Huerta (2023), el uso del machine learning y tecnologías derivadas está mostrando una tendencia creciente tanto en empresas de *retail* (consumo masivo) como financieras. Asimismo, según el diario El Comercio, el uso activo de las inteligencias artificiales (IA) dentro del ámbito empresarial peruano ha alcanzado el 28%. De manera similar, aproximadamente el 40% del sector empresarial peruano está llevando a cabo estudios exploratorios para evaluar su implementación. Esta tendencia se vio reforzada como resultado de la pandemia de la COVID-19, donde las empresas se enfrentaron a nuevos desafíos en términos de reducción de costos operativos, así como a nuevas formas de acercamiento a sus segmentos de valor en el marco de la virtualidad.

Proyectivamente hablando, el panorama de implementación de estas tecnologías es alentador, dada la rápida expansión del ecosistema *fintech* en Perú. Según información de EY publicada en el diario GESTIÓN, al cierre del 2023, más de 203 *fintechs* operan en el país. Dentro de este grupo, destacan las *fintechs* enfocadas en la banca digital, donde los desafíos de automatización y la necesidad de un contacto cercano con el cliente crean el entorno propicio para aprovechar

el uso de tecnologías de inteligencia artificial y similares en estos modelos de negocio. Asimismo, se presenta el reto de aumentar el porcentaje de bancarización formal de la población, prevenir el reciente aumento de casos de créditos informales (como el llamado gota a gota) y el incremento de los casos de estafas digitales a la población.

En ese sentido, el marco sobre el que se desarrollará esta investigación cuenta con un alcance exploratorio-descriptivo ya que busca descubrir cuáles son las principales novedades en tecnologías de machine learning para *fintechs* de crédito utilizando como metodología de análisis la vigilancia tecnológica (VT). El resultado esperado es un resumen de las principales novedades de diseño e implementación de estas tecnologías, así como un marco general para una posible implementación en el contexto peruano.

Por otro lado, una limitación que presenta esta investigación radica en la escasa disponibilidad de fuentes primarias, debido a que como se comentó anteriormente, el esquema de innovación de estos modelos de negocio no es sistemático y es incipiente, además del hermetismo de algunas empresas, particularmente del sector financiero. En ese sentido, el análisis bibliométrico representa una herramienta muy útil para obtener datos relevantes y entender cómo estos impactan en el ecosistema *fintech* local. Dichos conceptos se presentarán en el capítulo 2 del presente estudio.

CAPÍTULO 2: MARCO TEÓRICO - CONTEXTUAL

En el presente capítulo se desarrollarán los principales conceptos teóricos y técnicos que engloban la presente investigación, tanto de la metodología a usar como el contexto sobre el cual estos se aplican.

2.1 Vigilancia Tecnológica:

2.2.1 Definición

Un comentario realizado por Alutziza y Carrasco (2012) señala que las nuevas tecnologías están transformando radicalmente la manera en que las personas y las organizaciones transmiten conocimiento. Estos cambios motivan a las empresas a anticiparse a la información de sus competidores o del macroentorno general, transformándola en conocimiento y utilizándola de manera productiva para sus objetivos comerciales. Esta recopilación y gestión de información se conoce como *vigilancia estratégica* (VE), la cual se encarga de realizar esta transformación y contribuye a mejorar la competitividad de una empresa. La VE comprende cuatro componentes principales: vigilancia competitiva, comercial, tecnológica y del entorno. En este contexto, el presente trabajo aborda el concepto de *vigilancia tecnológica* como una metodología valiosa para transformar la información en elementos de valor para una organización (San Juan & Romero, 2016).

De acuerdo con Arango, Tamayo y Fadul (2012), la vigilancia tecnológica (VT) se define como el proceso de captación, análisis y difusión de información sobre un tema específico (financiero, tecnológico o procedimental), con el fin de detectar oportunidades y amenazas basadas en el estado del arte del tema seleccionado. Es decir, proporciona un marco de referencia para la ejecución de una actividad o la evaluación de decisiones organizacionales, como la implementación de un nuevo modelo de trabajo o el diseño de un nuevo producto. Este concepto tiene sus orígenes en los años 90 y ha sido aplicado por países como EE.UU., Francia, Suecia, Alemania, Reino Unido, Rusia e Israel (Escorsa y Maspons, 2001 citado en Guagliano et al., 2019).

Muñoz, Marín y Vallejo (2006) complementan que la VT es un proceso fundamental dentro de los proyectos de innovación tecnológica, proporcionando información para la implementación y/o creación de nuevas tecnologías, el diseño de nuevos productos o la evaluación de variables externas dentro de un modelo.

En el ámbito de la gestión de la Innovación, Desarrollo e Investigación, la Guía Nacional de Vigilancia e Inteligencia Estratégica de Argentina (2015) señala que la mayoría de las organizaciones que buscan generar propuestas innovadoras carecen de un manejo adecuado de la vigilancia tecnológica. Como consecuencia, muchas de estas iniciativas suelen encontrar barreras, ya sea porque están patentadas o porque están tecnológicamente desfasadas, lo que dificulta la competitividad y el posicionamiento de estas empresas en el mercado.

Por otro lado, Rojas (2011) afirma que esta metodología permite mantener trazabilidad sobre la evolución de la información, lo que facilita el seguimiento a lo largo del tiempo y una mejor capacidad de respuesta ante posibles cambios.

2.1.2 Inteligencia Competitiva y su relación con la VT:

Otro de los elementos que engloba el marco de la vigilancia tecnológica es el despliegue de la *inteligencia competitiva* (IC), la cual Terreros (2023) define como la capacidad de recopilar, analizar y utilizar la información que muestra el entorno competitivo de una empresa para tomar decisiones que apoyen el desarrollo de una organización en particular.

Dada la definición proporcionada en el punto anterior, ambos conceptos (IC y VT) son de naturaleza similar. Sin embargo, Panta (2022) realiza una distinción entre estos dos conceptos basada en un factor diferencial: el análisis y la gestión de la información. Esta distinción radica en el hecho de que la VT genera un abanico general de oportunidades y amenazas sobre un tema en concreto, mientras que la IC gestiona, analiza y brinda un valor agregado a dicha información con el fin de promover el desarrollo organizacional de la empresa o institución interesada.

La guía mencionada anteriormente complementa que las organizaciones, en el marco del desarrollo de su IC, deben establecer factores críticos de evaluación para mitigar posibles riesgos en la toma de decisiones, anticiparse a los cambios y obtener mejores resultados. Este aspecto puede (y debe) extrapolarse a las *fintechs* mediante el uso de los resultados de la metodología como *input* para desarrollar esquemas más sistemáticos e iterativos de innovación tanto para abordar los problemas expuestos como para enfrentar nuevos desafíos que puedan surgir, ya sea en forma de crisis económicas u otros efectos adversos de naturaleza similar.

Del mismo modo, este procedimiento es de carácter metódico y la información se puede extraer de dos grandes grupos principales de fuentes: las fuentes formales, que incluyen investigaciones científicas, patentes e información de organismos nacionales e internacionales; y las fuentes informales, que se pueden categorizar en congresos, encuestas, entrevistas, clases, simposios, entre otros (Panta, 2022).

2.1.3 Vigilancia Tecnológica en el Perú:

Dentro del marco del desarrollo nacional, según CONCYTEC, uno de los primeros hitos en lo que respecta a la vigilancia tecnológica fue el Programa Especial de Prospectiva y Vigilancia Tecnológica, que se llevó a cabo entre 2017 y 2021. Este programa tuvo como objetivo reconocer y promover la importancia de esta metodología como un elemento facilitador en los procesos de innovación y toma de decisiones, destinado a ser utilizado por instituciones encargadas de generar soluciones dentro de un marco de innovación, tales como universidades, institutos de investigación y empresas. Esto se debe a que los recursos y el capital humano disponibles para este fin aún son muy escasos dada la débil difusión de estas herramientas y la poca familiarización del personal en estos conceptos (OVTT UA, 2017).

Paralelamente, en relación con el desarrollo de proyectos de vigilancia tecnológica, el trabajo de Rivera (2018) utiliza la metodología de VT para identificar las principales oportunidades y amenazas en la exportación de productos basados en la semilla *sacha inchi*. Asimismo, el trabajo realizado por Panta (2022) exploró el panorama del uso de la manufactura aditiva en la elaboración de bicicletas.

Para ambos casos, los autores concluyen que Perú está rezagado en términos de investigaciones y desarrollos productivos de esta naturaleza, con la consecuente pérdida de oportunidades de posicionamiento respecto de otros mercados; aunque existen oportunidades para su desarrollo y explotación, tanto en términos de producción científica como de diseño de innovaciones propias y patentes. Un ejemplo de ello es el proyecto lanzado por el Observatorio de Ciencia, Tecnología e Innovación (OCTI CONCYTEC), que desde julio de 2023 publica semanalmente un boletín de vigilancia tecnológica que resume los principales avances mundiales en diversas disciplinas, particularmente en el campo de la medicina (CONCYTEC, 2023).

2.2 Bibliometría, Informetría y Cienciometría

Según Araújo y Arencibia (2002), la *bibliometría* analiza los aspectos de la información recolectada a nivel cuantitativo, permitiendo elaborar pronósticos y orientar la toma de decisiones basadas en los resultados obtenidos.

Uno de los principales enfoques de la *bibliometría* es la evolución de la cantidad de investigaciones realizadas sobre un tema específico (Escorsa y Valls-Pasola, citados en Panta, 2023). Además, Gonzales (2017) complementa que la bibliometría permite cuantificar el rendimiento de un conjunto de elementos seleccionados, en este caso, artículos y publicaciones científicas sobre un tema específico.

Otro concepto dentro del ámbito de la vigilancia tecnológica es la *informetría*. Worwell (s/f) lo define como la combinación de técnicas avanzadas de recuperación de información con su análisis. Podría considerarse como una variante más avanzada de la bibliometría, utilizando métodos estadísticos y matemáticos avanzados.

Finalmente, la *cienciometría*, según Panta (2023), se refiere al análisis de publicaciones científicas y técnicas, como patentes u otros artículos técnicos.

En el marco de esta investigación, se emplearán las técnicas de bibliometría para analizar el estado del arte de las tecnologías de *machine learning* y sus derivados aplicados a servicios crediticios a nivel mundial, y la *cienciometría* para examinar las principales patentes dentro de este campo.

2.3 Marco Contextual de las *fintechs*

2.3.1 Definición y Contexto Histórico:

De acuerdo con Bravo y Urgilés (2020), el término *fintech* hace referencia al conjunto de tecnologías y actividades relacionadas con la industria de servicios financieros (fin- de finanzas y -tech de tecnología).

Las empresas *fintech* utilizan estas tecnologías para desarrollar productos financieros de fácil acceso y bajo costo (Warthon College, citado en Bravo y Urgilés, 2020). La Cámara de Comercio de Bogotá (2018) también subraya la importancia de complementar estas tecnologías

con la educación financiera y oportunidades de microinversión para los usuarios. Un ejemplo local es *Tyba*, que fomenta la inversión en fondos mutuos para que el capital excedente de los usuarios crezca con el tiempo. Otras entidades financieras, como Interbank (inversiones en fondos colectivos y depósitos a plazo fijo) y el *Banco de Crédito del Perú* (BCP) con el portal *ABC del BCP*, siguen esta política.

Barrera et al. (2022) afirman que la introducción de estas tecnologías supuso una interrupción total en la distribución de las finanzas y la banca tradicional. Esta migración se intensificó tras la crisis económica de 2008, llevando a los bancos de todo el mundo a buscar en el desarrollo de nuevas tecnologías una ventaja competitiva a largo plazo, así como un medio más eficiente de atención y ampliación de sus segmentos de valor. Según el economista Alfredo Cardoso: "las *fintechs* cubren nichos a los que la banca tradicional no llega" (UDEP, 2023).

Además, estas empresas contribuyen al cumplimiento de los Objetivos de Desarrollo Sostenible (ODS) al apoyar la inclusión financiera, definida por el Banco Mundial como el acceso de personas y empresas a diversos productos y servicios financieros. En el Perú Fintech Forum 2023, Óscar Girón, director del Sistema Financiero y Capitales del Ministerio de Economía y Finanzas, destacó que el desarrollo del ecosistema *fintech* nacional contribuye al aumento de la bancarización de la población, resaltando la importancia de su consolidación y desarrollo continuo.

En el caso de Perú, esto cobra una gran importancia ya que, a mediados del 2023, el 42.6% de los peruanos aún no tiene acceso al sistema financiero nacional (INEI, 2023), siendo uno de los menos bancarizados de toda la región y representando uno de los principales desafíos para el sector (BE, 2022).

2.3.2 Clasificación de las Fintech:

Dentro de los principales modelos de negocio que las *fintech* han introducido se destacan los siguientes (INCYTU, 2017):

a. Pagos Electrónicos:

Dentro de esta categoría se encuentran las llamadas billeteras electrónicas. En el caso de Perú destacan dos principales: *Yape*, del Banco de Crédito del Perú (que ya cuenta con presencia en

Bolivia) y *Plin*, correspondiente a Interbank. Otro modelo correspondiente a esta categoría hace referencia a los pagos de remesas, las cuales se definen como transferencias internacionales.

b. Financiamiento Colectivo:

El *crowdfunding*, también conocido como financiamiento colectivo, agrupa plataformas que permiten a personas o empresas emergentes obtener financiamiento en línea. Dentro de esta categoría, se distinguen dos ramas principales: el *crowdfunding no financiero*, que tiene como objetivo el apoyo a proyectos altruistas, y el *crowdfunding financiero*, donde las empresas que buscan financiamiento prometen rentabilidad a los inversionistas.

Un ejemplo de este tipo de modelos es Klimb (antes Facturedo), una startup peruana con más de 6 años de operación, especializada en la inversión en cuentas por cobrar de forma masiva.

c. Préstamos:

Estas plataformas en línea proporcionan créditos a individuos de manera más rápida que los medios tradicionales, como la banca presencial. Utilizan sistemas de información basados en datos de clientes, los cuales son enriquecidos con el manejo de redes sociales¹, benchmarks locales e internacionales² y tecnologías basadas en inteligencia artificial para realizar evaluaciones de riesgo y segmentación de clientes de forma más precisa.

Una de las modalidades más tradicionales es el crédito personal, mediante instrumentos como la tarjeta de crédito. Este sector es dominado en la región por Nubank, empresa catalogada como *unicornio*³, dentro del ecosistema Fintech de Brasil. Por lo general, estas *fintechs* utilizan estos productos, ya que su sector de valor está asociado al consumo personal, de ahí el nombre de *préstamos personales* para estos productos. En el caso de Perú, destaca la *fintech Credigob*, que otorga créditos a pymes y personas, y es una de las pocas que emplea tecnologías de machine learning en sus propuestas de valor.

¹ Aquí se introduce el concepto de *sentiment analysis*. Kolungade (2020), lo define como una serie de algoritmos que permiten detectar sentimientos a partir de información textual como tweets, comentarios en RRSS, etc.

² Un caso particular de estos indicadores son las llamadas *perspectivas*, las cuales ofrecen una mirada global de determinados sectores startup en un período determinado (generalmente un año). Empresas como EY o Gartner suelen brindar dicha información.

³ Dentro del ecosistema Fintech, una empresa *unicornio* es aquella que sin haber sido adquirida por un tercero y sin cotizar en bolsa, ha alcanzado un valor de mil millones de dólares (USD).

Dentro de este ámbito, dos actividades críticas a controlar son la clasificación crediticia (*credit scoring*) y la detección de fraudes asociados a productos financieros de tipo crédito, como las tarjetas mencionadas anteriormente:

- Credit Scoring:

Según la Superintendencia de Banca, Seguros y AFP (SBS), el término *clasificación crediticia* se define como un sistema que permite predecir, a partir de ciertas variables (generalmente demográficas), la probabilidad de incumplimiento de un crédito. En función de esta predicción, se asigna una calificación. La SBS ofrece cuatro posibles calificaciones: "normal" (0), "problemas potenciales" (1), "deficiente" (2), "dudoso" (3) y "pérdida" (4). Algunas de estas variables se muestran en la tabla 1:

Tabla 1: Variables recurrentes en modelos de calificación crediticia

Variable	Valores Posibles
SEXO	Masculino (0) - Femenino (1)
EDAD	Edad del solicitante, es una variable numérica y los rangos dependen de la entidad financiera.
ESTADO CIVIL	Soltero (0) - Unidad Familiar (1)
ANTIGUO	Variable de tipo numérica que establece el tiempo de relación entre el cliente y la entidad financiera.
CLASIFICACIÓN SBS	Clasifica al cliente si es normal (0) o tiene algún problema o irregularidad (1)
SITUACIÓN LABORAL	Independiente (0) - Dependiente (1)

Fuente: Rayo Cantón - SBS (s.f.)

Villacorta (2021) amplía lo anterior al mencionar otras variables relevantes, como las vinculaciones financieras con otras entidades (por ejemplo, tarjetas de crédito de otras instituciones, saldo en cuentas bancarias), el historial crediticio y la información proveniente de entidades externas (por ejemplo, si el cliente está registrado en Infocorp). Es importante destacar que la entidad solicita documentación que respalde los elementos mencionados.

Otro indicador relevante es el *First Payment Default*, que se define como la situación en la que los clientes no amortizan la primera cuota de un préstamo. Esta variable es de naturaleza dicotómica y suele tener un impacto significativo en la solicitud de créditos por parte de los clientes (Socure, s/f). Algunas opciones adicionales que ofrece el portal, relacionadas con lo anterior, son el *Never Pay* (cuando un cliente no cumple con el pago

de su préstamo) y el *Straight Roller* (un tipo de fraude en el que un cliente solicita un crédito con la intención de no pagarlo).

El riesgo de un cálculo erróneo de este indicador radica en la reducción de los ingresos de la entidad financiera debido a los intereses del crédito no pagados, así como en el aumento de la tasa de morosidad. Un ejemplo destacado es el caso de Banco Azteca, que al cierre de 2019 tenía una tasa de morosidad del 9% y registraba pérdidas superiores a los 9 millones de soles (El Comercio, 2020).

- **Fraudes en Tarjeta de Crédito:**

En la actualidad, los pagos electrónicos son una de las formas más comunes de transacciones entre los clientes y diversas entidades. Durante este proceso, la información de la tarjeta, incluidos los doce dígitos de la misma, la fecha de vencimiento y el Código de Verificación de la Tarjeta (CVV), se transmite desde el punto de origen hasta la entidad financiera, que autoriza la transacción en tiempo real. Dado que esta información es sensible, los infractores pueden utilizarla para acceder a las líneas de crédito de los clientes y realizar operaciones bancarias fraudulentas con aparente normalidad.

Un dato que respalda lo mencionado anteriormente es que, en 2020, el 38% de los montos de transacciones catalogadas como fraudulentas tuvieron su origen en el uso de tarjetas de crédito para compras en línea (ASBANC, 2020, citado en GESTIÓN, 2021). Para obtener esta información, los infractores ejecutan diversas modalidades de fraude, las cuales se describen a continuación (BCRP, 2015):

- *Clonación o skimming*: Este procedimiento se ejecuta con un equipo de lectura y almacenamiento de datos conocido como *skimmer*, el cual extrae la información de la banda magnética de la tarjeta. Con estos datos, se crea una copia de la tarjeta. Además, en muchos casos, se requiere falsificar la firma del titular de la tarjeta.
- *‘Cambiao’*: En esta modalidad, se utiliza una copia de la tarjeta con la misma información para reemplazar (o robar directamente) la tarjeta original con una falsificada que contiene los mismos datos.
- *Phishing*: Esta táctica consiste en el envío masivo de correos electrónicos que dirigen a páginas web falsas, donde se solicita información de la tarjeta de crédito de la víctima.

- *Malware*: En esta modalidad, se instala un programa malicioso en la computadora de la víctima para extraer su información. Algunos ejemplos de malware incluyen gusanos, troyanos y virus informáticos.
- *Vishing* y *Smishing*: Estas tácticas implican el uso de llamadas telefónicas y mensajes de texto (respectivamente) para obtener información. A menudo, se hacen pasar por empleados falsos de entidades financieras, como asesores de ventas o gerentes comerciales. Algunos mensajes también contienen enlaces que redirigen a páginas web fraudulentas, generalmente similares al sitio web de la entidad bancaria.

A estas cinco modalidades, Rayo Mondragón (2020) añade una sexta:

- ‘*Regleta*’: Esta modalidad de fraude se utiliza comúnmente en cajeros automáticos (ATM), donde se colocan objetos en la ranura del dispensador de dinero (junto con un mensaje falso de error), lo que permite al infractor apropiarse del efectivo.

d. Criptomonedas:

Según el Banco Central Europeo (2015), una criptomoneda se define como un activo digital cuya emisión no está dentro del perímetro de una institución financiera central reconocida, la cual puede utilizarse como equivalente al dinero (sea físico o virtual). Una de las *fintechs* crypto más importantes es Binance.

Un elemento tecnológico fundamental en este ámbito es el blockchain, una tecnología de registro distribuido que proporciona un libro contable compartido e inmutable, permitiendo el registro y seguimiento de transacciones en una red descentralizada de negocios (IBM, s/f).

Según el informe EY Perú FinTech Index 2023/2024, de las 203 *fintechs* activas en Perú, 14 se dedican al rubro de activos virtuales, lo que representa un aumento de 5 empresas en comparación con el año anterior. Este crecimiento ha sido impulsado, en parte, por la inflación existente en la región, como señala Santiago Aldunate, PO en Capitaria. La inflación motiva a las personas a optar por criptomonedas para realizar transferencias monetarias con menores costos por concepto de comisiones.

En Perú, la actividad relacionada con activos virtuales se concentra principalmente en Lima, que representa el 57.94% del total nacional, seguido por Arequipa con el 11.16%. Estas

empresas operan en diversos sectores económicos, como la construcción, tecnología de la información y otros (EY, citado en GESTIÓN, 2024).

e. Cambio de Divisas:

El modelo de negocio descrito permite a los clientes realizar cambios de divisas de manera digital y en tiempo real. Según el Banco Central de Reserva del Perú (BCRP), estas *fintech* ofrecen tipos de cambio superiores a los de la banca tradicional, lo que las convierte en una opción preferida tanto para la población en general como para los cambistas. Actualmente, hay 30 empresas de este tipo operando en el país.

Según Omar Azañedo, CEO de Noncash, una *fintech* especializada en cambio de divisas, se espera que estas empresas movilicen más de un billón de dólares durante el año 2024, debido al tamaño significativo de este mercado y al aumento en el número de cambistas que están en proceso de digitalización (La República, 2024).

2.4 Inteligencia Artificial (AI):

El entendimiento del concepto y contexto de uso de las tecnologías de aprendizaje automático (machine learning, ML) se basa en la definición de inteligencia artificial (IA), ya que esta última sirve como su fundamento principal y visible. Según Rouhiainen (2018), la IA se refiere a la capacidad de una computadora para llevar a cabo tareas que típicamente requieren inteligencia humana, como la clasificación y discriminación, que son relevantes en el contexto de este trabajo.

Ponce (2010) añade que la IA no solo busca generar soluciones, sino que también persigue la mejor alternativa de solución a partir de los resultados obtenidos y la nueva información que recibe. Este proceso se apoya en un ciclo iterativo, que se retroalimenta con los resultados anteriores y la información entrante.

Un ejemplo reciente de aplicación de IA es la introducción de ChatGPT, un modelo que utiliza procesamiento de lenguaje natural (NLP) para entender las necesidades del usuario y generar respuestas relevantes (Gutiérrez, 2023).

En el contexto del presente trabajo, el objetivo es detectar modelos de IA orientados a la clasificación de clientes, ya sea para la evaluación de créditos o para identificar posibles fraudes

en transacciones con tarjetas de crédito. Estos modelos ofrecen resultados precisos al identificar patrones anómalos que pueden ser poco evidentes con métodos tradicionales (Sealpath, 2022).

La inteligencia artificial, como campo de estudio, se compone de dos "subcapas" fundamentales según Alonso (2023): el aprendizaje automático (machine learning) y el aprendizaje profundo (deep learning).

Machine Learning (ML):

Una primera definición de *machine learning* la propone Arthur Samuel (1959, citado en Véliz, 2020), quien lo define como una rama de la inteligencia artificial que busca brindar a la computadora, a través de una serie de algoritmos, la capacidad de aprender a partir de un conjunto de datos (sin necesidad de una secuencia de acción en particular), de modo que pueda generalizar una situación a partir de casos particulares⁴, esto con la finalidad de ejecutar procedimientos complejos o encontrar nuevas características o casos de uso sobre la información brindada. Asimismo, tienen la capacidad de actualizarse y retroalimentarse a partir de los resultados obtenidos.

Mitchell (1997, citado en Véliz, 2020) amplía dicha definición con un principio práctico:

“El aprendizaje automático comprende el estudio y diseño de programas que mejoran el desempeño P al realizar una tarea T , con base en la experiencia E ”

Briz (2018) complementa la definición anterior con la capacidad que poseen estos modelos para encontrar relaciones entre dichos datos que de otra forma (entiéndase ello como el uso de algoritmos *convencionales*) no se pueden detectar de forma trivial. Aquí Véliz (2020) introduce el concepto del *Data Mining*, el cual se define como un proceso que involucra herramientas informáticas, estadísticas y de la propia inteligencia artificial con el fin de extraer información de forma rápida y automática en algunos casos.

Otro concepto ligado por el autor al anteriormente mencionado es el Big Data, el cual se puede catalogar como una expansión del concepto anterior. Aquí se introducen dos variables clave: la *velocidad* a la cual se obtiene dicha información y la *complejidad*, puesto que esta información no suele ser necesariamente de tipo tabla. Aquí entran en juego las imágenes, archivos de sonido, elementos textuales u otros tipos no triviales de datos. Cabe destacar que

⁴ Véliz (2020) complementa que estos modelos son útiles cuando no se puede (o es muy complicado) establecer una cadena secuencial para una tarea en particular.

para explotar al máximo estas fuentes de información es menester contar con lo que el autor denomina un *pensamiento estadístico*, de modo que se puedan detectar relaciones dentro de esta información.

El principio fundamental de estos modelos radica en cuatro elementos clave: la preparación de la información, la construcción del modelo, el entrenamiento del modelo y finalmente el despliegue (AWS, s/f). Como regla práctica, se busca establecer una relación causa-efecto entre un conjunto de variables con el fin de explicar otras, se puede afirmar que siguen la siguiente relación:

$$y = F(X) + e = X$$

Donde:

y = Vector de variables dependientes objetivo

X = Vector de variables independientes

e = Error o ruido aleatorio producto de las mediciones de estas variables, su valor debería ser cercano a 0

Como se comentó líneas arriba, estos modelos cuentan con un fuerte componente estadístico⁵ para su construcción. Dentro de estos modelos, destacan los siguientes:

- Modelos de aprendizaje supervisado:

Véliz (2020) agrupa aquí los modelos que buscan explicar el comportamiento de una o más variables dependientes a partir de un conjunto de variables independientes. La lógica de estos modelos se basa en el conocimiento de variables dependientes que actúan como elementos *supervisores* para validar la efectividad del modelo construido. Para lograr ello, se divide la base de datos que alimenta el modelo en dos bloques: datos de entrenamiento y datos de prueba (donde se encuentran las variables de supervisión).

Dentro de estos modelos destacan los siguientes:

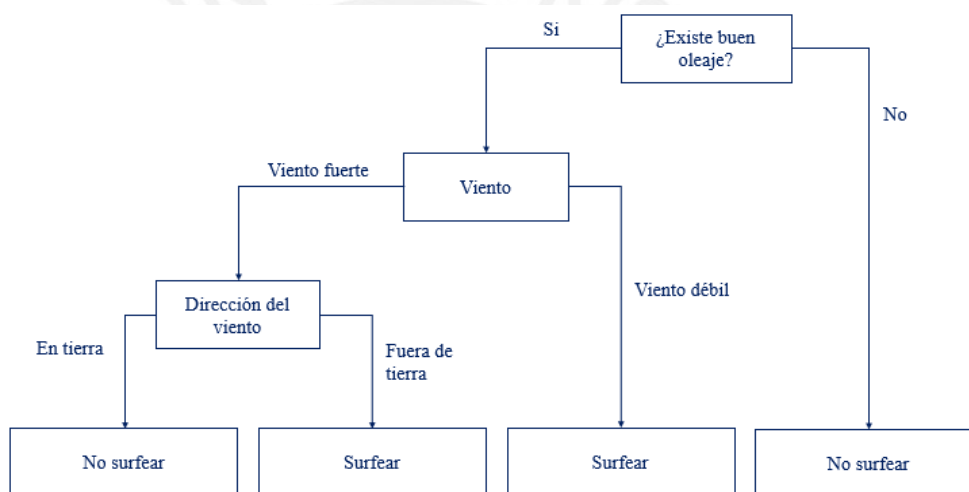
- Modelos de Regresión Lineal: Modelo que emplea variables independientes con el fin de estimar el valor de una variable dependiente. El formato de este modelo se aproxima a una ecuación lineal de grado 1 (IBM, s/f). Su forma es la siguiente:

$$Y = a_0 + a_1 * x_0 + a_2 * x_1 + \dots + a_n * x_{n-1}$$

⁵ Aquí el autor introduce el *Análisis Exploratorio de Datos (EDA)*, el cual busca obtener relaciones entre la información existente, de forma que aporte tanto a la selección del modelo como la preparación de esta información para alimentar al mismo.

- **Modelos de Regresión Logística:** Es un caso especial del modelo de regresión lineal, solo que la variable dependiente objetivo es de tipo dicotómica, es decir sólo toma valores 0 y 1. Es útil cuando se quiere estimar una variable de tipo categórica⁶ (IBM, s/f).
- **Árboles de Decisión:** Es un modelo que como su nombre lo indica, permite observar cómo se comporta una variable objetivo para características diferentes. Se basa en modelos de probabilidad, donde las ramas con mayor probabilidad consisten en las mejores rutas de acción para el modelo (IBM, s/f). La figura 2 muestra un ejemplo de estos modelos:

Figura 2: Modelo intuitivo de un árbol de decisión



Fuente: IBM (s.f.)

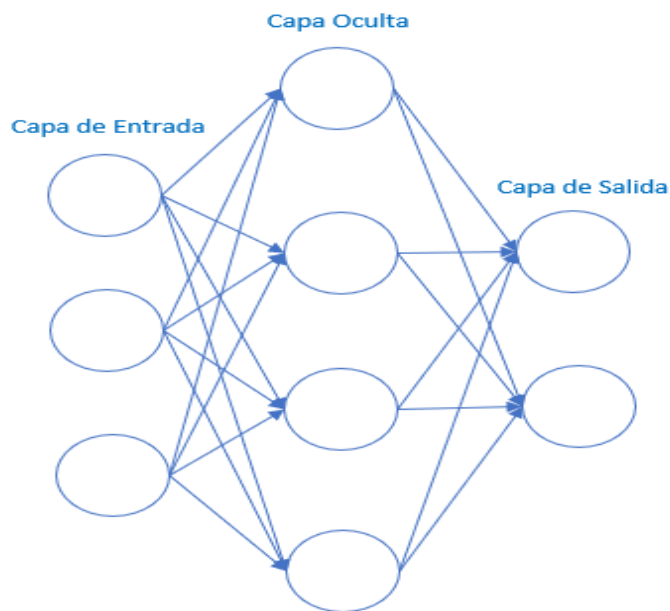
- **Redes Neuronales:** Este modelo busca emular el comportamiento de un cerebro humano, de tal forma que pueda realizar tareas de alta complejidad como reconocimiento de imágenes, caracteres o de sonido. Dichos modelos permiten a la computadora aprender de sus imprecisiones y mejorarse continuamente y de forma rápida. Estos cuentan con tres capas fundamentales: la *capa de entrada*, la cual absorbe la información, la categoriza y la transfiere a la próxima capa; la *capa oculta*, la cual ejecuta toda la analítica pertinente y la *capa de salida*, la cual puede tener uno o más nodos con los resultados del modelo (o de la variable dependiente de estudio). (AWS, s/f)

⁶ Se llama variable categórica, a una que representa un atributo o característica. Por ejemplo, si un cliente bancario tiene un régimen de gasto X, se clasifica ese gasto entre 5 rangos distintos, de modo que sea más sencillo identificarlo (Veliz, 2020).

Su funcionamiento gira en torno al *perceptrón*, el cual es la mínima unidad de una red neuronal (una neurona, en términos sencillos), la cual realiza tareas de clasificación.

Un caso especial de las redes neuronales es el concepto de *deep learning*, el cual se definirá más adelante. La figura 3 muestra un ejemplo ilustrativo de una red neuronal.

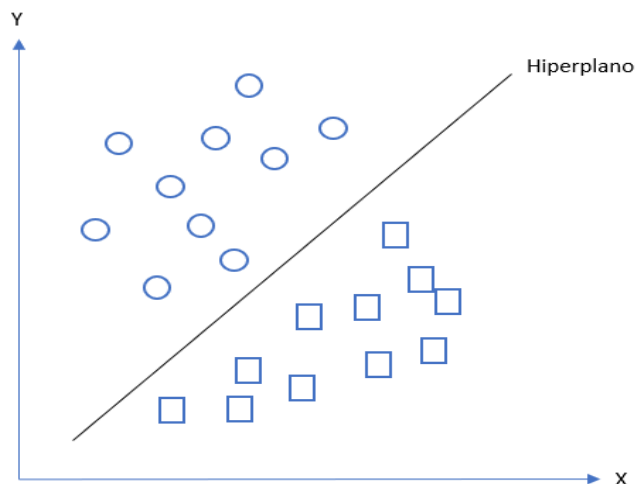
Figura 3: Modelo intuitivo de una red neuronal artificial



Fuente: AWS (s/f)

- Máquinas de Vector Soporte (SVM): Es un modelo que podría definirse en términos sencillos como un separador de datos. Aquí busca el mejor divisor de dos conjuntos de datos para clasificar. En términos matemáticos, el modelo busca la distancia máxima de separación entre los dos elementos más cercanos de la distribución de datos (de ambos grupos) mediante el mejor hiperplano calculable (Rodríguez, 2023). La figura 4 ilustra el concepto anterior:

Figura 4: Representación gráfica de una SVM



Fuente: Rodríguez (2023)

- Modelos de aprendizaje no supervisado:

El autor describe estos modelos como aquellos donde no se cuenta con variables dependientes bien definidas (variables no etiquetadas). Son modelos más orientados al análisis exploratorio (cuando no se tienen muchas referencias de cómo categorizar, o cuando es muy complejo) y suelen ser elementos de alimentación para modelos supervisados.

Algunos algoritmos destacados son:

- Agrupamiento Jerárquico: Modelo que busca crear una jerárquica a partir de la información establecida.
- Modelo K-Means: Modelo que busca agrupar datos en k grupos a partir de sus características.
- Análisis de Componentes Principales (PCA): Modelo que se emplea para analizar información con un gran número de características de forma que pueda simplificar su información.

Deep Learning (DL):

Deep Learning se define como un caso especial de las redes neuronales que ofrecen una precisión superior a los modelos de redes neuronales simples definidos en el acápite anterior. La diferencia radica en que estos modelos cuentan con múltiples capas ocultas, las cuales ejecutan un análisis mucho más preciso. Sin embargo, estas requieren un amplio volumen de información y entrenamiento constante, así como un alto poder computacional, de modo que mejoren su precisión (AWS, s/f).

Dentro del abanico de redes neuronales de aplicación frecuente en estos modelos se destacan los siguientes:

- **Modelo de Perceptrón Multicapa (MLP):** Es un modelo capaz de generar un modelo que permite predecir el valor de una o más variables dependientes sobre la base de los valores de las variables independientes. Se considera el modelo más clásico (y básico) de redes neuronales. Suele emplearse en tareas de clasificación o regresión. (IBM, s/f)
- **Redes Neuronales Convolucionales (CNN):** Este tipo de red suele emplearse para análisis de imágenes y sonidos. Emplea una *capa de convolución*, la cual extrae características relevantes del elemento a analizar, obtiene patrones y simplifica la posterior clasificación (IBM, s/f).
- **Redes Neuronales Recurrentes (RNN):** Como su nombre lo indica, este tipo de red trabaja con dependencias, las cuales permiten afinar los resultados obtenidos. Suelen emplearse en tareas de *natural language processing* (o procesamiento de lenguaje, NLP) y reconocimiento de voz. Asistentes virtuales como Siri o el Asistente de Google lo emplean. (IBM, s/f)
- **Redes Generativas Adversariales o Antagónicas (GAN):** Este modelo cuenta con la capacidad de generar información u otros elementos visuales (imágenes, sonidos, etc.). Aquí entran en juego dos elementos principales: el generador y el discriminador. El primero se encarga de generar elementos a partir de la información y el segundo (en un rol antagónico, de allí el nombre de adversarial) discrimina entre una y otra, de modo que la rama generadora afina sus resultados. (Martínez, 2020)

Modelos de Lenguaje de Gran Tamaño (LLM):

Estos modelos se basan en algoritmos de deep learning y se entrenan con grandes volúmenes de datos. Además, tienen la capacidad de responder preguntas, traducir textos, resumir documentos, completar oraciones, entre otras tareas (AWS, s/f).

Un ejemplo destacado de estos modelos es GPT. Esta inteligencia artificial desarrollada por la empresa OpenAI, puede comprender el idioma utilizado por el usuario y generar respuestas coherentes, recordando el contexto de la conversación y de forma similar a la que lo haría una persona. Una de sus versiones más recientes, GPT-3, es utilizado en plataformas de conversación como ChatGPT, que se emplea para una variedad de tareas, como resumir y traducir documentos, así como generar fragmentos de código (Gutiérrez, 2023).

En marzo de 2023 se lanzó una versión más avanzada del sistema GPT, el modelo GPT-4, el cual cuenta con una mayor complejidad de construcción en comparación con su predecesor. Esta complejidad permite la generación de respuestas más detalladas y complejas, adaptadas a las solicitudes de los usuarios (Fernández, 2023). Además, esta nueva versión ya no se limita únicamente a textos, sino que también puede incorporar documentos y archivos audiovisuales en su análisis y generación de respuestas (Pastor, 2023).

Asimismo, el propio portal de OpenAI muestra funcionalidades adicionales, en conjunto con organizaciones alrededor del mundo en tareas como personalización de aprendizaje (destacan los casos de Duolingo y Khan Academy), apoyo en compras para usuarios en supermercados (Be My Eyes⁷), búsqueda de soluciones precisas para automatización y codificación (Stripe Docs⁸) y preservación de lenguaje (utilizado por el gobierno islandés en su proyecto de preservación de su lengua franca).

Algoritmos Genéticos

Estos algoritmos constituyen una de las ramas de la IA que basan su funcionamiento en procesos biológicos como la evolución y la selección natural de Darwin. (Melián, Moreno Pérez y Moreno Vega, 2009)

Según los autores, este algoritmo responde a un problema de optimización cuya solución óptima se busca mediante el uso de probabilidades, las cuales se aplican sobre una “población” aleatoria de soluciones con el fin de elegir la mejor. Su funcionamiento, a grandes rasgos, sigue las siguientes etapas:

1. Generación de una familia aleatoria de soluciones, la cual será la población de generación 1.
2. De la población actual, elegir las mejores soluciones, es decir las que tienen mayor probabilidad de alcanzar el valor óptimo.
3. Sobre las soluciones seleccionadas, realizar la “reproducción” de estas para obtener la “descendencia” de estas (hijos de la generación 1).

⁷ Plataforma creada para apoyar a personas con discapacidad visual. La plataforma empareja a una de estas personas con un voluntario que se encarga de apoyar al discapacitado en la realización de tareas puntuales como compras, reconocer colores, entre otros.

⁸ Esta plataforma ofrece a sus usuarios modelos de código muy frecuentes de forma que se puedan integrar al Workflow de trabajo (con enfoque particular en el rubro financiero).

4. Realizar la “mutación” de las soluciones. Esto responde al principio de mutación genética, propio de la evolución de las especies (Darwin, 1959 citado en Melián, Moreno Pérez y Moreno Vega, 2009)
5. Sobre los resultados de las soluciones mutadas, elegir las más “fuertes”. Estas conformarán la generación 2 de soluciones y responde al principio de adaptación de las especies cuando cambia el entorno o evolucionan en el tiempo.
6. Si es que alguna de estas soluciones no alcanza el criterio de parada, iterar desde el paso 2 hasta alcanzar el umbral.

Boosting:

Ningún modelo de *machine learning*, y una de las grandes causas suele ser la base de datos que la alimenta. Por lo general, dichas fallas se deben a valores perdidos a la hora de extraer los datos de un servidor, valores no reconocidos por la interfaz de lectura, tipos de datos mezclados, etc (IBM, s/f). Otras causas suelen ser sesgos en la información de alimentación, o al hecho de que no se cuente con suficiente información para poder tomar una decisión objetiva (AWS, s/f).

Para contrarrestar esta problemática, se introduce el concepto de boosting, el cual toma una serie de modelos individuales de precisión baja llamados *estudiantes débiles*, debido a que son muy sensibles a datos muy alejados de la base de datos original que se usó en su entrenamiento (*outliers*) y analiza los resultados de forma conjunta para crear un único resultado y modelo (conocido como *estudiante fuerte*). (AWS, s/f)

Indicadores de Rendimiento:

Una forma de establecer qué tan bien se desempeña un modelo de *machine learning* es mediante el cálculo de ciertos indicadores de rendimiento. Particularmente, este dato es de interés cuando el modelo tiene como objetivo la clasificación, ya que se pueden presentar casos donde la clasificación positiva del modelo no corresponde a la real (falso positivo) y donde el modelo arroje un resultado negativo, pero este no es así (falso negativo). Una forma resumida de obtener estos valores es mediante la matriz de confusión (*confussion matrix*) la cual permite observar el recuento de los valores antes mencionados y ofrece una forma más sencilla de analizar los indicadores de rendimiento. La figura 5 muestra un ejemplo de lo anterior:

Figura 5: Representación gráfica de la matriz de confusión de un modelo

		Predicción del Modelo	
		<i>Característica 1</i>	<i>Característica 2</i>
Valor Real	<i>Característica 1</i>	Positivo Real (TP)	Falso Positivo (FP)
	<i>Característica 2</i>	Falso Negativo (FN)	Falso Real (TF)

Fuente: Microsoft (2023)

Se definen cuatro indicadores clave:

- Exactitud (*accuracy*): Este indicador mide la proporción de predicciones acertadas del modelo respecto del total. Cabe resaltar que esta medida es sensible a la proporción de datos dentro del *dataset* de entrenamiento. En términos de una expresión, luce de la siguiente forma:

$$Accuracy = \frac{(TP + TN)}{(TP + FP + TN + FN)}$$

- Precisión (*precision*): Ahora, sobre los casos catalogados como positivos (entiéndase estos como los casos que se espera el modelo brinde como correctos), este indicador mide la proporción de los casos que realmente son correctos sobre el total de estos. Se expresa de la siguiente manera:

$$Precision = \frac{TP}{(TP + FP)}$$

- Sensibilidad (*recall*): Este indicador se centra exclusivamente en la cantidad de positivos reales de un modelo sobre el total de casos positivos reales existentes. Se expresa de la siguiente manera:

$$Recall = \frac{TP}{(TP + FN)}$$

- Especificidad (*specificity*): Este indicador es muy similar al anterior, solo que se centra en los valores negativos reales. Se expresa de la siguiente manera:

$$Specificity = \frac{TN}{(TN + FP)}$$

Donde:

TP: *True Positive*, o positivo real

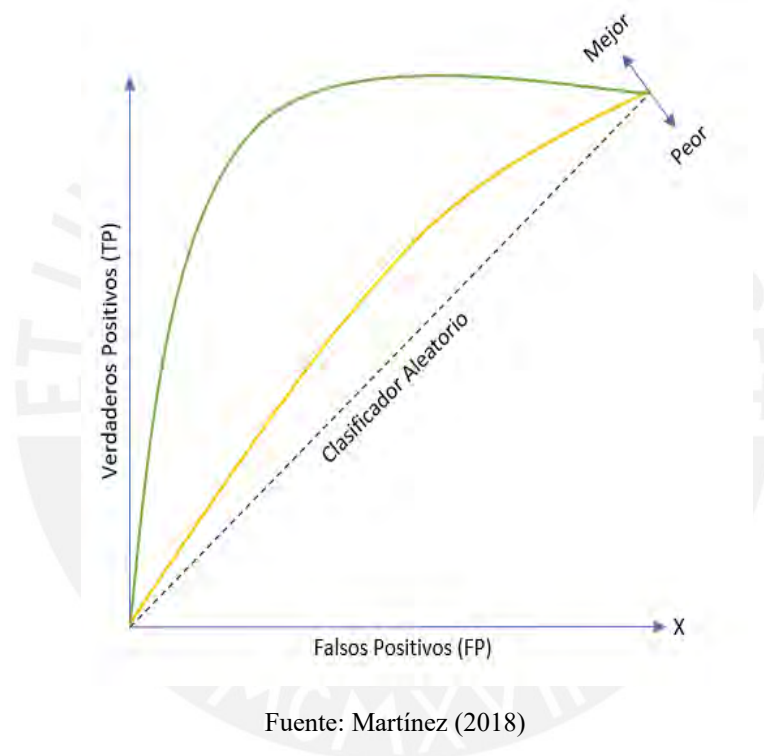
TN: *True Negative*, o negativo real

FP: *False Positive*, o falso positivo

FN: *False Negative*, o negativo real

Otra forma de evaluación de estos modelos es el concepto de la *curva característica de operación* (ROC), la cual, según Martínez (2018), suele aplicarse en modelos de clasificación para evaluar la potencia que tiene este a la hora de discriminar entre los dos valores de la variable objetivo. Para su construcción se emplean los indicadores de *recall* y *specificity*, y diferentes valores del umbral de clasificación⁹ con los cuales se obtiene un conjunto de valores para estos indicadores (idealmente, el mejor clasificador cuenta con un *recall* de 1 y un *specificity* de 0). Juntándolos, se obtiene la curva y el área debajo de esta representa la potencia de discriminación del modelo, la cual si es cercano a 1 corresponde a un buen rendimiento. La figura 6 ilustra el concepto anterior:

Figura 6: ROC correspondiente a un modelo de *machine learning*



2.4.1 IA aplicada a las Fintechs:

Acorde con del Barrio (2021), la IA es una herramienta que se puede integrar de forma satisfactoria con modelos de negocio tecnológicos, en especial de tipo financiero. Contribuye en dos puntos fundamentales: mejora la eficiencia en conjunto con la calidad del servicio y permite abaratar costos operativos. Saby Celestino (consultora del grupo SAS) afirma que cerca

⁹ El umbral de clasificación se define como el valor límite para el cual un valor se clasifica dentro de uno y otro tipo. Por ejemplo: si es que un cliente, al final de la evaluación del modelo, cuenta con una probabilidad de 0.6 de que el crédito es bueno (clientela solvente) y el umbral de clasificación es de 0.75 pues se concluye que este cliente es no apto.

del 41% de la banca tradicional y 36% de cajas municipales están adoptando dichas tecnologías como parte de su propuesta de valor. (GESTIÓN, 2023)

Dentro de este abanico de opciones, se presentan las siguientes:

- **Asistentes Virtuales:**

Los chatbots financieros se definen como software que proporciona asistencia a usuarios en relación con productos financieros. Una de sus principales ventajas es la rapidez en la atención al cliente y la mejora en la productividad al facilitar el acceso a información sobre productos financieros, e incluso en algunos casos, la realización de transacciones o cierres de venta.

En el contexto peruano, un ejemplo destacado son los chatbots utilizados por algunos bancos, como Clara, el asistente virtual del Banco de Crédito del Perú (BCP). Clara puede recibir y atender consultas de clientes a través de WhatsApp, proporcionando información sobre saldos, movimientos, promociones y ofertas en productos financieros. El BCP continúa su estrategia de actualización digital y planea lanzar un chatbot de voz, según Rafael Lemor, gerente de IA en el BCP. Este chatbot permitirá a los clientes realizar solicitudes mediante comandos de voz, como activar compras en línea con la tarjeta, lo que mejorará la fluidez de la interacción y eliminará la limitación de opciones numéricas (INFOBAE, 2023).

- **Evaluación de Créditos**

Este procedimiento combina algoritmos con el uso de Big Data para agilizar la interacción entre el cliente y el producto financiero deseado, así como para reducir los tiempos en los trámites y la revisión de solicitudes.

Según Bastos (2022), el objetivo principal de estos modelos es clasificar a los solicitantes de crédito en dos categorías principales: buen crédito y mal crédito. Esta clasificación se basa en características como la edad, nivel educativo, empleo, ingresos, entre otros. A partir de estas características, se establece un indicador probabilístico de solvencia que se utiliza para llevar a cabo esta clasificación.

- **Control de Fraude**

Este modelo permite analizar el comportamiento de los usuarios utilizando algoritmos de detección de patrones para prevenir y alertar sobre indicios de fraude, lavado de

activos y otras actividades ilícitas relacionadas con el sistema financiero. Estos modelos tienen la capacidad de retroalimentación para un análisis más preciso y eficiente, y se basan en listados amplios de información de transacciones, incluyendo un porcentaje de transacciones fraudulentas para su entrenamiento.

Es importante destacar que tanto este modelo como el anterior suelen ser diseñados utilizando árboles de decisión y redes neuronales debido a la necesidad de alta precisión en la detección. En el capítulo 4 se explorarán casos asociados a estos modelos y sus aplicaciones.

- Fondos de Inversión Automatizados

El Robo Advisor es otra forma de acercamiento a los clientes para las microinversiones en el ámbito de las Fintech. Este sistema utiliza robots para recomendar a los usuarios dónde invertir su excedente de efectivo. Para ello, recopila datos del usuario y establece su perfil de riesgo, para luego ofrecerle alternativas de inversión de forma periódica.

Es importante destacar que la incertidumbre asociada a estos modelos es baja, debido a la naturaleza retroalimentativa de los algoritmos utilizados en su funcionamiento. Esto significa que pueden ajustar continuamente sus recomendaciones en base a la evolución del perfil de riesgo y las preferencias del usuario.

- Automatización de Tareas Manuales

La Automatización Robótica de Procesos (RPA) es un modelo que funciona en conjunto con la Inteligencia Artificial (IA) para estudiar y automatizar procesos realizados en una organización. La IA analiza los procesos existentes y sugiere rutas de automatización para mejorar la eficiencia y reducir los tiempos operativos.

Esta automatización permite incrementar los niveles de productividad al realizar tareas repetitivas de manera más rápida y precisa que los humanos. Además, al liberar a los empleados de estas tareas rutinarias, pueden enfocarse en actividades de mayor valor agregado que requieren habilidades humanas como la creatividad o el análisis crítico. Sin embargo; Mateu Batle, CEO de *fintech* de cambio de divisa Rextie, afirma que su implementación debe responder a criterios económicos y sobre todo de control de la automatización, de modo que sea rentable y sostenible en el tiempo. (Revista Economía, 2023)

El valor ofrecido por estas tecnologías es innegable en la generación de propuestas de valor por parte de las empresas del sistema financiero, tanto a nivel nacional como regional. En el próximo capítulo, se explorará más a fondo la metodología para analizar las principales novedades en la adopción y diseño de soluciones financieras basadas en IA. Este análisis proporcionará una comprensión más completa de cómo estas tecnologías están transformando el sector financiero y creando nuevas oportunidades para la innovación y el crecimiento.



CAPÍTULO 3: MARCO METODOLÓGICO

Con lo descrito previamente en el capítulo 2, se mostrará el marco metodológico a aplicar en el presente trabajo de investigación, sus etapas y la finalidad de estas para responder a la interrogante planteada en el capítulo 1.

3.1 Despliegue del Método de Vigilancia Tecnológica:

Las etapas asociadas a esta metodología las propone Fernández (2009). Dicha estructura permite esquematizar y analizar la información obtenida. La figura 7 muestra el esquema mencionado.

Figura 7: Desglose por etapas de la metodología de vigilancia tecnológica

Etapa 1

- Identificar objetivos de la investigación.

Etapa 2

- Selección de las fuentes de información a analizar.

Etapa 3

- Búsqueda de información en las fuentes seleccionadas.

Etapa 4

- Almacenamiento de la información obtenida.

Etapa 5

- Análisis e interpretación de la información

Etapa 6

- Informes concluyentes de la investigación.

Fuente: Fernández (2009)

3.1.1 Etapa 1: Identificar los objetivos de la información:

En esta etapa se define el concepto central sobre el cuál se aplicará la metodología. Sobre la base de los objetivos de investigación, se eligen los campos temáticos, puntos de vista de interés, cobertura espacial y temporal, idiomas para el universo de análisis y los tipos de documentos a revisar (Fernández, 2009).

3.1.2 Etapa 2: Selección de las fuentes de información a analizar:

Fernández define esta etapa como la selección criteriosa de fuentes de información a analizar, sobre la base de los objetivos establecidos en el punto anterior. Cabrera (2010) menciona dos tipos principales de fuentes de información: las fuentes primarias, que contienen información reciente y no han sido sometidas a un análisis concreto; y las fuentes secundarias, que hacen referencia a información contenida en elementos bibliográficos (análisis documental).

Un complemento a estos tipos de fuentes lo constituyen elementos no necesariamente bibliográficos. Dicha clasificación se divide en fuentes formales, que agrupan fuentes primarias y secundarias, y fuentes informales, que engloban elementos no necesariamente escritos (Escorsa y Maspons, 2000, como se cita en Panta, año). La tabla 2, presentada por Panta (año), agrupa estas fuentes.

Tabla 2: Desglose de fuentes por su origen

Formal	Informal
Libros	Clientes
Patentes	Empresas
Revistas	Proveedores
Artículos Científicos	Consultores
Normas Técnicas	Congresos
Noticias	Seminarios
Bases de Datos	Exposiciones
Artículos Técnicos	Ferias
Portales Web	Competidores Directos

Fuente: Panta (2023)

3.1.3 Etapa 3: Búsqueda de información en las fuentes seleccionadas:

Dentro de esta etapa, Fernández (2009) comenta que se debe realizar la búsqueda de la información de interés, mediante los procedimientos pertinentes por cada herramienta.

En el marco de esta investigación, el método de VT tomará como referencia los siguientes puntos de investigación: publicaciones y artículos científicos-técnicos sobre el uso de las tecnologías ya mencionadas aplicadas a servicios financieros, así como las patentes relevantes de estas tecnologías dentro del sector.

3.1.4 Etapa 4: Almacenamiento de la información obtenida:

Fernández (2009) sugiere que como parte del análisis de VT, se deben tener herramientas de gestión y guardado de la información obtenida con el fin de simplificar el procedimiento de análisis posterior.

En el marco del presente trabajo de investigación, se empleará la herramienta de Mendeley Desktop para el guardado y gestión de las referencias bibliográficas. Asimismo, esta herramienta simplifica el proceso de citados de estas.

3.1.5 Etapa 5: Análisis e Interpretación de la Información:

Fernández (2009) afirma que parte importante de un proceso de VT es el análisis de la información obtenida, con el objetivo de detectar características en la información que aportarán para la interpretación posterior.

Uno de los puntos de interés dentro de este análisis gira en torno a las tendencias que se puedan detectar sobre el campo analizado, su crecimiento (tanto a nivel científico como técnico) y el impacto de este en el desarrollo de dicho campo (Escorsa et al., 2003, citado en Panta, 2022).

3.1.6 Etapa 6: Informes Concluyentes de la Investigación:

Como se definió líneas arriba, uno de los objetivos de la VT es la difusión de los resultados obtenidos. En ese sentido, Fernández (2009) sugiere establecer dichos informes dentro de un marco de ejecución periódico.

Para este proyecto de investigación, el marco de periodicidad sugerido es de seis meses. El capítulo 4 muestra la ejecución de las etapas de la metodología planteada, desde la selección de fuentes hasta los hallazgos que se obtendrán producto del análisis.

CAPÍTULO 4: DESARROLLO DE LA METODOLOGÍA DE VIGILANCIA TECNOLÓGICA

En este capítulo se realizará el desarrollo completo de la metodología de VT que se describió en el capítulo anterior, desde su justificación hasta la revisión de las fuentes bibliográficas más relevantes sobre el tema.

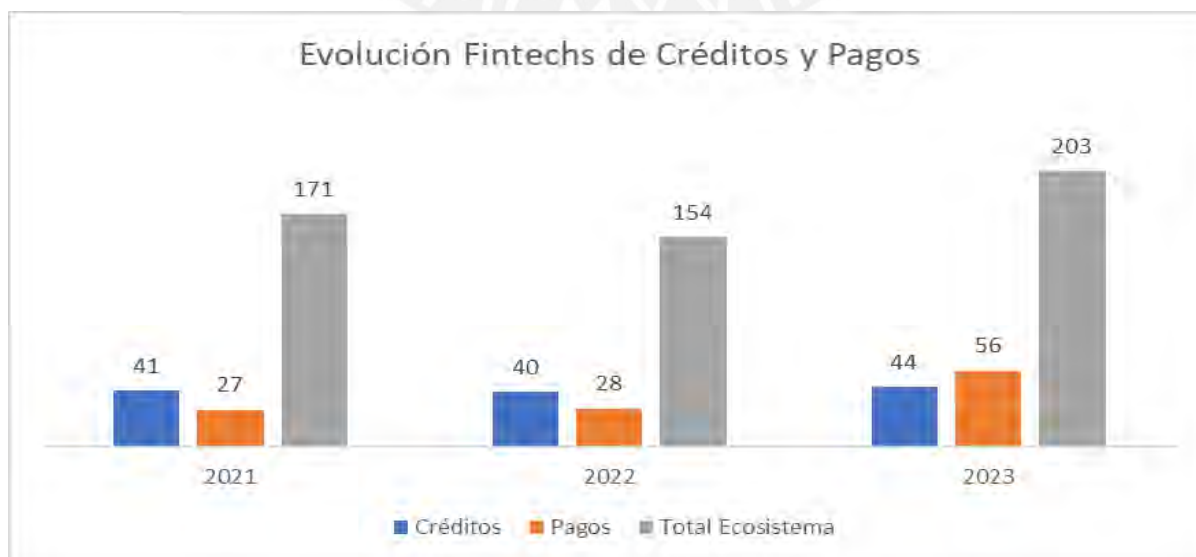
4.1 Desarrollo Etapa 1: Objetivos:

4.1.1 Razones para realizar VT de la IA en el sector *fintech*:

Una de las principales motivaciones para llevar a cabo este proyecto de vigilancia tecnológica es el creciente incremento de empresas dentro del ecosistema *fintech* nacional. Según el informe *fintech* proporcionado por la consultora EY, al cierre del año 2023 existen cerca de 203 empresas de este rubro en actividad, de las cuales los giros correspondientes a créditos y pagos (especialmente billeteras digitales) son los que poseen la mayor participación, con 44 y 56 empresas respectivamente. Asimismo, se resalta el crecimiento del giro correspondiente al cambio de divisas, cuyo número asciende a las 30 y se espera que dicho crecimiento sea superior en los próximos años.

Los dos modelos de negocio mencionados anteriormente se encuentran en segmentos de valor donde los desafíos de seguridad de datos, seguridad del cliente y prevención de fraudes son cruciales para la sostenibilidad de estos (Aivo, 2022). La gráfica 8 muestra la evolución del ecosistema *fintech* a nivel local durante los últimos 3 años, así como el impacto de las *fintech* de préstamos y pagos en el mismo.

Figura 8: Evolución del número de *fintechs* de créditos y pagos del ecosistema peruano



Fuente: Elaboración propia con información de EY (2023)

Un caso emblemático de estos modelos de *fintech* es el de Yape, el cual al cierre de 2022 ya cuenta con más de 14 millones de usuarios en su plataforma. Asimismo, ha introducido a sus clientes la posibilidad de acceder a microcréditos en caso de no disponer de saldo suficiente para alguna operación en particular y poder realizar operaciones con otras billeteras digitales como Plin, por ejemplo. La gráfica 9 muestra un cuadro gráfico de los montos que se mueven en el sistema financiero en la modalidad de banca virtual en el tiempo:


Figura 9: Evolución del monto en operaciones del sistema financiero nacional



Fuente: EY (2024)

Sobre lo anterior, para el mes de marzo del 2023, cerca del 52.3% de las transferencias y pagos elaborados por entidades minoristas utilizaron las billeteras digitales como medio de ejecución. (EY, 2023) La figura 10 muestra la participación de los distintos medios de pago en transferencias minoristas

Figura 10: Proporción de los medios de pago de empresas minoristas



Fuente: EY (2024)

Otro dato a resaltar es el flujo de ingresos que perciben las empresas dentro del ecosistema. Hacia fines del 2020, cerca del 24% de las empresas *fintech* percibió ingresos entre USD 500,000 y USD 15,000,000. Dicho dato ofrece un panorama alentador para el ecosistema, que logró un crecimiento importante pese a las complicaciones producto de la pandemia de la COVID-19. Asimismo, el diario El Peruano afirma que estas empresas *fintech* mueven más de USD 15,000,000,000 anualmente.

Un tercer indicador relevante, ya por la otra cara de lo expuesto anteriormente, tiene que ver con la alta tasa de mortalidad de las empresas *fintech* del ecosistema local. Según Finnovista (2018), Perú es el segundo país con la mayor tasa de mortalidad de *fintechs* de la región Latinoamérica. Dicha cifra se debe en gran medida a los desafíos expuestos al inicio del capítulo: la ciberseguridad, donde el 63% de *fintechs* peruanas no cuenta con sistemas de ciberseguridad robustos y la actualización de tecnologías en pos de mejorar sus propuestas de valor, aquí solo el 22% de startups *fintech* utilizan tecnologías de IA como herramienta en su desarrollo y consolidación.

4.1.2 Objetivos del ciclo de VT:

Como se mencionó en el acápite anterior, se tienen dos eventos: el primero, asociado al rápido crecimiento del ecosistema *fintech* en Perú y sus sectores de mayor impacto, así como su *boom* producto de la pandemia y la aversión al manejo de dinero físico (MIDIS, 2020).

No obstante, el segundo evento está asociado a la alta tasa de mortalidad producto de las dos causas expuestas, aspectos que durante el capítulo 2 se mostró como soluciones que pueden ser abarcadas por tecnologías basadas en IA, elemento que representa una oportunidad para su introducción y desarrollo en el ecosistema *fintech* peruano.

Dado este panorama, los objetivos de este proyecto de VT son los siguientes:

1. Identificar las nuevas herramientas basadas en ML y sus derivados aplicados en las *fintechs* de créditos.
2. Definir las tecnologías o modelos que emplean dichas herramientas.
3. Definir oportunidades y amenazas de su implementación a nivel Perú en las *fintech* ya existentes como las nuevas que busquen ingresar al ecosistema.

Estos objetivos, plasmados como objetivos específicos del presente trabajo, tienen como finalidad ofrecer una perspectiva sobre cómo se están desarrollando estos modelos a nivel mundial y analizar, a grandes rasgos, si es posible implementarse en Perú.

4.2 Desarrollo Etapa 2: Fuentes de Información:

4.2.1 Selección de Fuentes de Información:

Para esta selección, se empleará la distribución de tipos de fuentes que emplea Fernández (2009). Dicho desglose se muestra en la tabla 3:

Tabla 3: Fuentes seleccionadas para el análisis bibliométrico

Categoría	Fuente a Consultar
Noticias Técnicas	Exame (BR), Dock (PE)
Artículos Científicos	Portales de artículos científicos sobre uso de las IA en modelos de negocio tipo Fintech, como Scopus - Springer
Patentes	European Patent Office (EPO), The Global Brand Database (WIPO), Patentscope, Lens
Proyectos de Investigación	Tesis alojadas en repositorios de universidades locales e internacionales.
Norma Legal	SBS, BCRP y entes similares
Productos	Portales web de entidades financieras (<i>fintechs</i>) locales.
Congresos	Congresos y simposios sobre empleo de inteligencias artificiales en entidades financieras o similares.

Fuente: Elaboración propia

4.3 Desarrollo Etapa 3: Búsqueda en Fuentes de Información:

4.3.1 Búsqueda de Artículos Científicos sobre IA aplicadas a Fintechs:

Para este análisis a nivel de artículos científicos, la base de datos seleccionada es Scopus ya que dicho portal ofrece un amplio repositorio de artículos relevantes sobre temas variados de investigación, así como una interfaz intuitiva de búsqueda mediante una sentencia de búsqueda. Naturalmente, se debe realizar una búsqueda segmentada acorde al tema de interés, el cual en este caso es el estado del uso de modelos de ML y afines dentro de *fintechs* u otras entidades financieras de similar naturaleza. Cabe destacar que dicho acceso es posible gracias a las bases de datos que ofrece la PUCP a la comunidad estudiantil.

Este análisis, como etapa dentro de la metodología de VT, permitirá obtener resultados interesantes a nivel bibliométrico, los cuales se emplearán como *input* en las próximas etapas de la misma. Los resultados de dicha búsqueda pueden analizarse mediante herramientas como VOSViewer, de modo que sea más sencillo obtener hallazgos relevantes.

Dentro de esta segmentación de resultados, las palabras clave a emplear se pueden categorizar en cuatro grandes bloques: el primero referido al tipo de herramienta, en este caso modelos o algoritmos (*models OR algorithms*, en inglés); el referido a la tecnología, donde se seleccionaron los términos de *machine learning* e *IA* (*AI* en inglés); el bloque de propuesta de valor, donde se emplearon términos asociados a créditos y productos de esta naturaleza (*loans, credit cards*) y el bloque de soluciones a atender como la detección de fraude y la clasificación crediticia. Asimismo, se excluyen palabras y tópicos que no guarden relación con el tema central de estudio. Una vez ejecutada la fórmula, se obtiene un total de 321 documentos.

Finalmente, la tabla 4 muestra la formulación de búsqueda realizada en Scopus para este análisis:

Tabla 4: Fórmula de búsqueda de artículos científicos en SCOPUS

Base de Datos	Fórmula de Búsqueda
SCOPUS	TITLE-ABS-KEY (((algorithm OR model) AND (ai OR "machine learning" OR "deep learning" OR "neural network")) AND ((loan OR <i>fintech</i> OR "credit card" OR "financial services") AND ("credit scoring" OR "fraud detection" OR "fraudulent transactions"))) AND (LIMIT-TO (DOCTYPE , "ar")) AND (EXCLUDE (SUBJAREA , "NEUR") OR EXCLUDE (SUBJAREA , "PHYS") OR EXCLUDE (SUBJAREA , "ENER") OR EXCLUDE (SUBJAREA , "MATE") OR EXCLUDE (SUBJAREA , "SOCI") OR EXCLUDE (SUBJAREA , "CHEM") OR EXCLUDE (SUBJAREA , "BIOC") OR EXCLUDE (SUBJAREA , "CENG") OR EXCLUDE (SUBJAREA , "PHAR") OR EXCLUDE (SUBJAREA , "EART") OR EXCLUDE (SUBJAREA , "PSYC") OR EXCLUDE (SUBJAREA , "MULT") OR EXCLUDE (SUBJAREA , "MEDI") OR EXCLUDE (SUBJAREA , "ARTS") OR EXCLUDE (SUBJAREA , "AGRI") OR EXCLUDE (SUBJAREA , "ENVI"))

Fuente: Elaboración propia

4.3.2 Búsqueda de patentes sobre IA aplicadas a Fintechs:

Una segunda fuente relevante, como ya se mencionó en el marco metodológico, son las patentes. Dichos registros se alojan en la base de datos de la *World Intellectual Property Organization* (WIPO) mediante el motor Patentscope el cual, acorde con el propio portal, cuenta con más de 112 millones de patentes registradas.

Para dicha búsqueda se utilizan palabras clave similares al caso anterior: el bloque de tecnologías, ya sean sistemas o algoritmos; el bloque del sector de aplicación, detección de fraudes en tarjeta de crédito o transacciones y el *scoring crediticio*; el sector a analizar, el de créditos. El resultado muestra un total de 50 patentes. Finalmente, la tabla 5 muestra la query utilizada:

Tabla 5: Fórmula de búsqueda de patentes en WIPO

Base de Datos	Fórmula de Búsqueda
PATENTSCOPE	FP:(((SYSTEM OR ALGORITHM) AND (AI OR "MACHINE LEARNING" OR "DEEP LEARNING" OR "NEURAL NETWORK") AND ("FRAUD DETECTION" OR "FRAUDULENT TRANSACTIONS" OR "CREDIT SCORING") AND ("CREDIT CARD" OR LOAN OR "FINANCIAL SERVICES" OR FINTECH)))

Fuente: Elaboración propia

4.3.3 Búsqueda en fuentes adicionales:

Como parte de las fuentes complementarias, en particular para los capítulos previos, se emplearon fuentes como artículos (en *Google Scholar*), libros, tesis, portales web, instituciones y organismos tanto locales como mundiales, las cuales se encuentran referenciadas de manera oportuna a lo largo del presente trabajo.

Referente al marco estructural del presente trabajo, se obtuvo un modelo invaluable del trabajo de Panta (2022), la cual ofrece la estructura para su redacción.

4.4 Desarrollo Etapa 4: Uso de herramientas de documentación:

En esta etapa, se almacena la información obtenida en softwares de gestión de referencias. Dicho paso intermedio funciona como elemento organizador para facilitar el posterior análisis. La tabla 6 muestra el listado de software empleado para este fin:

Tabla 6: Herramientas de análisis bibliométrico y de citado

Herramienta	Rol dentro de la metodología
Mendeley Desktop	Herramienta empleada para gestionar la bibliografía recopilada a lo largo del presente trabajo de investigación, facilita la tarea de citado.
Excel	Utilizado con las fuentes obtenidas en Scopus, de modo que se pueda almacenar la información en archivos CSV (comma separated values) para su posterior análisis bibliométrico.
VOSViewer	Herramienta que permite realizar un análisis visual de las referencias obtenidas a nivel bibliométrico y obtener relaciones sobre las fuentes obtenidas.

Fuente: Elaboración propia

4.5 Desarrollo Etapa 5: Análisis de Información de Artículos Científicos:

4.5.1 Entorno Estratégico de la VT:

Análisis Político

Políticamente, Perú durante los últimos 2 años (incluyendo 2023) ha vivido una de las mayores crisis políticas desde el año 2000 (France24, 2024). Dicha crisis se agudizó producto de la detención del expresidente Pedro Castillo producto de una acción que el Congreso calificó como intento de golpe de estado. Tras su captura y posterior designación de Dina Boluarte como jefa de estado, hubo un estallido social masivo en el país, en especial en la zona centro-sur del Perú, siendo el foco más crítico el departamento de Puno donde se registraron un total de 18 civiles y un policía fallecidos, así como desmanes en establecimientos públicos y el intento de toma del aeropuerto de Juliaca.

Por otro lado, pese al cambio de mando, la situación política nacional experimenta una alta volatilidad, marcada sobre todo por la desaprobación de la ciudadanía al gobierno en cuestión (Infobae, 2023). Al cierre de noviembre 2023, este porcentaje de aprobación es de apenas 9% siendo uno de los más bajos de la región.

Análisis Económico

Pese al factor expuesto anteriormente, la economía peruana acorde con la proyección del Banco Mundial (2022) tiene una perspectiva de crecimiento de 2.4%, tomando los sectores primarios (materias primas) y servicios como principales pilares, y para el año 2024, el BCRP espera un crecimiento económico de 3.1%. Del mismo modo, el inicio del proyecto Quellaveco y el incremento sostenido de las inversiones internacionales, elevarían el porcentaje mencionado hasta un 2.8%. Otros proyectos como el Aeropuerto Internacional de Chinchero y el Puerto de Chancay ofrecen mayores posibilidades de ampliación de estas inversiones, aunque aún los avances de estos proyectos son muy reducidos y en algunos casos paralizados (La República, 2023).

El Fondo Monetario Internacional (FMI) complementa esta información con el hecho de que la deuda interna nacional es la más baja de la región y que su sector financiero es lo suficientemente robusto como para enfrentar los riesgos macroeconómicos como los generados por la actual guerra ruso-ucraniana y la desaceleración económica que experimenta el PBI, el cual oscila entre 2 y 3%. Pese a dichos indicadores, uno de los grandes retos para la economía peruana es el valor de la inflación anual, la cual al cierre de diciembre 2023 tiene un valor anualizado de 2.83%, estando en el límite superior de la banda de tolerancia establecida por el

BCRP, entre 1 y 3%, aunque esta ha reducido de forma sostenida durante los últimos meses del 2023 pero su impacto no es del todo significativo (30 meses con un valor de inflación sobre el rango meta). Asimismo, el organismo nacional espera que dicho porcentaje se mantenga entre 2.7% y 3.5% durante el 2024.

Sobre el contexto económico en cuanto a la inversión nacional en materia de ciencia, tecnología e innovación (CTI), Mesia (2023) afirma que Perú invierte cerca del 0.17% de su PBI en este rubro, una de las cifras más bajas de la región si se compara con países como Chile (0.4%) y Colombia (0.29%), países que cuentan con los ecosistemas startup más variados y robustos (Finnovista).

Análisis Social

El punto de inflexión dentro del universo de *fintechs* lo marcó una recomendación del entonces viceministro Javier Loza y el MIDIS (2020) dentro del contexto de la pandemia de la COVID-19, la cual se asoció al uso del dinero físico para realizar pagos variados. Dicha necesidad permitió a las *fintechs* encontrar vías para acercarse a sus segmentos de valor mediante alternativas de manejo de dinero con el uso de las billeteras electrónicas (ejemplos son Yape, Plin, etc).

Por el lado de créditos, otro hito alcanzado durante la pandemia fue la cantidad de microcréditos desembolsados a emprendedores como parte de la iniciativa VendeMas de Niubiz, lo cual permitió a dichos microempresarios reactivar sus labores, así como establecer su historial crediticio para acceder a futuros créditos (Stakeholders Sostenibilidad, 2021).

Asimismo, en el 2023, se aprobó la Política Nacional de Transformación Digital 2030, con el objetivo de incrementar la capacidad de digitalización de la población nacional. Uno de sus ejes es el referente a actividades en banca y servicios financieros digitales. (EY, 2023)

Análisis Tecnológico

Dentro de las tecnologías relacionadas con estas propuestas de valor, en los últimos tiempos ha surgido la implementación de asistentes virtuales basados en inteligencia artificial (IA). Un ejemplo destacado es Clara, el chatbot asistente del BCP, que proporciona a los clientes información sobre sus estados de cuenta y productos nuevos, ajustados a su puntaje crediticio y disponibilidad, entre otros factores (BCP, 2022). Además, la tendencia hacia la adopción de estas tecnologías está en aumento, con un 28% del sector empresarial nacional que ya las ha implementado, aunque aún de manera no sistemática.

Otro aspecto relevante es la infraestructura de conectividad a Internet, fundamental para el funcionamiento de la banca digital y las *fintech*. Según un informe de EY, en 2023, el 77.8% de los hogares en Lima Metropolitana contaba con acceso a Internet; en zonas urbanas a nivel regional, este porcentaje alcanzaba el 58.7%, mientras que en las zonas rurales llegaba al 19.3%. Es importante destacar que la región de Apurímac experimentó el mayor crecimiento, con un aumento del 41.8% en comparación con 2022. Además, según datos de OSIPTEL, cerca del 92% de la población utiliza dispositivos móviles para acceder a Internet. Sin embargo, según Miguel Di Campo, gerente de asuntos públicos de American Tower Perú, este crecimiento en la conectividad no se corresponde de manera uniforme con el aumento de la demanda de conectividad, y la brecha digital aún alcanza el 30%, debido a factores como la falta de otros servicios básicos relacionados y el bajo nivel de alfabetización digital en la población (El Comercio, 2023).

Para los fines de este trabajo, se explorarán las tecnologías basadas en aprendizaje automático y sus ramas relacionadas para las empresas *fintech* de tipo crédito. Es importante señalar que este análisis también incluirá las tecnologías empleadas por los grandes bancos, ya que la definición no excluye a estos.

Análisis Ambiental

Una de las ventajas que trajo la digitalización de la banca lo mencionan Camacho, Marroquín y Russo (2017), la cual se asocia con la reducción del uso de papel dentro de los trámites financieros. Al ser servicios de fácil acceso a través de un equipo móvil (celular o laptop), ya no requiere del componente físico como lo es el papel. Dicho componente digital ayuda a que el modelo de estas empresas sea sostenible y a su vez dinámico, ya que el cliente interesado ya no requiere acudir a una sede física para realizar solicitudes, de modo que lo puede hacer desde la comodidad de su domicilio y a través de su dispositivo móvil.

Análisis Legal

Si bien es cierto, aún no existe un marco regulatorio concreto para las *fintech* en Perú (llámese a éste una *Ley Fintech* como el caso de Colombia u otros países de la región), se han realizado varios avances para lograr dicho hito, entre ellos destacan:

- Reglamento para la Realización Temporal de Actividades en Modelos Novedosos:
Dicho reglamento, aprobado por resolución SBS N° 2049-2021, faculta de manera temporal a las empresas autorizadas la implementación de un modelo de negocio que

no disponga de una regulación específica y/o ésta requiera de una flexibilización de alguna norma regulatoria vigente.

- **Sandbox Regulatorio:**

Diseñado en el marco del dinamismo de modelos de negocio financiero. Según la SBS, este espacio brinda oportunidad a instituciones licenciadas y no licenciadas (con autorización) para el desarrollo de sus modelos siempre que tengan beneficios para los usuarios finales y los sistemas regulatorios.

Asimismo, acorde con la SBS, no es necesario (ni sencillo) realizar una ley de carácter generalista para estas empresas, dada la heterogeneidad de estos modelos de negocio. En su lugar, es preferible realizar ajustes a la normativa actual, con el fin de incluir a estos modelos innovadores dentro de su perímetro regulatorio, de modo que no afecte de más su funcionamiento.

4.5.2 Análisis de Publicaciones:

La figura 11 muestra el evolutivo de publicaciones realizadas en Scopus, tomando como base la query de búsqueda planteada en la tercera etapa de la presente metodología. Dentro del rango de tiempo mostrado se tienen publicaciones desde el año 1992. Se pueden distinguir dos grandes bloques de tiempo: el periodo 1992-2017, donde las investigaciones fueron muy reducidas (producto de las limitaciones tecnológicas de la época y la limitada producción científica), aquí destaca el año 2009 con un total de 8 publicaciones las cuales giran en torno al uso de modelos de *deep learning* en la prevención de fraudes. Un segundo bloque que comprende desde el 2018 hasta junio del 2024, donde se registra un crecimiento grande de la producción científica (el cual se vio acelerado producto de la digitalización de los servicios financieros y los retos de la pandemia). Los años 2022 y 2023 representan los picos de investigación de este tema, con un total de 59 y 77 publicaciones respectivamente. Al mes de febrero del 2024, se tiene ya un total de 6 publicaciones y se espera que aumente en los próximos meses.

Figura 11: Evolución del número de publicaciones científicas del tema en cuestión



Fuente: Elaboración propia con información de SCOPUS - Elsevier (2023)

Uno de los primeros pasos en materia de investigación de estos modelos para el puntaje crediticio lo presenta Davis et al. (1992). Aquí se introduce una comparativa entre dos tipos de modelos: aprendizaje supervisado y el uso de redes neuronales como forma de realizar evaluaciones a la hora de que un cliente busque acceder a una tarjeta de crédito. Otro trabajo a destacar es el de Hamdoun y Rguibi (2019), los cuales realizaron un caso de estudio comparativo sobre los métodos de *scoring* crediticio aplicado en la banca marroquí tanto en el uso de modelos estadísticos antiguos como lo es la regresión logística y modelos más recientes, que a su vez aplican métodos de machine learning, como lo es el uso de bosques aleatorios¹⁰ (*random forests* en inglés), siendo estos últimos una alternativa más efectiva para dichos puntajes. Por el lado del trabajo realizado en Perú (Asencios et al., 2023), se propone un modelo de clasificación crediticio basado en 6 modelos potenciados por la técnica de *boosting* para ser empleado en el marco de cooperativas financieras como apoyo para los analistas financieros.

Por el lado de la detección de fraudes, el trabajo de Reilly (1993) supone la primera introducción al uso de redes neuronales con las cuales se busca analizar el comportamiento de clientes y utilizar la detección de anomalías como fuente para identificar casos de fraude en etapa temprana. Para el año 2006, Chen propone un modelo para el mismo fin empleando

¹⁰ Los bosques aleatorios (*random forests*) se definen como una familia de árboles de decisión con el fin de obtener un resultado mucho más preciso (IBM).


máquinas de vector soporte (SVM) y las ya mencionadas redes neuronales ofreciendo efectividades superiores al 90% (esta cifra puede variar según la distribución del *dataset* brindado). Dentro de los trabajos más recientes destaca el de Hoang et al. (2023), el cual utiliza técnicas de minería de datos y herramientas de *deep learning* para la detección de fraudes con una efectividad del 97%, lo cual representa un avance significativo en la prevención de dichas anomalías.

4.5.3 Países con mayor producción científica:

La figura 12 muestra el desglose de publicaciones científicas por país de procedencia. Acorde con los resultados obtenidos, India es el país con mayor producción científica sobre modelos de IA y *machine learning* aplicadas a finanzas con un total de 70 publicaciones, dicho dato es consecuente con la alta producción científica que tiene dicho país, con un 16% de crecimiento desde 2016 (Elsevier, 2016). De forma similar, un importante bloque asiático cuenta con investigaciones acerca de estos modelos, siendo este el más numeroso con más de 214 publicaciones.

Por el lado americano, destacan USA con 36 publicaciones y presencia sudamericana como es el caso de Brasil con 5 publicaciones y el de Colombia y Perú con una publicación cada una. Destacar que este bloque cuenta con el ecosistema *fintech* más desarrollado y diverso dentro de la región.

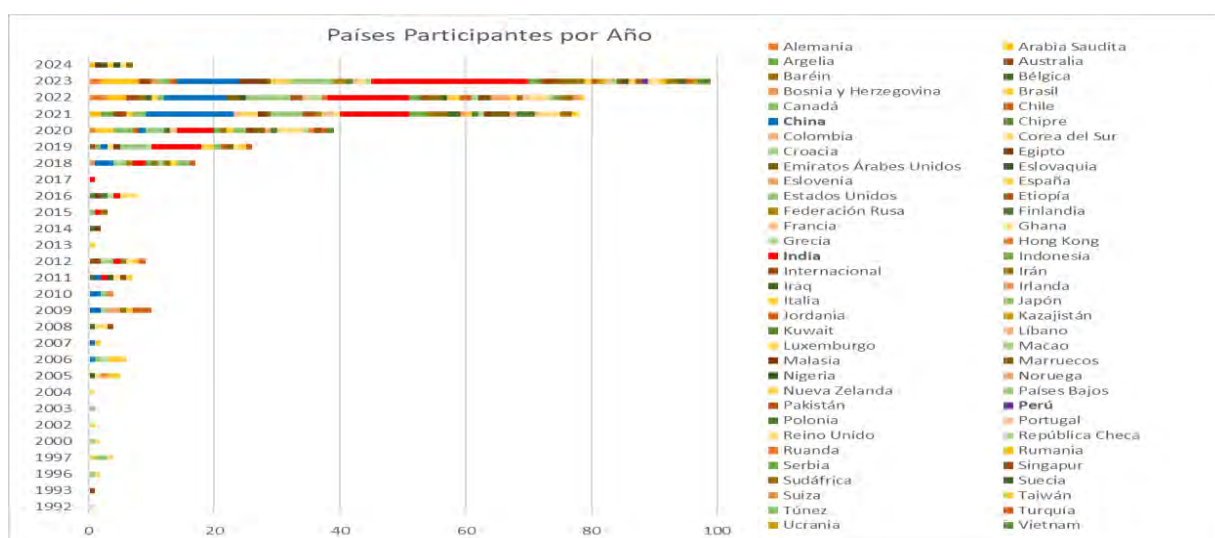
Figura 12: Recuento de aportes científicos por país de origen



Fuente: Elaboración propia con información de SCOPUS - Elsevier (2024)

La gráfica 13 muestra el desglose por año de las publicaciones mencionadas. Como se mencionó líneas arriba, el intervalo 2018-2023 constituye el periodo con mayor producción científica, siendo 2022 el año donde se observó la mayor cantidad de países colaboradores en materia de investigaciones con un total de 34. La tendencia es de carácter constante y a noviembre del 2023 ya se tienen 37 países involucrados, la gran mayoría del bloque asiático, con la India como principal aliado, además de ser el más presente en el quinquenio ya mencionado.

Figura 13: Desglose de países involucrados en publicaciones por año



Fuente: Elaboración propia con información de SCOPUS - Elsevier (2024)

4.5.4 Organizaciones investigadoras:

A nivel de organizaciones involucradas en estos trabajos, cerca del 72% de estas corresponden a universidades, las cuales han ahondado en la exploración de estos modelos optimizados con machine learning. Se destaca la presencia de organismos gubernamentales pertenecientes a China, Irán, Irlanda e Irak. La tabla 7 muestra el desglose de estas organizaciones:

Tabla 7: Organizaciones involucradas en aportes científicos

Entidad	Cantidad
Universidad	424
Instituto	101
Empresa	39
Centro de Investigación	18
Organismos Gubernamentales	6
Independientes	3

Fuente: Elaboración propia con información de SCOPUS - Elsevier (2024)

Asimismo, ya a nivel país, se observa que la mayor concentración de organizaciones involucradas se aloja en la India, con un total de 103 instituciones, con alta presencia de universidades e institutos tecnológicos (63 y 38, respectivamente). Similarmente a India, varios países del bloque asiático cuentan con organizaciones investigadoras involucradas en el tópico de estudio. Por el lado americano, Estados Unidos cuenta con 67 organizaciones y por parte de la región sudamericana (Brasil, Chile, Colombia y Perú) con 11. En el caso de Perú, la Universidad de Lima es la organización aportante.

Finalmente, la tabla 8 muestra el recuento de organizaciones, así como su país de origen para un mejor detalle:

Tabla 8: Países involucrados en aportes científicos

País de Procedencia	Cantidad	País de Procedencia	Cantidad	País de Procedencia	Cantidad
India	103	Noruega	6	Nueva Zelanda	3
Estados Unidos	67	España	6	Bahréin	2
China	66	Corea del Sur	6	Rumania	2
Reino Unido	28	Bélgica	6	Bosnia y Herzegovina	2
Taiwán	23	Alemania	5	Chipre	2
Irán	16	Malasia	5	Serbia	2
Turquía	14	Vietnam	5	Pakistán	2
Arabia Saudita	12	Emiratos Árabes Unidos	5	Suiza	2
Australia	12	Hong Kong	4	Líbano	2
Egipto	12	Eslovaquia	4	República Checa	2
Canadá	11	Portugal	4	Chile	2
Polonia	11	Croacia	4	Irlanda	1
Marruecos	10	Eslovenia	4	Suecia	1
Italia	9	Japón	4	Kuwait	1
Federación Rusa	8	Macao	4	Rusia	1
Indonesia	8	Argelia	3	Perú	1
Grecia	8	Singapur	3	Ucrania	1
Francia	8	Kazajistán	3	Internacional	1
Brasil	7	Nigeria	3	Afganistán	1
Jordania	7	Túnez	3	Luxemburgo	1
Ghana	7	Escocia	3	Ruanda	1
Iraq	7	Finlandia	3	Colombia	1
Sudáfrica	6	Etiopía	3	Países Bajos	1

Fuente: Elaboración propia con información de SCOPUS - Elsevier (2024)

Finalmente, la tabla 9 muestra la lista total de organizaciones involucradas en estas investigaciones, junto con sus países de origen. De la presente tabla se destaca la fuerte presencia del bloque asiático, el cual lidera los esfuerzos en estas investigaciones. Se distinguen un total de 591 organizaciones de 69 países alrededor del mundo.

Tabla 9: Listado de instituciones involucradas en aportes científicos

Institución	País	Institución	País	Institución	País
Aalto University	Finlandia	Tamil Virtual Academy	India	Periyar University	India
AB Schnare Associates	Estados Unidos	Indraprasta Persatuan Guru Republik Indonesia University	Indonesia	SHU-UTS SILC Business School	China
Academia Sinica Taiwan	Taiwán	Indraprasta PGRI University	Indonesia	Sichuan University	China
Academia Sinica, Research Center for Information Technology Innovation	Taiwán	Industrial and Commercial Bank of China (Macau) Limited	Macao	Sindh Madressatul Islam University	Pakistán
Vignan's Foundation for Science	India	Industrial Management Institute	Irán	Singapore University of Social Sciences	Singapur
Ambalika Institute of Technology and Management	India	INSA Lyon	Francia	Singidunum University	Serbia
ACM	Taiwán	Thapar Institute of Engineering & Technology	India	Skyline University College	Emiratos Árabes Unidos
Addis Ababa Science and Technology University	Etiopía	The LNM Institute of Information Technology	India	Slovak Academy of Sciences	Eslovaquia
Ambedkar Institute of Advanced Communication Technologies & Research	India	Institute for Industrial Systems Innovation	Japón	Presidency University Bangalore	India
Adnan Kassar School of Business	Líbano	Vel Tech Rangarajan Dr.Sagunthala R&D Institute of Science and Technology	India	Soochow University	China
African University of Science and Technology	Irán	Institute of Automation Chinese Academy of Sciences	China	South Ural State University	Federación Rusa
AGH University of Krakow	Polonia	Institute of Theoretical and Applied Informatics of the Polish Academy of Sciences	Polonia	Southampton Business School	Reino Unido
Agriculture and Agri-Food Canada	Canadá	Instituto Federal de Educação, Ciência e Tecnologia de São Paulo	Brasil	Southern New Hampshire University	Estados Unidos
Al Farabi Kazakh National University	Kazajistán	Instituto Tecnológico de Aeronautica	Brasil	Southern University of Science and Technology	China
Al Qassim University	Arabia Saudita	integrate.ai	Canadá	Southwest Petroleum University China	China

Al-Balqa Applied University	Jordania	International Burch University	Bosnia y Herzegovina	Southwestern University of Finance and Economics	China
Ale Taha Institute of Higher Education	Afganistán	Iowa State University	Estados Unidos	PSN College of Engineering & Technology	India
Alfred Lerner College of Business And Economics	Estados Unidos	Iranian National Tax Administration	Irán	R.V.R. & J.C.College of Engineering	India
Alibaba Group Holding Limited	China	Ireland Central Bank	Irlanda	Rajalakshmi Engineering College	India
Avinashilingam Institute for Home Science and Higher Education for Women	India	ISEG Lisbon School of Economics and Management	Portugal	RajaRajeswari College of Engineering, Bengaluru	India
Bharath Institute of Higher Education and Research	India	Isfahan University of Technology	Irán	Rajarajeswari Medical College & Hospital	India
Amin Police University	Irán	Islamic Azad University, South Tehran Branch	Irán	Rajiv Gandhi Proudhyogiki Vishwavidyalaya	India
Amirkabir University of Technology	Irán	Istanbul Bilgi Üniversitesi	Turquía	SASTRA Deemed University	India
Birla Institute of Technology, Mesra	India	Istanbul Ticaret Üniversitesi	Turquía	Saveetha Engineering College	India
Christu Jyothi Institute of Technology and Science	India	Istituto di Scienza e Tecnologie dell'Informazione A. Faedo	Italia	Savitribai Phule Pune University	India
GMR Institute of Technology	India	Itä-Suomen yliopisto	Finlandia	St. Joseph's College of Engineering	Estados Unidos
Guru Nanak Institute of Technology	India	Japan Advanced Institute of Science and Technology	Japón	St. Joseph's Institute of Technology	Estados Unidos
Ant group	China	Vellore Institute of Technology	India	Shrimathi Devkunvar Nanalal Bhatt Vaishnav College for Women	India
Applied Science Private University	Jordania	Jiangsu Normal University	China	Stephen M. Ross School of Business	Estados Unidos
Arab Open University - Bahrain	Bahréin	Jilin University of Finance and Economics	China	Stockholms universitet	Suecia
Arab Open University - Egypt	China	Jouf University	Arabia Saudita	Summerland Research and Development Centre	Canadá
Arba Minch University	Etiopía	Ministry of Electronics and Information Technology	India	Surrey Business School	Reino Unido
Ashesi University	Ghana	ACE Engineering College	India	Sveučilište Josipa Jurja Strossmayera u Osijeku	Croacia
Guru Nanak Institutions Technical Campus	India	Kafrelsheikh University	Egipto	Systems Research Institute of the Polish Academy of Sciences	Polonia

Asia Pacific University of Technology and Innovation	Malasia	Kainan University Taiwan	Taiwán	Szkola Główna Handlowa w Warszawie	Polonia
Aston Business School	Reino Unido	Acharya Nagarjuna University	India	Taibah University	Arabia Saudita
Aston University	Reino Unido	Aditya College of Engineering and Technology	India	Tanri Abeng University	Indonesia
Athens University of Economics and Business	Grecia	Amity University	India	Tanta University	Egipto
Auckland University of Technology	Nueva Zelanda	Key Laboratory of Embedded System and Service Computing, Ministry of Education	China	Tarbiat Modares University	Irán
AUT Business School	Nueva Zelanda	Kharazmi University	Irán	Technical University of Crete	Grecia
Indian Institute of Technology (Indian School of Mines), Dhanbad	India	King Abdulaziz University	Arabia Saudita	Teesside University	Reino Unido
Azarbaijan Shahid Madani University	Irán	King Saud University	Arabia Saudita	Tennessee Technological University	Estados Unidos
Indian Institute of Technology Kharagpur	India	Korea Credit Bureau	Corea del Sur	Texas A&M University	Estados Unidos
Babylon Education Directorate	Iraq	KU Leuven	Bélgica	SNS College of Technology	India
Bahrain Polytechnic	Bahrén	Kumamoto University	Japón	The Adelaide Business School	Australia
Bain & Company Inc.	Estados Unidos	Kuwait College of Science & Technology	Kuwait	The Catholic University of Korea	Corea del Sur
Institute for Development and Research in Banking Technology India	India	Kwame Nkrumah University of Science & Technology	Ghana	The George Washington University	Estados Unidos
Bank of Karlovac	Croacia	Kyung Hee University	Corea del Sur	The Jacob of Paradies University	Italia
Bank of Scotland	Escocia	Kyushu Institute of Technology	Japón	Sree Vidyanikethan Engineering College	India
Beijing Fantaike Technology Co. Ltd.	China	Lääketieteellinen Tiedekunta	Turquía	The University of Adelaide	Australia
Beijing North Billion Technology Co. Ltd.	China	Laboratoire de Technologie de l'Information et Modélisation	Marruecos	The University of Auckland	Nueva Zelanda
Beijing University of Posts and Telecommunications	China	Laboratoire d'Informatique de Grenoble	Marruecos	The University of Chicago	Estados Unidos
Beijing Zhongguancun Kejin Technology Co. Ltd.	China	Amity University Kolkata	India	The University of Edinburgh	Escocia
Benha University	Reino Unido	Lancashire School of Business and Enterprise	Reino Unido	The University of Hong Kong	Hong Kong

Bentley University	Estados Unidos	Lebanese American University	Líbano	The University of North Carolina at Greensboro	Estados Unidos
Besterp Technologies	Estados Unidos	Leonard N. Stern School of Business	Estados Unidos	The University of Texas at Dallas	Estados Unidos
Institute of Aeronautical Engineering, Hyderabad	India	LexisNexis Business Information Solutions	Estados Unidos	Thomas Jefferson University	Estados Unidos
Bina Nusantara University	Indonesia	Lian Sazeh Corporation	Irán	Thuongmai University	Vietnam
Binghamton University State University of New York	Estados Unidos	Liverpool John Moores University	Reino Unido	Tianjin University	China
K.J. Somaiya Institute of Management	India	Anna University	India	Tongji University	China
Boğaziçi Üniversitesi	Turquía	Annamalai University	India	Toronto Metropolitan University	Canadá
Boston University	Estados Unidos	LUT University	Finlandia	Torrens University Australia	Australia
Bournemouth University	Reino Unido	Macau University of Science and Technology	Macao	Turku University	Turquía
Brunel University London	Reino Unido	Ashoka Women's Engineering College	India	UiT Norges Arktiske Universitet	Noruega
Burgundy School of Business	Francia	Babasaheb Bhimrao Ambedkar University	India	Unifund CCR, LLC	Estados Unidos
Business School of Sichuan University	China	Banaras Hindu University	India	Union Bank of Switzerland	Suiza
Carl H. Lindner College of Business	Estados Unidos	Central University of Haryana	India	Universidad Autónoma de Madrid	España
Carnegie Mellon University	Estados Unidos	Central University of Punjab	India	Universidad de Chile	Chile
Central South University	China	Majmaah University	Arabia Saudita	Universidad de La Sabana	Colombia
Central University of Finance and Economics	China	Manchester Metropolitan University	Reino Unido	Universidad de Lima	Perú
Karnatak Law Society's Gogte Institute of Technology	India	Chandigarh University	India	Universidad de Talca	Chile
KCEs COEM Jalgaon	India	Chitkara University	India	Universidad del Pais Vasco	España
Kongu Engineering College	India	Mansoura University	Egipto	Universidade de Lisboa	Portugal
Charles Darwin University	Australia	Marmara Üniversitesi	Turquía	Universidade Federal de Pernambuco	Brasil
Chelyabinsk State University	Federación Rusa	Christ University, Bengaluru	India	Universidade Federal do Ceará	Brasil

Chien Hsin University of Science and Technology	Taiwán	Marymount University	Estados Unidos	Universidade Federal do Rio de Janeiro	Brasil
China Agricultural University	China	Masaryk University	República Checa	Universidade Nova de Lisboa	Portugal
China University of Mining and Technology	China	Medmenham	Reino Unido	Università degli Studi di Cagliari	Italia
Chinese Academy of Sciences	China	Mendoza College of Business	Estados Unidos	Università degli Studi di Pavia	Italia
Chinese Culture University Taiwan	Taiwán	Menoufia University	Egipto	Università degli Studi di Salerno	Italia
Chinese University of Hong Kong	Hong Kong	CMR Engineering College	India	Università della Calabria	Italia
Loyola Institute of Technology	India	Michigan Technological University	Estados Unidos	Universitas Gadjah Mada	Indonesia
Manipal Academy of Higher Education	India	Microsoft Research	Estados Unidos	Universitas Sriwijaya	Indonesia
Manipal Institute of Technology	India	Middle East Technical University (METU)	Turquía	Universitat de València	España
City University of Hong Kong	Hong Kong	Ministry of Education General Director of Education	Iraq	Universitat Oberta de Catalunya	España
City University of Macau	Macao	Ministry of Education of the People's Republic of China	China	Universität Passau	Alemania
Marri Laxman Reddy Institute of Technology and Management	India	DIT University	India	Universitat Politècnica de València	España
CNRS Centre National de la Recherche Scientifique	Francia	MIREA–Russian Technological University	Federación Rusa	Université Abou Bekr Belkaid Tlemcen	Argelia
College of Academic Studies Dositej	Serbia	Mohammed V University in Rabat	Marruecos	Université Bourgogne Franche-Comté	Francia
College of Business Administration	Jordania	Monash Business School	Australia	Üniversite Caddesi	Turquía
College of Engineering	Emiratos Árabes Unidos	Monash University	Australia	Université Dr Taher Moulay Saida - Algeria	Argelia
College of Engineering - Iowa University	Estados Unidos	Monash University Malaysia	Malasia	Université du Québec à Montréal	Canadá
College of Engineering - National University	Taiwán	Moscow Institute of Physics and Technology	Rusia	Université Hassan 1er	Marruecos
College of Engineering - Texas University	Estados Unidos	Najran University	Kazajistán	Université Ibn Tofail	Marruecos
College of Engineering and Management	Jordania	Nanjing University	China	Université Libre de Bruxelles	Bélgica

College of Management - National Cheng Kung University	Taiwán	Nanjing University of Aeronautics and Astronautics	China	Université Paris-Dauphine	Francia
College of Sciences	Jordania	Nanjing University of Information Science & Technology	China	Université Sultan Moulay Slimane	Marruecos
Concordia Institute for Information Systems Engineering	Canadá	National Aviation University	Ucrania	Universiteit Gent	Bélgica
Concordia University	Canadá	National Central University	Taiwán	Universiti Sains Malaysia	Malasia
Council for Scientific and Industrial Research Ghana	Ghana	National Changhua University of Education	Taiwán	Universiti Sultan Zainal Abidin	Malasia
Credito Emiliano	Turquía	National Cheng Kung University	Taiwán	Universiti Tenaga Nasional	Malasia
CSIR - Crops Research Institute Ghana	Ghana	National Chi Nan University	Taiwán	University of Abuja	Nigeria
Curtin Business School	Australia	National Chiao Tung University	China	Sri Manakula Vinayagar Engineering College	India
Curtin University	Australia	National Institute of Chemistry Ljubljana	Eslovenia	University of Anbar	Iraq
Cyprus University of Technology	Chipre	Easwari Engineering College	India	University of Babylon	Iraq
Dalian University of Technology	China	Faculty of Computer Studies - Arab Open University	India	University of Bisha	Arabia Saudita
Daneshgah Elm va Sanat e Iran	Irán	Galgotias University	India	University of Bradford	Reino Unido
Deakin University	Australia	National Kaohsiung University of Science and Technology	China	University of Bradford School of Management	Reino Unido
Debre Berhan University	Etiopía	National Research and Development Institute for Cryogenic and Isotopic Technologies – ICSI Rm. Valcea	Rumania	University of California, San Diego	Estados Unidos
Deep Future Analytics LLC	Estados Unidos	National Taichung University of Science and Technology	Taiwán	University of Central Lancashire	Reino Unido
Democritus University of Thrace	Grecia	National Taipei University	Taiwán	University of Cincinnati	Estados Unidos
Department of Structural Engineering - California University	Estados Unidos	National Taipei University of Nursing and Health Sciences	Taiwán	University of Delaware	Estados Unidos
Dexia Group	Bélgica	National Taipei University of Technology	Taiwán	University of Delta	Nigeria
National Institute of Technology	India	National Taiwan University	Taiwán	University of Economics Bratislava	Eslovaquia
National Institute of Technology Rourkela	India	National Taiwan University of Science and Technology	Taiwán	University of Economics Ho Chi Minh City	Vietnam

Donghua University	China	National University of Singapore	Singapur	University of Edinburgh Business School	Reino Unido
Dorodnicyn Computing Centre of Federal Researcher Center "Computer Science and Control"	Federación Rusa	National Yunlin University of Science and Technology	Taiwán	University of Energy and Natural Resources	Ghana
DTEW	Bélgica	Nationwide Building Society	Reino Unido	University of Eyvanekey	Irán
Dumlupinar Üniversitesi	Turquía	NEC Laboratories America, Inc.	Estados Unidos	University of Ghana	Ghana
Durban University of Technology	Sudáfrica	NED University of Engineering & Technology	Pakistán	University of Huddersfield	Reino Unido
East Carolina University	Estados Unidos	New Jersey Institute of Technology	Estados Unidos	Sri Ramakrishna Engineering College	India
EC - Leasing Co.	Federación Rusa	New York University	Estados Unidos	University of Johannesburg	Sudáfrica
Ecole Nationale de Commerce et de Gestion	Marruecos	Newark College of Engineering	Estados Unidos	University of KwaZulu-Natal	Sudáfrica
Ecole Nationale d'Ingénieurs de Sfax	Túnez	Ngee Ann Polytechnic	Singapur	University of Luxembourg	Luxemburgo
École Supérieure de Management de Tlemcen	Argelia	Nile Higher Institute for Engineering and Technology	Egipto	University of Macau	Macao
Effat University, Saudi Arabia	Arabia Saudita	Gayatri Vidya Parishad College of Engineering For Women	India	St.Xavier's College, Palayamkottai	India
Ekonomicky ustav Slovak Academy of Sciences	Eslovaquia	GITAM University	India	T.K. Government Arts and Science College	India
Erasmus Universiteit Rotterdam	Países Bajos	Norges Teknisk-Naturvitenskapelige Universitet	Noruega	University of Alkafeel	India
Excelia Business School	Francia	Norsk Regnesentral	Noruega	University of Maryland Center for Environmental Science	Estados Unidos
EY (Ernst & Young)	Reino Unido	Northern Technical University	Iraq	University of Michigan, Ann Arbor	Estados Unidos
Faculté des Sciences - Rabat University	Marruecos	North-West University	Sudáfrica	University of Missouri-Kansas City	Estados Unidos
Faculté des Sciences Ben M'Sick	Marruecos	Northwestern Polytechnical University	China	University of Münster	Alemania
Faculty of Artificial Intelligence - Kafrelsheikh University	Egipto	NOVA Information Management School, Universidade Nova de Lisboa	Portugal	University of Nebraska Omaha	Estados Unidos
Faculty of Commerce - Mansoura University	Egipto	Npontu Technology	Ghana	University of Notre Dame	Estados Unidos


Faculty of Computer and Information - Mansoura University	Egipto	NVIDIA	Estados Unidos	University of Oxford	Reino Unido
Faculty of Computer Science and Engineering - Mansoura University	Egipto	OwnerIQ Inc.	Estados Unidos	University of Patras	Grecia
National Institute of Technology Tiruchirappalli	India	Oxford-Man Institute of Quantitative Finance	Reino Unido	University of Hyderabad	India
Faculty of Computers and Information - Benha University	Alemania	Özyeğin Üniversitesi	Turquía	University of Plymouth	Reino Unido
Faculty of Electronic Engineering - Menoufia University	Egipto	Glasgow Caledonian University	India	University of Presov in Presov	Eslovaquia
Faculty of Engineering - Tanta University	Egipto	Government College Kariavattom	India	University of Primorska	Eslovenia
Faculty of Engineering - University of Informatics	Egipto	Parthenope University	Italia	University of Rwanda	Ruanda
FAU College of Engineering and Computer Science	Estados Unidos	Payame Noor University	Irán	University of Salford	Reino Unido
Federal University of Petroleum Resources, Effurun	Nigeria	People's Public Security University of China	China	University of Sfax	Túnez
Financial Services Applications	Estados Unidos	Graphic Era Hill University	India	University of Sharjah	Emiratos Árabes Unidos
Florida Atlantic University	Estados Unidos	Petrol d.d.	Eslovenia	University of South Africa	Sudáfrica
Fraud Risk Management Analytics	Bélgica	Plekhanov Russian University of Economics	Federación Rusa	University of South Carolina - Upstate	Estados Unidos
FSEG Sfax - Faculté des Sciences Économiques et de Gestion de Sfax	Túnez	Plymouth Business School	Reino Unido	University of Southampton	Reino Unido
Fu Jen Catholic University	Taiwán	Polish Academy of Sciences	Polonia	University of Surrey	Reino Unido
Fuzhou University	China	Politechnika Krakowska	Polonia	University of Tabuk	Arabia Saudita
Panimalar Institute of Technology	India	Politechnika Poznanska	Polonia	University of Tafresh	Irán
Rajagiri School of Engineering & Technology	India	Politechnika Warszawska	Polonia	University of Technology Sydney	Australia
Gebze Teknik Üniversitesi	Turquía	Politecnico di Milano	Italia	University of Tehran	Irán
George R. Brown School of Engineering	Estados Unidos	Polytechnic STMI Jakarta	Indonesia	University of the Aegean	Grecia
German Jordanian University	Jordania	Pontificia Universidade Católica do Paraná	Brasil	University of the Peloponnese	Grecia

Rajalakshmi Institute of Technology	India	Prague University of Economics and Business	República Checa	University of the Western Cape	Sudáfrica
Royal Institute of Technology and Science	India	Prince Sattam Bin Abdul Aziz University Wadi Aldwassir	Arabia Saudita	University of Thessaly	Grecia
Saveetha Institute of Medical and Technical Sciences	India	Prince Sultan University	Arabia Saudita	University of Toronto	Canadá
Saveetha School of Engineering	India	Great Lakes Institute of Management, Chennai	India	University of Virginia	Estados Unidos
Gnosis Data Analysis	Grecia	Purdue University	Estados Unidos	University of Virginia School of Engineering and Applied Science	Estados Unidos
Goethe-Universität Frankfurt am Main	Alemania	Guru Gobind Singh Indraprastha University	India	University of Warsaw	Polonia
Graduate Institute of Business and Management National Taichung Institute of Technology	Taiwán	Jaypee University of Engineering and Technology	India	University of Washington	Estados Unidos
Sree Dattha Institute of Pharmacy	India	K L Deemed to be University	India	University of Waterloo	Canadá
Sreenidhi Institute of Science & Technology	India	Karpagam College of Engineering	India	University of Zagreb	Croacia
SRM Institute of Science and Technology	India	Lakireddy Bali Reddy College of Engineering	India	University of Zagreb, Faculty of Electrical Engineering and Computing	Croacia
Guangxi Key Laboratory of Hybrid Computation and IC Design Analysis	China	Renmin University of China	China	University Politehnica of Bucharest	Rumania
Guangxi Normal University for Nationalities	China	Rice University	Estados Unidos	Univerza v Ljubljani	Eslovenia
Guangxi University for Nationalities	China	Rollins College	Estados Unidos	Univerzitet u Sarajevu	Bosnia y Herzegovina
Guilin Tourism University	China	Rotman School of Management	Canadá	Uniwersytet Szczeciński	Polonia
Guosen Securities Co., Ltd.	China	Lovely Professional University	India	UNSW Business School	Australia
GW School of Business	Estados Unidos	Rutgers University–New Brunswick	Estados Unidos	UNSW Sydney	Australia
Handelshøyskolen BI	Noruega	Sabancı Üniversitesi	Turquía	UST Global	Estados Unidos
Hanoi Department of Education and Training	Vietnam	Saint Joseph's University, United States	Estados Unidos	University of Madras	India

Hanyang University	Corea del Sur	Saint Petersburg National Research University of Information Technologies, Mechanics and Optics University ITMO	Federación Rusa	University of Petroleum and Energy Studies	India
Hassan II University of Casablanca	Marruecos	Salford Business School	Reino Unido	Viet Nam National University Ho Chi Minh City	Vietnam
Hefei University of Technology	China	Santander Consumer Bank AS	Noruega	Veer Bahadur Singh Purvanchal University	India
Henan Institute of Science and Technology	China	Sao Paulo State Technological College (Faculdade de Tecnologia—Fatec)	Brasil	Vignans Foundation for Science Technology and Research University	India
Heriot-Watt University	Escocia	Sapienza Università di Roma	Italia	Virginia Polytechnic Institute and State University	Estados Unidos
Higher Colleges of Technology	Emiratos Árabes Unidos	SAS Institute, Inc.	Estados Unidos	Virginia Tech, Pamplin College of Business	Estados Unidos
Higher Institute for Computers and Information Technology	China	Madras Christian College	India	Visa Inc.	Estados Unidos
HKU Business School	Hong Kong	Satbayev University	Kazajistán	Wasit University	Iraq
HNC Software, Inc.	Estados Unidos	Saudi Electronic University	Arabia Saudita	West Pomeranian University of Technology, Szczecin	Polonia
Ho Chi Minh City University of Technology - HUTECH	Vietnam	Maharishi Markandeshwar (Deemed to be University), Mullana	India	Western University	Canadá
Hochschule Stralsund	Alemania	Maharshi Dayanand University	India	Wordline Research	Francia
HØGSKULEN PÅ VESTLANDET	Noruega	Mepco Schlenk Engineering College	India	Worldline Research	Francia
HSE University	Federación Rusa	Nirma University	India	Wuchang University of Technology	China
Huafan University	Taiwán	Nirma University, Institute of Technology	India	Xiamen University	China
Huarong Rongtong (Beijing) Technology Co., Ltd.	China	Sekolah Tinggi Manajemen PPM	Indonesia	Xiamen University of Technology	China
Huazhong University of Science and Technology	China	Seoul National University	Corea del Sur	Xi'an Jiaotong University	China
Hubei University Of Economics	China	Shandong Technology and Business University	China	Xi'an University of Science and Technology	China
Huddersfield Business School	Reino Unido	Shandong University of Finance and Economics	China	Yakın Doğu Üniversitesi	Chipre
Hunan Institute of Engineering	China	Shanghai Jiao Tong University	China	Yaşar Üniversitesi	Turquía

Hunan Normal University	China	Shanghai Maritime University	China	Yonsei University	Corea del Sur
Hunan University	China	Shanghai Stock Exchange	China	Zarqa University	Jordania
IEEE	Taiwán	Shanghai University	China	Zayed University	Emiratos Árabes Unidos
Imam Ja'afar Al-Sadiq University	Iraq	Shanghai University of Finance and Economics	China	ZHAW Zurich University of Applied Sciences	Suiza
Independent	España	ShanghaiTech University	China	Zhejiang Gongshang University	China
Independent Researcher	Internacional	Panimalar Engineering College	India	Zhejiang University	China

Fuente: Elaboración propia con información de SCOPUS - Elsevier (2024)



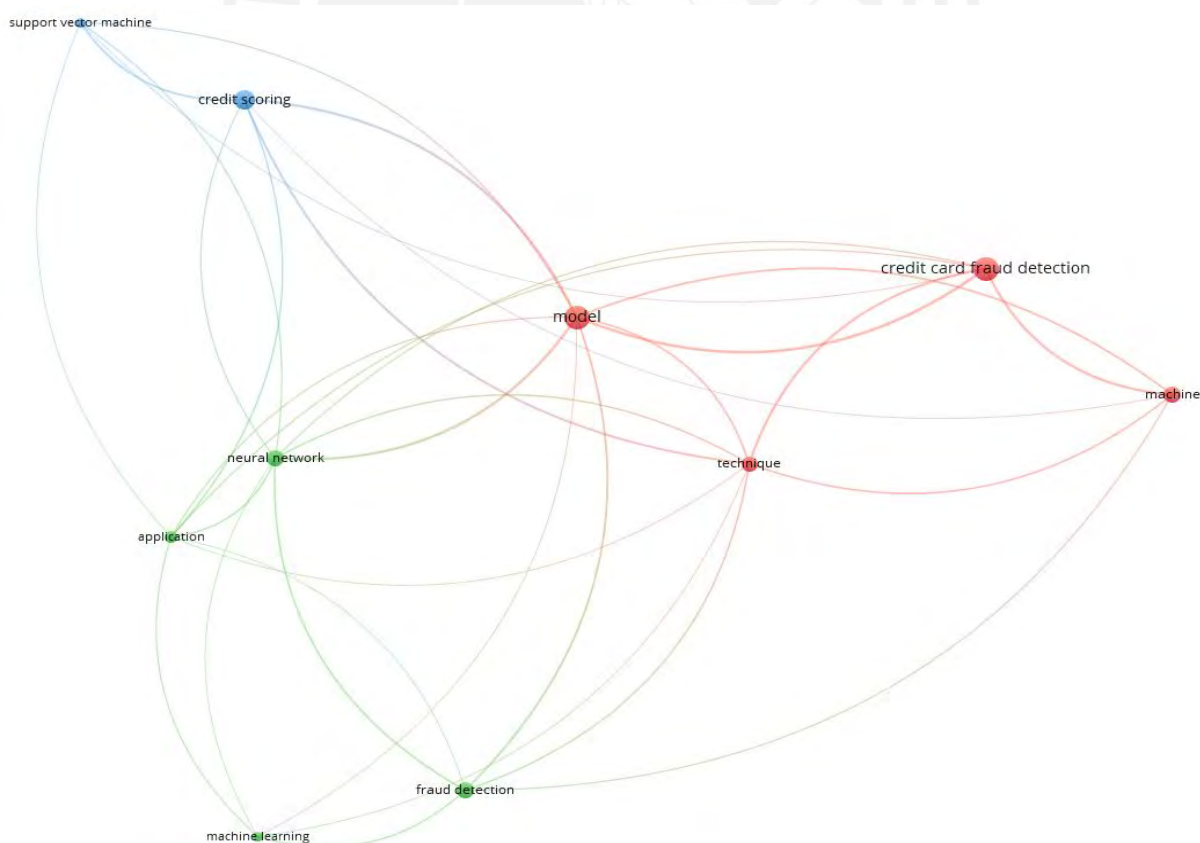
4.5.5 Análisis de palabras clave en VOSViewer:

La figura 14 muestra el análisis de los resultados obtenidos en la búsqueda a partir de sus palabras clave. Cabe destacar que se realizó este análisis con un mínimo de 9 ocurrencias por palabra clave, esto producto del amplio abanico de resultados. En la figura se puede distinguir 3 clusters:

- Rojo: Asociado a la aplicación de las tecnologías en detección de fraudes en tarjetas de crédito.
- Verde: Asociado a la detección de fraudes en operaciones bancarias en general (incluyendo créditos y otras anomalías)
- Azul: Asociado al *scoring* crediticio.

Asimismo, se destaca que la gran mayoría de elementos dentro de los clusters giran en torno al término *model*, lo cual es coherente con el objeto de estudio del presente trabajo de investigación, así como los elementos de *machine learning*, *deep learning* y sus derivados.

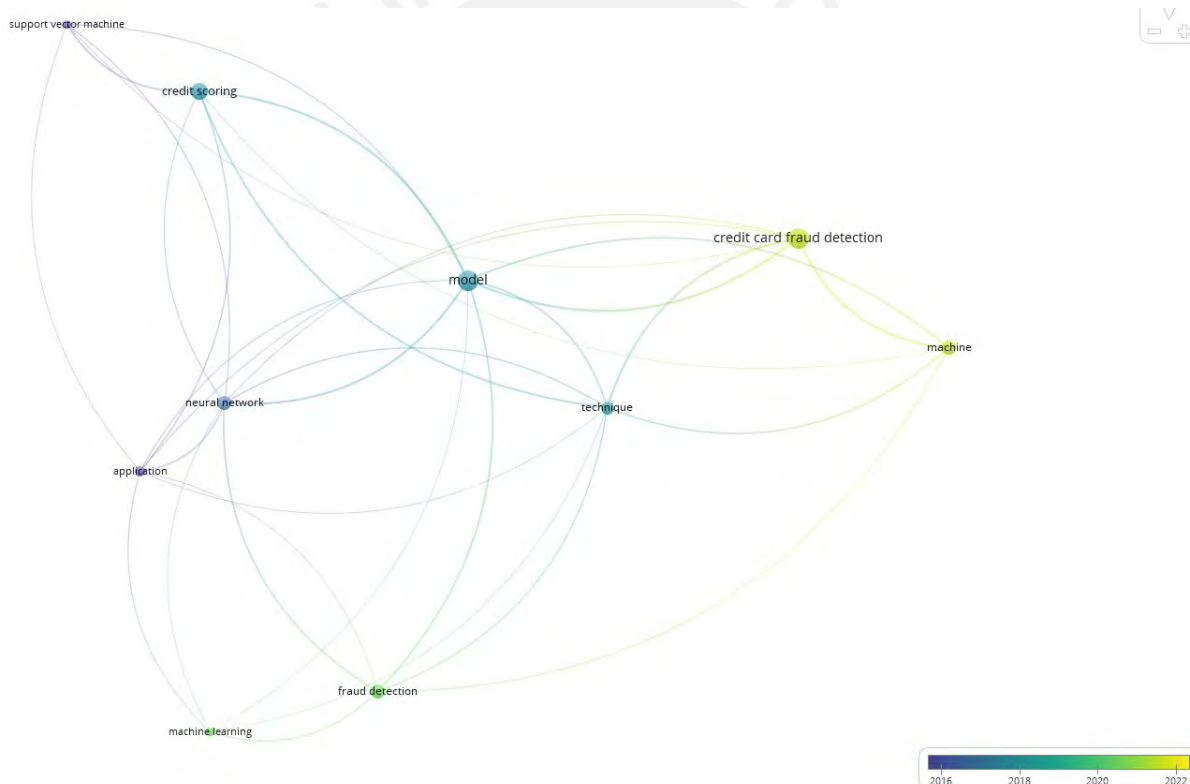
Figura 14: Agrupación por palabras clave de los artículos encontrados



Fuente: Elaboración propia con información de SCOPUS - Elsevier (2024) mediante VOSViewer

Ahora, al añadir la variable tiempo a este análisis se observa que el interés de aplicar las tecnologías antes mencionadas se reparte de forma relativamente uniforme en el periodo 2014-2022, sobre todo para la detección de fraude en tarjetas de crédito. Dicha uniformidad encuentra sustento en el impacto de la pandemia en la virtualización y transformación digital de los servicios financieros (particularmente en el bloque asiático). Por otro lado, se observa un crecimiento sostenido de trabajos por el lado del uso de redes neuronales (*deep learning*) y su aplicación en la banca (ya como bloque conjunto de servicios financieros), lo que supone un avance significativo en esta transformación tecnológica, con especial énfasis en la detección de fraudes en tarjetas de crédito. La figura 15 muestra lo expuesto anteriormente, donde los colores de los elementos de cada clúster representan los periodos de tiempo.

Figura 15: Análisis temporal de la agrupación por palabras clave de los artículos encontrados



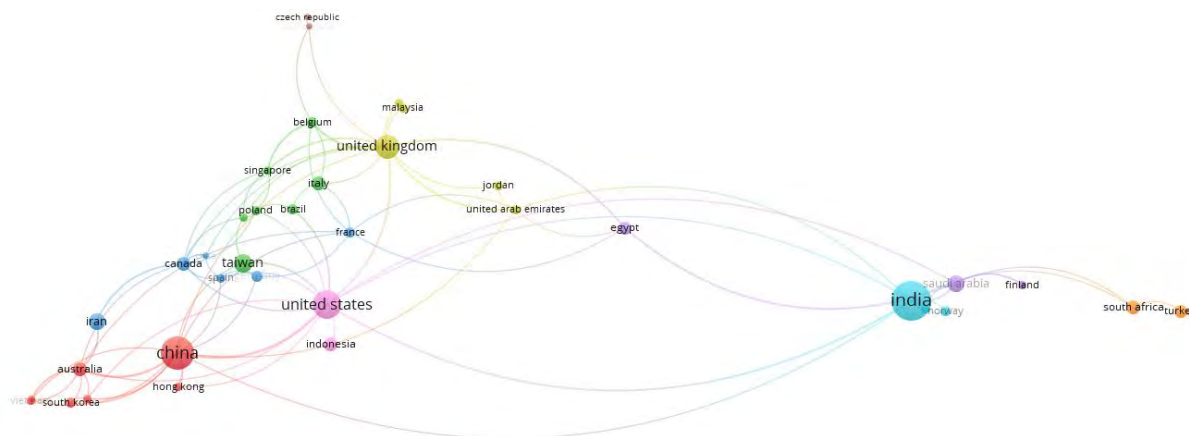
Fuente: Elaboración propia con información de SCOPUS - Elsevier (2024) mediante VOSViewer

4.5.6 Redes de colaboración en publicaciones científicas:

La figura 16 muestra un análisis a nivel de países de origen de las investigaciones mostradas anteriormente. Bajo este concepto, se analiza colaboraciones donde los países en cuestión hayan aportado con al menos dos publicaciones. El resultado muestra cuatro grandes bloques de colaboración: el primero, liderado por Reino Unido, con 15 países colaboradores (incluyendo USA y China); el segundo, liderado por Estados Unidos, con 14 países

colaboradores (incluyendo Reino Unido, China y la India); el tercero, liderado por China, con 11 países colaboradores (incluyendo los países de India, Reino Unido y USA) y el bloque de la India, con 6 países. En líneas generales, se detectan variadas redes de colaboración tanto por parte del bloque asiático como del europeo. Destaca también la intercolaboración entre estos cuatro países ya mencionados.


Figura 16: Primera agrupación de países líderes en aportes científicos



Fuente: Elaboración propia con información de SCOPUS - Elsevier (2023) mediante VOSViewer

Ahora, una segunda iteración (elevando el número de publicaciones a 5), dado el número de resultados, lo muestra la figura 17. Como se mencionó anteriormente, el bloque asiático es el más presente y el país que lidera los esfuerzos de investigación es China, seguido de otros países como India, USA y Reino Unido, países muy involucrados en elementos de transformación tecnológica e innovación, lo que justifica la interrelación entre ellos, lo que se traduce en la colaboración estrecha entre ambos países, como lo muestra la gráfica.

Figura 17: Segunda agrupación de países líderes en aportes científicos



Fuente: Elaboración propia con información de SCOPUS - Elsevier (2023) mediante VOSViewer

4.5.7 Publicaciones científicas a destacar:

En este acápite se realizarán dos bloques de análisis: el primero corresponde a las publicaciones relacionadas con la detección de fraude y el segundo respecto al *scoring* crediticio.

Detección de Fraude:

Khan et al. (2022) aporta una alternativa de mejora a los modelos de clasificación convencionales que sufren el sesgo del desequilibrio de datos¹¹. A nivel procedimental, se destacan dos instantes principales:

- **Procesamiento de la Información:** El conjunto de datos cuenta con un total de 284,807 transacciones hechas con tarjeta de crédito, de las cuales 492 (el 0.172%) corresponden a operaciones fraudulentas. Aquí se evidencia el problema del desequilibrio de datos, el cual se aborda mediante técnicas de remuestreo que permiten equilibrar el volumen de transacciones legítimas. Para la alimentación del modelo (el conjunto de datos de entrenamiento), se empleó el análisis de componentes principales¹², asignando valores de 1 y 0 a las transacciones fraudulentas y legítimas, respectivamente.
- **Modelamiento:** Aquí los autores exploran tres modelos para dicha categorización:
 - **Regresión Logística:** Este modelo utiliza probabilidades para determinar el tipo de transacción que corresponde a un fraude. En este sentido, si la probabilidad calculada es superior a un umbral predeterminado (por ejemplo, 0.5), se clasifica como fraudulenta. En palabras del autor, la detección de fraude se reduce a un problema de clasificación binaria, razón por la cual este modelo se ajusta como potencial solución a dicho problema.
 - **Redes Neuronales Artificiales (ANN):** Esta red consta de dos capas ocultas, de las cuales se obtienen dos valores en la capa de salida: 0 si la operación es conforme y 1 si es fraudulenta. Este trabajo emplea el concepto de una red neuronal *prealimentada* (F-FNN), las cuales se construyen de forma recurrente y lineal. Esta constituye el tipo más sencillo de red neuronal.
 - **Máquinas de Vector Soporte:** Este último modelo emplea el concepto del hiperplano más óptimo para clasificar los datos de la mejor forma posible. Cabe

¹¹ Se le llama desequilibrio de datos al sesgo que genera la información de variables de tipo categórica cuando existe un valor predominante sobre el resto. Este sesgo podría causar inconsistencias en el modelo a construir y reducir su efectividad, así como imposibilitar la detección de nuevos casos (Carrasco, 2021).

¹² El modelo de análisis de componentes principales es un tipo de modelo de *machine learning* no supervisado que busca determinar qué características son relevantes a partir de un conjunto de datos. Dicho modelo permite entrenar modelos supervisados de clasificación (Véliz, 2020).

recalcar que, en la preparación de la información para el modelo, se obtuvieron 28 características diferentes tras el modelo de componentes principales, por lo que la complejidad de este modelo es mucho más aguda.

Finalmente, la tabla 10 muestra los indicadores de rendimiento para los tres modelos descritos anteriormente. Se destacan en la capacidad de detección de casos negativos y se llega a la conclusión que el modelo de máquinas de vector soporte se desempeña mejor dados todos los indicadores:

Tabla 10: Indicadores comparativos de los modelos estudiados

Modelo	Accuracy	Precision	Recall
Regresión Logística	99.91%	87.32%	61.59%
Redes Neuronales	99.91%	76.91%	75.81%
SVM	99.94%	87.67%	78.05%

Fuente: Khan et al. (2022)

Otro trabajo propuesto por Benchaji et al. (2021) ofrece un modelo de detección de fraude con base en el *deep learning*. Este modelo emplea redes neuronales de tipo *Long Short-Term Memory* (LSTM¹³) así como un mecanismo de atención adicional que permite seleccionar las características más importantes de la información, las cuales evitan la selección de elementos de poco valor. Para su construcción se siguen las siguientes etapas:

1. Realizar la reducción de características (también llamada reducción dimensional) de la información mediante algoritmos como *Principal Component Analysis* (PCA), *t-distributed Stochastic Neighbor Embedding* (t-SNE¹⁴) y el *Uniform Manifold Approximation and Projection* (UMAP¹⁵).
2. Balancear las bases de datos mediante técnicas de sobremuestreo sintético (SMOTE), la cual crea datos *sintéticos*, de forma que las características que cuenten con poca información puedan emparejarse con otras que sí cuenten con mayor información. Se utiliza para prevenir sesgos en la información.

¹³ El autor define este modelo como un tipo especial de red neuronal que tiene la capacidad de aprender de sus elementos predecesores en el tiempo (y un largo tiempo, de ahí su nombre)

¹⁴ Algoritmo que permite observar un registro de información de un gran número de características como una variable en tres dimensiones, de modo que componentes de similares características pueden agruparse de modo que sea más sencillo detectar patrones (IBM).

¹⁵ Algoritmo que cuenta con un funcionamiento similar al del t-SNE, solo que ofrece una mayor eficiencia computacional cuando se trabaja con grandes volúmenes de información.

3. Construcción de la red neuronal LSTM, de forma que pueda clasificar las transacciones de forma dinámica y generar dependencias de longitud grande.
4. Aplicar el instrumento de atención a la red. Dicho mecanismo permite focalizar la atención de los clasificadores en ciertas características antes de formular la decisión global sobre una transacción. De esta forma, se mejora la eficiencia del modelo.
5. Aplicar el modelo a los conjuntos de datos.

Ahora, a nivel de resultados, este modelo evaluó dos bases de datos, las cuales cuentan con características propias. La tabla 11 muestra el resumen obtenido:

Tabla 11: Indicadores comparativos de eficiencia del modelo contra dos *datasets* distintos

Dataset	Registros	Fraudulentos	Accuracy	Precision	Recall
1	284,807	28	96.72%	98.85%	91.91%
2	594,643	7200	97.48%	97.69%	97.22%

Fuente: Benchaji et al. (2021)

El trabajo de Plakandaras et al. (2022) presenta un sistema basado en herramientas de machine learning diseñado para mejorar la detección de fraudes en transacciones mediante tarjeta de crédito. Esta integración se logra mediante el uso del sistema Just Add Data Bio (JAD), desarrollado por AWS. Utilizando un conjunto de datos de entrenamiento, el sistema selecciona variables críticas para la detección de fraudes y genera modelos que permiten discriminar con alta efectividad las transacciones fraudulentas. El sistema se compone de tres bloques principales de modelos: árboles de decisión, bosques aleatorios y máquinas de vectores soporte (SVM), los cuales son evaluados por una inteligencia artificial que selecciona qué modelo usar dentro de una familia de modelos. En términos de precisión, el mejor modelo (un modelo de regresión con ajuste Ridge) alcanza una precisión del 84.78% (con 39 detecciones exitosas de 46, 7 omisiones y 10 falsos positivos). Es notable destacar que este enfoque resulta en un ahorro económico de 7,535.24 euros gracias a las 39 transacciones exitosas detectadas, mientras que los casos no detectados representan solo 477.64 euros, cifras muy alentadoras.

En relación con lo anterior, se puede afirmar que los dos bloques de modelos más utilizados y sobre los cuales se construyen la mayor parte de sistemas son los árboles de decisión y las máquinas de vectores soporte (SVM). El trabajo de Al-Fatlawi et al. (2024) emplea estos modelos junto con algoritmia genética (un concepto definido en el capítulo 2) para mejorar la precisión en la detección de fraudes en transferencias en línea y el uso de tarjetas de crédito.

Para ello, se trabajó con dos conjuntos de datos de la banca en línea alemana y se evaluaron tres bloques de modelos:

- Árbol de Decisión (DT)
- Máquina de Vector Soporte (SVM)
- Árbol de Decisión (con población inicial de 15 individuos) con algoritmia genética (AdDT)

La tabla 12 muestra los principales indicadores de rendimiento. A partir de estos resultados, se concluye que los árboles de decisión son la mejor herramienta para detectar fraudes en operaciones bancarias y que el enfoque adicional de los algoritmos genéticos proporciona resultados satisfactorios y superiores, sin restar importancia al rendimiento potente de los modelos SVM. Los autores definen dos momentos: el primero antes de filtrar los componentes principales del modelo y el segundo después de filtrar las características principales.

Tabla 12: Indicadores comparativos de eficiencia entre árboles de decisión y modelos SVM

Modelo	DT		SVM		AdDT	
	Antes	Después	Antes	Después	Antes	Después
Precision	71.67	71.67	78.67	79.33	75.67	76.00
Recall	83.33	83.33	90.00	91.43	93.33	90.00
Accuracy	77.78	77.78	81.47	81.36	76.86	78.75

Fuente: Al-Fatlawi et al. (2024)

Scoring Crediticio:

El trabajo de Bastos (2022) emplea el concepto de árbol de decisión potenciado (BDT) que emplea el concepto de *boosting*, el cual realiza una fusión de múltiples modelos de menor potencia en un gran modelo con mayor capacidad mediante el uso de iteraciones continuas. Una de las ventajas de esta mejora es que proporciona al modelo robustez ante cambios en los *datasets* de entrenamiento y le brinda mayor estabilidad.

Con fines de contrastar la potencia del modelo, este se probó en dos bases de datos (una de la banca alemana y otra de la banca australiana) y se comparó contra un modelo de máquina de vector soporte (SVM) y un modelo de red neuronal de tipo perceptrón multicapa. La tabla 13 muestra la comparativa de poder de clasificación acertada del modelo a partir del trazado de sus ROC, siendo la mayor área la del modelo de árbol de decisión para ambos grupos de datos:

Tabla 13: Indicadores comparativos de eficiencia del modelo BDT contra otros modelos para los dos *datasets* propuestos

Modelo	Data Alemana	Data Australiana
MLP	73.8%	92.3%
SVM	79.9%	92.9%
BDT	81.1%	94.0%


Fuente: Bastos (2022)

Un caso novedoso lo presenta Plawiak et al. (2019), el cual introduce un modelo nuevo de red neuronal, la cual llama *Deep Genetic Hierarchical Network of Learners* (DGHNL) la cual ofrece cuatro características particulares:

- Entrenamiento por niveles, lo que le permite a la red retroalimentar su propia estructura. Podría decirse que es una característica similar a las redes neuronales de tipo LSTM, explicadas en el acápite anterior.
- Simultaneidad de ejecución de modelos de *machine learning*: este sistema cuenta con un abanico de 5 modelos que funcionan de manera simultánea: dos de SVM, dos de red neuronal y un sistema difuso¹⁶.
- Estructura de red basada en jerarquías, lo que aporta trazabilidad a la clasificación y permite una mayor profundidad de análisis a medida que se desagregan estas jerarquías.
- Estructura basada en un modelo de *deep learning*, aspecto que brinda robustez al modelo.

A nivel diagrama de flujo, el desglose es de la siguiente manera, tal y como se muestra en la figura 18. El *dataset* utilizado corresponde a información de clasificación empleado por la banca alemana:

Figura 18: Flujo del modelo DGHNL



Fuente: Plawiak et al. (2019)

A nivel de resultados, se probaron dos conjuntos de datos: el primero corresponde a créditos aceptados y el segundo, a rechazados. Este modelo ofrece un *accuracy* de 93.30% para el

¹⁶ Echeverri et al. (2012) define los sistemas difusos (*fuzzy system*) como un modelo que permite realizar clasificaciones tomando en cuenta elementos subjetivos (información de tipo ambigua o con alguna imprecisión) y de difícil tangibilización numérica.

primer bloque y 98.40% para el segundo. Dichos números suponen resultados alentadores dado que este modelo no representa un modelo dicotómico de clasificación, y permite asegurar finura a la hora de otorgar créditos.

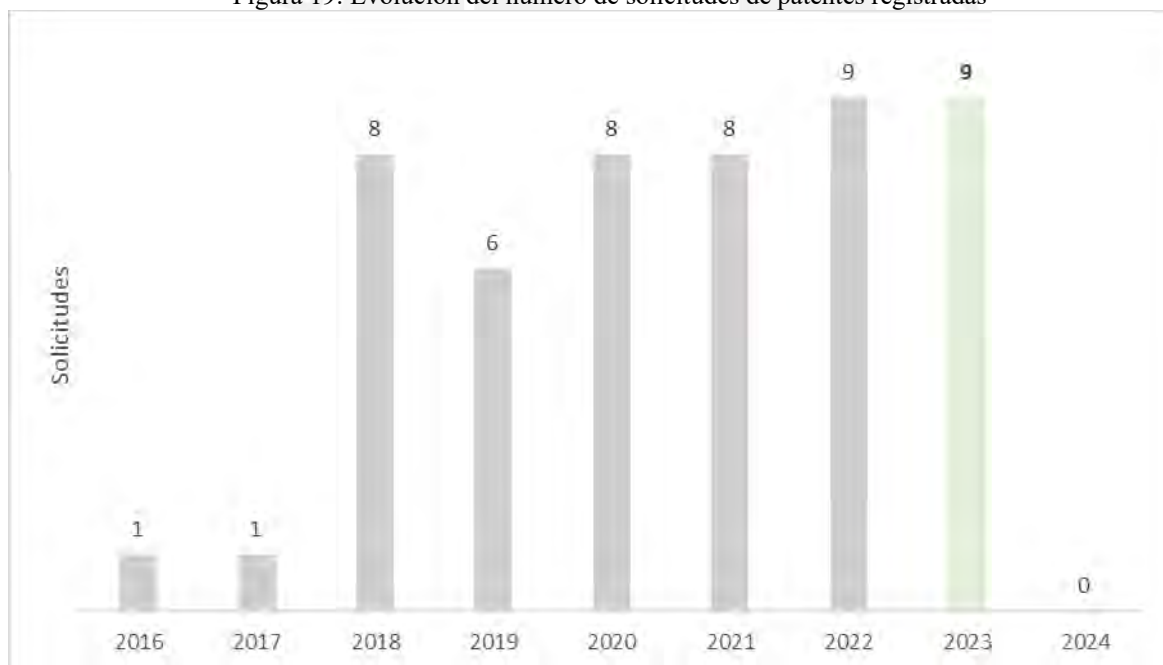
De manera similar al caso de la detección de fraudes, se prefiere el uso de metodologías de *boosting* y el uso de algoritmos como árboles de decisión y SVM dada su versatilidad y los valores altos de sus indicadores.

4.6 Desarrollo Etapa 6: Análisis de Información de Patentes:

4.6.1 Solicitudes de Patentes en WIPO:

De la gráfica 19 se aprecia que el núcleo fuerte de registros de solicitudes se distribuye uniformemente en el periodo 2021-2023, con una media de casi 8 por año. Al cierre del 2023, se tiene un total de 9 solicitudes registradas. Cabe resaltar que el periodo de tiempo de donde se dispone información es desde el año 2016, lo cual permite concluir que dichos sistemas son una tendencia relativamente reciente.

Figura 19: Evolución del número de solicitudes de patentes registradas




Fuente: Elaboración propia con información de WIPO (2023)

Llevando el análisis a nivel país, se aprecia que India lidera los esfuerzos de innovación en estos sistemas con 23 solicitudes registradas, lo cual hace sentido a la fuerte presencia de estos países (y del bloque asiático en general) en trabajos de esta índole. A este país le sigue China con 14. Por el lado americano, Estados Unidos cuenta con 6 solicitudes y Canadá con una. Se destaca presencia latinoamericana por parte de México, con un registro. Finalmente se

encuentran patentes registradas bajo firma multinacional (PCT) con 3 solicitudes y conglomerados europeos con una solicitud. Lo anterior, lo ilustra la figura 20:

Figura 20: Países involucrados en solicitudes de patentes



Fuente: Elaboración propia con información de WIPO (2023)

4.6.2 Clasificación de las patentes solicitadas:

Como parte de los registros de solicitudes de patentes, a estos se les asigna un código único, el cual se define dependiendo del sector tecnológico al cual se orienta. Dicha clasificación la ofrece la Clasificación Internacional de Patentes (CIP) o IPC por sus siglas en inglés (International Patent Classification).

Dichos códigos están enumerados alfabéticamente, con letras de la A a la H y se abren hasta un cuarto nivel. La tabla 14 muestra las clasificaciones de las patentes registradas en el acápite anterior. Cabe resaltar que una misma patente puede ingresar con más de una sectorización (es decir, múltiples códigos asociados a una sola patente).

Tabla 14: Listado de códigos de patentes detectados

CIP	Descripción	Solicitudes
G06Q	Este código se refiere a métodos o sistemas de procesamiento de datos relacionados con la gestión o administración de actividades económicas, comerciales o financieras. Estas patentes están relacionadas con tecnologías utilizadas en el ámbito de los negocios, como sistemas de pago, servicios bancarios, gestión de inventarios, análisis de mercado, entre otros.	49
G06N	Este código se refiere a patentes relacionadas con sistemas o métodos de computación basados en modelos o simulaciones de procesos cognitivos o neuronales. Estas patentes están relacionadas con el campo de la inteligencia artificial y el aprendizaje automático, abarcando áreas como redes neuronales, algoritmos de aprendizaje, sistemas expertos y otras tecnologías relacionadas con la emulación de procesos cognitivos humanos.	32
G06F	Este código se refiere a patentes relacionadas con tecnologías de la información y la computación en general. Engloba una amplia variedad de invenciones en el ámbito de la informática, como hardware, software, sistemas de procesamiento de datos, programación, arquitectura de computadoras, sistemas operativos, entre otros.	9
G06K	Este código se refiere a patentes relacionadas con tecnologías de reconocimiento de patrones y procesamiento de imágenes. Estas patentes están asociadas con técnicas de identificación automática, como reconocimiento de caracteres, reconocimiento de huellas dactilares, reconocimiento facial, reconocimiento de objetos, sistemas de visión artificial, entre otros.	4
G07F	Este código se refiere a patentes relacionadas con tecnologías de sistemas de manejo de dinero, como sistemas de pago, máquinas expendedoras, cajeros automáticos, sistemas de identificación y autenticación de billetes, dispositivos de seguridad para efectivo, entre otros.	4
G16H	Este código se refiere a patentes relacionadas con tecnologías de interacción humano-máquina y sistemas de control de procesos. Estas patentes están asociadas con dispositivos y métodos para la interacción entre humanos y máquinas, como interfaces de usuario, dispositivos de entrada/salida, realidad virtual, realidad aumentada, sistemas de control automatizados, entre otros.	3
H04L	Este código se refiere a patentes relacionadas con tecnologías de comunicación de datos y redes de telecomunicaciones. Estas patentes abarcan áreas como transmisión de datos, protocolos de comunicación, redes de área local (LAN), redes de área extensa (WAN), seguridad de la información, criptografía, entre otros.	2
H04M	Este código se refiere a patentes relacionadas con tecnologías de comunicación telefónica y sistemas telefónicos en general. Estas patentes están asociadas con sistemas y métodos de telecomunicaciones, como telefonía fija, telefonía móvil, servicios de voz, sistemas de mensajes, enrutamiento de llamadas, entre otros.	2
G10L	Este código se refiere a patentes relacionadas con tecnologías de procesamiento de señales de audio o de voz. Estas patentes están relacionadas con codificación de audio, compresión, reconocimiento de voz, síntesis de voz, mejoras en la calidad del sonido, tecnologías de grabación, entre otros.	1
H04W	Este código se refiere a patentes relacionadas con tecnologías inalámbricas y redes de comunicación móvil. Estas patentes están asociadas con sistemas y métodos para la comunicación inalámbrica, como redes móviles, tecnologías de acceso inalámbrico, transmisión de datos móviles, protocolos de comunicación, entre otros.	1

Fuente: Elaboración propia con información de WIPO (2023)

De la tabla anterior destacan dos grandes bloques de patentes: las G06Q, los cuales se asocian a sistemas de manejo de datos, lo cual resulta coherente con lo expuesto en la etapa de publicaciones (en especial las referentes a transacciones bancarias, objeto de estudio de los modelos expuestos), y las G06N, asociado a los modelos propiamente dichos, en especial algoritmos de *machine learning* y *deep learning*.

4.6.3 Patentes a destacar:

Chen et al. (2019) ofrece un modelo de *scoring crediticio* aplicado a entornos de préstamos P2P, es decir, entre personas y sin ningún mediador directo. Este sistema permite recopilar la información de personas que buscan créditos de forma activa y los que buscan brindarlos de modo que se verifiquen y alimenten este modelo. De esta forma, los prestamistas podrán contar con la información del solicitante y verificar si son solventes o no.

Otro trabajo muy interesante es el de Hao et al. (2018), quienes lograron diseñar un sistema que permite detectar fraude en tiempo real aplicado a la obtención de créditos vía online. Este sistema emplea un algoritmo de clasificación de tipo *k-means*¹⁷ el cual, con la información del cliente, alimenta un modelo no supervisado de detección que permite determinar la probabilidad de que el crédito haya sido asignado a un cliente no solvente. Asimismo, a partir de estas características, el modelo es capaz de detectar nuevos patrones de fraude de modo que se pueda atender de forma más temprana.

¹⁷ El modelo *k-means* es un tipo de aprendizaje no supervisado, el cual permite agrupar datos en elementos llamados *clusters*. Mediante el uso de puntos aleatorios como los “centros” de cada cluster, el modelo irá refinando estos clusters para hacer grupos cada vez más precisos (Ramírez, 2023).

CAPÍTULO 5: CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones:

Como parte concluyente del despliegue de la metodología trabajada a lo largo de la presente tesis, se ejecuta la última etapa, la cual corresponde al cierre del informe de vigilancia tecnológica. Para este fin, se formularán las conclusiones con base en los objetivos planteados al inicio de este trabajo.

Sobre las principales novedades a destacar, a nivel bibliométrico, la mayoría de estos trabajos científicos tomaron como referencia tres grandes bloques de modelos: las máquinas de vector soporte (SVM), los árboles de decisión (incluyendo los bosques aleatorios y su potenciación mediante modelos de *boosting*) y las redes neuronales artificiales (como parte del *deep learning*). Esto se refleja en el análisis de palabras clave con VOSViewer mostrado en el capítulo anterior. Como herramienta, destaca el estudio de nuevos sistemas que combinan estos modelos (como el caso de DGHNL para el caso de *scoring crediticio* y el sistema JAD para detección de operaciones fraudulentas) y el uso de métodos complementarios para potenciar estos modelos como es el caso del *boosting*.

Sobre las publicaciones científicas, si bien es cierto Perú cuenta con una investigación aplicada al sector de *scoring crediticio*, aún el desarrollo científico nacional es de carácter incipiente (tomando en cuenta que el artículo en cuestión es del 2023). De aquí se puede afirmar que Perú aún se encuentra rezagado en cuanto a investigaciones de este estilo, pero con el dato alentador de que ya se cuenta con trabajos al respecto, como los boletines que ha lanzado el CONCYTEC durante el segundo semestre del 2023.

Por otro lado, a pesar de que el bloque americano cuenta con publicaciones (siendo USA el representante con mayor presencia), es un hecho que el bloque asiático lidera los esfuerzos de investigación. India lidera este bloque con un total de 67 publicaciones las cuales en su mayoría pertenecen a universidades, institutos y centros de investigación. Un dato que refuerza esta causalidad es lo que expone Nagaki (2016), quien comenta que la inclusión financiera en India ha tenido un crecimiento acelerado (18% de incremento de bancarización entre 2011 y 2014), así como el activo interés de su estado en materia de investigación, como se comentó en el capítulo anterior.

Por el lado de las patentes, Perú no cuenta con ninguna solicitud registrada para sistemas de esta naturaleza. Este aspecto, en relativa medida, afecta la capacidad de las *fintechs* a innovar en cuanto a estos elementos, lo que les reduce competitividad, confiabilidad y genera el efecto comentado al inicio de este trabajo, la mortalidad de estas empresas.

Países como China e India, que cuentan con sistemas financieros sólidos y Estados Unidos, que cuenta con un ecosistema *fintech* nutrido, son los tres países que cuentan con registros de estas invenciones.

Sobre las patentes obtenidas sobre estos modelos, predomina la clasificación de tipo G06Q y G06N con 49 y 32 apariciones respectivamente, la cual hace referencia a sistemas de gestión de información financiera y sobre modelos diseñados a partir de estos. Dentro de este bloque, destaca el desarrollo de sistemas de detección de fraude en tiempo real a partir de algoritmos de aprendizaje no supervisado, el cual no solo permite la detección temprana de estos casos, sino que también tiene la capacidad de detectar nuevos.

Otro caso destacado es el de la aplicación de préstamos P2P sobre la base de algoritmos no supervisados de scoring, con el fin de garantizar a los prestatarios clientes con solvencia suficiente para dichos créditos.

A nivel estratégico, el análisis PESTEL realizado muestra que Perú cuenta con un panorama económico alentador (y superior a los países de la región), lo que brinda oportunidades de potenciar la labor del CONCYTEC (e incluso la posibilidad de aperturar un ministerio de esta índole, según Panta, 2023). Asimismo, a nivel regulatorio, se está logrando avances significativos en la consolidación de modelos de negocio de tipo *fintech*, como el caso del *Sandbox regulatorio* de la SBS y medidas a favor de modelos de negocio innovadores (SBS N° 2049-2021). Por el lado técnico, Perú cuenta con entidades financieras prestas para la implementación de estos modelos. Muestra de ello es el caso de Alfin Banco el cual se convirtió en la primera entidad financiera que funciona totalmente en la nube (Microsoft, 2023) así como el servicio de chatbot potenciado por inteligencia artificial que está implementando el BCP, además de sistemas de reconocimiento facial y reconocimiento de voz, con el fin de prevenir fraudes bancarios. (INFOBAE, 2023).

5.2 Recomendaciones:

Es necesario recordar que el propósito de este trabajo es proporcionar un análisis detallado de las oportunidades y amenazas relacionadas con la posible implementación de herramientas y modelos en las operaciones de las empresas interesadas. Este trabajo podría considerarse como una recopilación de datos que debe ser complementada y fortalecida con las características propias y debilidades de estas empresas, de manera similar al funcionamiento de una matriz FODA, con el fin de determinar el mejor curso de acción.

A pesar de los resultados prometedores en términos de tecnología que podrían implementarse en estos sistemas, aún persisten ciertas incógnitas por resolver, como los costos asociados, tanto en el diseño como en la arquitectura de estos sistemas, así como los aspectos regulatorios relacionados con su implementación en servicios financieros. Otro desafío propio de la implementación de dichos modelos hace referencia a la naturaleza de la información. Cada sistema financiero a nivel local y regional cuenta con una estructura propia de características en cuanto a transacciones, créditos, tarjetas y acciones

propias de la banca tradicional y digital, por lo que se requiere un análisis diferenciado de dicha información con el fin de que los modelos que se ejecuten sobre esta sean correctos y funcionen de forma apropiada.

Por otro lado, como se mencionó anteriormente, Perú aún se encuentra rezagado en términos de investigación y registro de solicitudes en este ámbito. Sin embargo, existen indicios suficientes para demostrar que la implementación de estos sistemas es factible. Se destaca la importancia de fomentar más investigaciones sobre el tema, para que, en un futuro cercano, las entidades financieras puedan adoptar estas nuevas tecnologías de manera rápida y eficiente. Si bien se ha dado un primer paso con la publicación de los boletines mencionados anteriormente, es necesario profundizar en esta investigación y fortalecer el capital humano destinado a este fin.

Por otro lado, trabajos como el de Asensios (2023) prueban que la implementación de estos modelos en la evaluación de créditos, por lo que un análisis en entidades financieras de banca tradicional y el mercado *fintech* generaría un impacto significativo en la prevención de delitos cibernéticos y en la mejora de las propuestas de valor.

Y lo anterior no se reduce únicamente al sector de créditos. Como se comentó en el capítulo 2, existen áreas en las cuales se podría evaluar y aplicar tanto la metodología como los modelos propiamente dichos. Una de estas, y que según EY está en crecimiento, es el sector de cambio de divisas y el de criptomonedas, debido a la flexibilidad que tienen estas divisas tanto para invertir como para intercambiar, así como lo ágil de estos procedimientos.

CAPÍTULO 6: REFERENCIAS BIBLIOGRÁFICAS

American Society for Quality. AI-based model for fraud detection in bank systems (2024). Recuperado de <https://www.americaspg.com/articleinfo/3/show/2220>

Aivo. (s.f.). 7 Ways Artificial Intelligence Will Change Fintechs. Recuperado de <https://es.aivo.co/blog/7-ways-artificial-intelligence-will-change-fintechs>

Amazon Web Services. (s.f.). ¿Qué es una red neuronal? Recuperado de <https://aws.amazon.com/es/what-is/neural-network/#:~:text=Una%20red%20neuronal%20es%20un,lo%20hace%20el%20cerebro%20humano.>

Amazon Web Services. (s.f.). What is a large language model? Recuperado de <https://aws.amazon.com/es/what-is/large-language-model/>

Andina. (s.f.). Cuidado, los fraudes informáticos: estas son las modalidades más denunciadas en Perú. Recuperado de: <https://andina.pe/agencia/noticia-cuidado-los-fraudes-informaticos-estas-son-las-modalidades-mas-denunciadas-peru-928425.aspx>

ArXiv. (2019). Weather Forecasting using Machine Learning Techniques, arXiv:1906.02691. Recuperado de <https://arxiv.org/pdf/1906.02691.pdf>

Banco Central de Reserva del Perú (BCRP). (s.f.). Revista Moneda, 164. Recuperado de: <https://www.bcrp.gob.pe/docs/Publicaciones/Revista-Moneda/moneda-164/moneda-164-03.pdf>

Banco Central de Reserva del Perú. (2023). Nota de Estudios N° 41. Recuperado de <https://www.bcrp.gob.pe/docs/Publicaciones/Notas-Estudios/2023/nota-de-estudios-41-2023.pdf>

Banco Central de Reserva del Perú. (2024). Resumen informativo 2024. Recuperado de <https://www.bcrp.gob.pe/docs/Publicaciones/Nota-Semanal/2024/resumen-informativo-2024-01-04.pdf>

Banco de Crédito BCP. (s.f.). Pregúntale a Clara. Recuperado de <https://www.viabcp.com/canales/preguntale-a-clara>

Banco Mundial. (s.f.). Inclusión financiera. Banco Mundial. Recuperado de <https://www.bancomundial.org/es/topic/financialinclusion/overview#:~:text=La%20inclusi%C3%B3n%20financiera%20se%20refiere,de%20manera%20responsable%20y%20sostenible.>

Banco Mundial. (s.f.). Perú. Recuperado de <https://www.bancomundial.org/es/country/peru/overview>

Banco Nacional de Comercio Exterior. (2018). México, nación *fintech*. Banco Nacional de Comercio Exterior. Recuperado de <https://www.bancomext.com/wp-content/uploads/2018/12/MEXICO-NACION-FINTECH-V5.pdf>

Banco Santander. (s.f.). Empresas unicornio: ¿qué son y por qué están en auge? Banco Santander. Recuperado de <https://www.santander.com/es/stories/empresas-unicornio>

Bentley, M. R., & Higgins, J. J. (1996). Financial characteristics of U.K. manufacturing firms. *International Review of Financial Analysis*, 5(1), 43-58. Recuperado de <https://academic.oup.com/imaman/article-abstract/4/1/43/656001?redirectedFrom=PDF&login=true>

Be My Eyes. (s.f.). Recuperado de <https://www.bemyeyes.com/language/spanish>

Biblioteca CCB. (s.f.). Guía metodológica para la vigilancia tecnológica. Cámara de Comercio de Bogotá. Recuperado de <https://bibliotecadigital.ccb.org.co/handle/11520/22726>

Business Empesarial. (2020). Perú es el país menos bancarizado de Latinoamérica: la tecnología se presenta como una oportunidad de inclusión financiera. Business Empesarial. Recuperado de <https://www.businessempesarial.com.pe/peru-es-el-pais-menos-bancarizado-de-latinoamerica-la-tecnologia-se-presenta-como-una-oportunidad-de-inclusion-financiera/>

Cabrera, K. (2019). Ciberseguridad en las *fintech* y su relación con la regulación en el Perú. *Advocatus*, 25(37), 153-169. Recuperado de <https://revistas.ulima.edu.pe/index.php/Advocatus/article/view/5116/4929>

CaixaBank Research. (s.f.). Inclusión financiera en India y retos para la banca. Recuperado de: <https://www.caixabankresearch.com/es/economia-y-mercados/mercados-financieros/inclusion-financiera-india-y-retos-banca>

Cámara de Comercio de Lima. (s.f.). Informe especial: Evolución de la banca móvil y pagos digitales en el Perú. Cámara de Comercio de Lima. Recuperado de https://apps.camaralima.org.pe/repositorioaps/0/0/par/r914_2/informe%20especial.pdf

Camargo, R. (2008). Vigilancia tecnológica para la gestión de la innovación en la pequeña y mediana empresa: una propuesta de modelo. *Revista Iberoamericana de Ciencia, Tecnología y Sociedad*, 4(10). Recuperado de <https://www.redalyc.org/journal/147/14746959006/html/>

Campos, V. (2019). Análisis del impacto de Big Data en la experiencia del cliente en el sector financiero peruano. *Investigación en Datos y Aplicaciones*, 24(2), 99-107. Recuperado de <http://www.scielo.org.pe/pdf/idata/v24n2/1810-9993-idata-24-02-99.pdf>

CEDIA. (s.f.). Informe de Vigilancia Tecnológica de Fintech en América Latina y el Caribe. CEDIA. Recuperado de <https://cedia.edu.ec/dmdocuments/INNOVACION/CONNECT/N3/4.%20Informe%20VT%20FINTECH.pdf>

Centro Latinoamericano y del Caribe de Información en Ciencias de la Salud. (s.f.). Conceptos, enfoques y aplicaciones de la vigilancia tecnológica e inteligencia competitiva en salud. BIREME/OPAS/OMS. Recuperado de <https://pesquisa.bvsalud.org/portal/resource/pt/lil-259043>

Centro Tecnológico Plástico. (s.f.). Guía Nacional de Vigilancia e Inteligencia Estratégica para la Industria del Plástico. Centro Tecnológico Plástico. Recuperado de <https://ctplas.com.uy/wp-content/uploads/2018/10/guia-nacional-de-vigilancia-e-inteligencia-estrategica.pdf>

Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica. (s.f.). Metodología para la elaboración de estudios de prospectiva e inteligencia estratégica. CONCYTEC. Recuperado de https://portal.concytec.gob.pe/images/publicaciones/libro_prospectiva.pdf

Del Barrio Silva, V. (s.f.). Inteligencia Artificial con aplicaciones a la ingeniería [Trabajo de fin de grado]. Universidad Politécnica de Madrid. Recuperado de https://oa.upm.es/67977/1/TFG_VICTORIA_DEL_BARRIO_SILVA.pdf

Díaz, M., Méndez, E., & Delgado, Y. (2011). La vigilancia tecnológica como herramienta para el desarrollo local. Ingeniería Industrial, 32(2), 156-164. Recuperado de <http://132.248.242.188/ib/index.php/ib/article/view/3943>

El Comercio. (2023). Conectividad digital: ¿Cómo está la brecha en las regiones y qué falta para atender la demanda futura? Recuperado de <https://elcomercio.pe/economia/dia-1/conectividad-digital-como-esta-la-brecha-en-las-regiones-y-que-falta-para-atender-la-demanda-futura-brechas-regiones-conectividad-digital-internet-wifi-red-movil-operadores-noticia/>

El Comercio. (2022). El 28% de empresas en el Perú ha implementado la inteligencia artificial, según informe de IBM. Recuperado de <https://elcomercio.pe/tecnologia/actualidad/ia-el-28-de-empresas-en-el-peru-ha-implementado-la-inteligencia-artificial-segun-informe-de-ibm-espana-mexico-colombia-noticia/>

El Comercio. (2020). El banco de capitales mexicanos había sido golpeado por la crisis. Recuperado de: <https://elcomercio.pe/economia/el-banco-de-capitales-mexicanos-habia-sido-golpeado-por-la-crisis-noticia/>

El Peruano. (2022). Fintech llegan a movilizar más de US\$ 15,000 millones. Recuperado de <https://elperuano.pe/noticia/119110-fintech-llegan-a-movilizar-mas-de-us-15000-millones>

El Peruano. (2022). Fintech llegan a movilizar más de US\$ 15,000 millones. Recuperado de <https://elperuano.pe/noticia/119110-fintech-llegan-a-movilizar-mas-de-us-15000-millones>

El Peruano. (2023). La investigación y el desarrollo del país. Recuperado de <https://www.elperuano.pe/noticia/207832-la-investigacion-y-el-desarrollo-del-pais#:~:text=15%2F03%2F2023%20De%20acuerdo,a%20223%2C300%20millones%20de%20d%C3%B3lares.>

ESAN. (2021). ¿Cómo funciona el Credit Scoring en el 2021? Recuperado de: <https://www.esan.edu.pe/conexion-esan/como-funciona-el-credit-scoring-en-el-2021>

EY Perú. (2022). Guía Fintech. Recuperado de https://www.ey.com/es_pe/law/guia-fintech

EY Perú. (2023). Guía Fintech. Recuperado de https://www.ey.com/es_pe/law/guia-fintech

Fernández, A. (2020). Ventajas de la clasificación de datos en IA y ML. SealPath. Recuperado de <https://www.sealpath.com/es/blog/ventajas-clasificacion-datos-ia-ml/>

Fernandez, Perez, del Valle. (2009). Metodología para la implantación de sistemas de vigilancia tecnológica y documental: El caso del proyecto INREDIS. Investigación Bibliotecológica, 28(62), 139-160. Recuperado de <http://132.248.242.188/ib/index.php/ib/article/view/21393>

Finnovista. (2021). Radar Finnovista General 2021. Recuperado de <https://www.finnovista.com/wp-content/uploads/2021/12/Radar-Finovista-General-2021-4.pdf>

Finnovista. (2023). Finnovista Fintech Radar MX 2023. Finnovista. Recuperado de https://www.finnovista.com/wp-content/uploads/2023/01/Finnovista_Fintech_Radar_MX_2023_ESP.pdf

Foro Consultivo Científico y Tecnológico. (2017). El futuro de la inteligencia artificial en México. Foro Consultivo Científico y Tecnológico. Recuperado de https://www.foroconsultivo.org.mx/INCyTU/documentos/Completa/INCYTU_17-006.pdf

France 24. (2023). ¿Cuál es el origen de la crisis política que sacude a Perú? Recuperado de <https://www.france24.com/es/programas/historia/20230119-cu%C3%A1l-es-el-origen-de-la-crisis-pol%C3%ADtica-que-sacude-a-per%C3%BA>

Gana Más. (2023). MEF: Las Fintech impulsan la inclusión y la bancarización financiera. Recuperado de <https://revistaganamas.com.pe/mef-las-fintech-impulsan-la-inclusion-y-la-bancarizacion-financiera/>

García, L. (2022). Perú se encuentra entre los mejores mercados de la región en uso de inteligencia artificial. Perú21. Recuperado de <https://peru21.pe/economia/peru-se-encuentra-entre-los-mejores-mercados-de-la-region-en-uso-de-inteligencia-artificial-inteligencia-artificial-industria-peru-tecnologia-negocios-herramientas-noticia/>

García, L. M. (2012). Clasificación de datos en IA y ML. *Revista Colombiana de Computación*, 16(1), 45-57. Recuperado de http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S1692-33242012000100012

García, L. M. (2020). Enhanced credit card fraud detection based on attention mechanism and LSTM deep model. *ResearchGate*. Recuperado de https://www.researchgate.net/publication/356779990_Enhanced_credit_card_fraud_detection_based_on_attention_mechanism_and_LSTM_deep_model

Gestión. (2024). Casas de cambio de criptos en Perú aumentan: el panorama de las empresas para este 2024. Recuperado de <https://gestion.pe/economia/mercados/casas-de-cambio-de-criptos-en-peru-aumentan-el-panorama-de-las-empresas-para-este-2024-bitcoin-stablecoins-inversionistas-tecnologia-fintech-noticia/>

Gestión. (2023). El 41% de entidades del sistema financiero utiliza IA para gestionar el riesgo crediticio. Recuperado de <https://gestion.pe/tecnologia/el-41-de-entidades-del-sistema-financiero-utiliza-ia-para-gestionar-el-riesgo-crediticio-noticia/>

Gestión. (2021). ¿Qué es el score crediticio y cómo funciona en las centrales de riesgo SBS? Recuperado de: <https://gestion.pe/tu-dinero/que-es-el-score-crediticio-y-como-funciona-centrales-de-riesgo-sbs-entidades-financieras-finanzas-personales-nnda-nnlt-noticia/>

Gestión. (2021). Las cuatro modalidades de fraudes en tarjetas de crédito con mayor incidencia vía online en Perú. Recuperado de: <https://gestion.pe/tu-dinero/las-cuatro-modalidades-de-fraudes-en-tarjetas-de-credito-con-mayor-incidencia-via-online-en-peru-noticia/>

Gestion.pe. (2021). Perspectivas en el ecosistema digital financiero para el 2022. Recuperado de <https://gestion.pe/blog/mas-alla-del-efectivo/2021/12/perspectivas-en-el-ecosistema-digital-financiero-para-el-2022.html/>

Gobierno del Perú. (2020). MIDIS sigue impulsando el uso de la billetera digital para evitar riesgo de contagio de COVID-19. Recuperado de <https://www.gob.pe/institucion/midis/noticias/312561-midis-sigue-impulsando-el-uso-de-la-billetera-digital-para-evitar-riesgo-de-contagio-de-covid-19>

Gómez, J. (2023). Algoritmo k-means: qué es y cómo funciona. *IEBSchool*. Recuperado de <https://www.iebschool.com/blog/algoritmo-k-means-que-es-y-como-funciona-big-data/>

Gómez-Díaz, R., & Martínez-Martínez, A. (2007). El modelo FIDIS de vigilancia tecnológica. *Anales de Documentación*, 10, 281-290. Recuperado de http://eprints.rclis.org/9400/1/vol15_6.1.pdf

Gómez-González, J., & Ojeda-Joya, J. (2021). Heterogeneous effects of financial inclusion on the monetary policy transmission mechanism. *Banco de España*. Recuperado de <https://ideas.repec.org/p/bde/opaper/2214.html>

Gonzales, S. (2015). Metodología para la implementación de un sistema de vigilancia tecnológica en el sector construcción en Perú. Universidad Peruana de Ciencias Aplicadas. Recuperado de https://repositorioacademico.upc.edu.pe/bitstream/handle/10757/622413/Gonzales_S.pdf?sequence=2

Gutiérrez, P. (2023). Modelos LLM: un vistazo a las máquinas de lenguaje. Recuperado de <https://www.linkedin.com/pulse/modelos-llm-un-vistazo-las-m%C3%A1quinas-de-lenguaje-del-pompas-guti%C3%A9rrez/?originalSubdomain=es>

Hamdoun y Rguibi. (2019.). Impact of AI and Machine Learning on Financial Industry: Application on Moroccan Credit Risk Scoring. Recuperado de https://www.researchgate.net/publication/338251885_Impact_of_AI_and_Machine_Learning_on_Financial_Industry_Application_on_Moroccan_Credit_Risk_Scoring/link/5ecfddb792851c9c5e65b84f/download

HubSpot. (2022). Qué es inteligencia competitiva y cómo utilizarla en tu estrategia de marketing. HubSpot. Recuperado de <https://blog.hubspot.es/marketing/que-es-inteligencia-competitiva#:~:text=La%20inteligencia%20competitiva%20es%20la,y%20los%20desaf%C3%ADos%20que%20existen>.

Ibañez, L., & Huaman, C. (2016). Acceso a servicios financieros formales y satisfacción con la vida en el Perú. Revista Quipu, 30(63), 69-83. Recuperado de <http://www.scielo.org.pe/pdf/quipu/v30n63/1609-8196-quipu-30-63-69.pdf>

IBM. (s.f.). ¿Qué es el Deep Learning? Recuperado de <https://www.ibm.com/es-es/topics/deep-learning#:~:text=el%20siguiente%20paso-,%C2%BFQu%C3%A9%20es%20Deep%20Learning%3F,de%20grandes%20cantidades%20de%20datos>.

IBM. (s.f.). Aprendizaje automático con regresión lineal. Recuperado de <https://www.ibm.com/mx-es/analytics/learn/linear-regression>

IBM. (2021). Gráficos t-SNE. Recuperado de <https://www.ibm.com/docs/es/spss-modeler/saas?topic=ss3ra7-sub-modeler-mainhelp-client-ddita-spss-base-chart-creation-tsne-html>

IBM. (s.f.). Redes neuronales convolucionales (CNN). Recuperado de <https://www.ibm.com/es-es/topics/convolutional-neural-networks>

IBM. (s.f.). Redes neuronales recurrentes (RNN). Recuperado de [https://www.ibm.com/mx-es/topics/recurrent-neural-networks#:~:text=Una%20red%20neuronal%20recurrente%20\(RNN,voz%20y%20sub%C3%ADtulos%20de%20im%C3%A1genes](https://www.ibm.com/mx-es/topics/recurrent-neural-networks#:~:text=Una%20red%20neuronal%20recurrente%20(RNN,voz%20y%20sub%C3%ADtulos%20de%20im%C3%A1genes).

IBM. (s.f.). Redes neuronales: perceptrón multicapa (Multilayer Perceptron). IBM SPSS Statistics Documentation. Recuperado de <https://www.ibm.com/docs/es/spss-statistics/saas?topic=networks-multilayer-perceptron>

IBM. (s.f.). Regresión logística. IBM SPSS Statistics Documentation. Recuperado de <https://www.ibm.com/docs/es/spss-statistics/saas?topic=regression-logistic>

Infobae. (2023). Dina Boluarte registra 9% de aprobación a pocos días de cumplir un año de gobierno. Recuperado de <https://www.infobae.com/peru/2023/11/21/dina-boluarte-registra-9-de-aprobacion-a-pocos-dias-de-cumplir-un-ano-de-gobierno/>

Infobae Perú. (2023). BCP implementará inteligencia artificial en su asistente virtual de voz en el primer trimestre del 2024. Recuperado de <https://www.infobae.com/peru/2023/11/27/bcp-implementara-inteligencia-artificial-en-su-asistente-virtual-de-voz-en-el-primer-trimestre-del-2024/>

Infobae Perú. (2023). Estafas digitales dejan millonarias pérdidas en 2023: 6 mil casos en el país y criminales ya usan la IA para engaños. Recuperado de <https://www.infobae.com/peru/2023/12/19/estafas-digitales-dejan-millonarias-perdidas-en-2023-6-mil-casos-en-el-pais-y-criminales-ya-usan-la-ia-para-enganos/#:~:text=Se%20estiman%206.000%20denuncias%20por%20estafas%20digitales%20en%20el%20Per%C3%BA&text=Las%20mismas%20han%20resultado%20en,millones%200977%20mil%20635%20d%C3%B3lares.>

Instituto de Ciencias de la Universidad Autónoma del Estado de Hidalgo. (2022). Vigilancia tecnológica e inteligencia competitiva. Universidad Autónoma del Estado de Hidalgo. Recuperado de <http://dgsa.uaeh.edu.mx:8080/bibliotecadigital/handle/231104/2840>

Instituto Nacional de Estadística e Informática. (2021). El 51.9% de la población de 18 y más años de edad del país tienen una cuenta en el sistema financiero. INEI. Recuperado de <https://m.inei.gob.pe/prensa/noticias/el-519-de-la-poblacion-de-18-y-mas-anos-de-edad-del-pais-tienen-una-cuenta-en-el-sistema-financiero-13110/>

International Information and Engineering Technology Association. (2020). Application of Artificial Intelligence in the Financial Industry. Recuperado de <https://www.iieta.org/download/file/fid/25676>

International Journal of Advances in Technology, Innovation, and Research. (2018). Novel Method for Predicting Weather Patterns Using Machine Learning Techniques, 10(6). Recuperado de <http://www.jatit.org/volumes/Vol100No6/4Vol100No6.pdf>

International Journal of Computer Science and Engineering. (2022). Weather Forecasting Using Machine Learning Techniques: A Review, 14(1). Recuperado de <https://dl.acm.org/doi/abs/10.1504/ijcse.2022.122212>

International Journal of Intelligent Systems and Applications in Engineering. (2021). A Comparative Study of Machine Learning Techniques for Weather Forecasting, 10(3). Recuperado de <https://ijisae.org/index.php/IJISAE/article/view/2750/1330>

Invest in Peru. (2021). Perú ocupa sexto lugar en Sudamérica como el más atractivo para inversión extranjera directa. Recuperado de <https://www.investinperu.pe/es/invertir/detalle-noticia/peru-ocupa-sexto-lugar-en-sudamerica-como-el-mas->

Johnson, A. B. (2021). Developing a Credit Card Fraud Detection Model using Machine Learning Approaches. ResearchGate. Recuperado de https://www.researchgate.net/publication/359635597_Developing_a_Credit_Card_Fraud_Detection_Model_using_Machine_Learning_Approaches

Klimb. (s.f.). Recuperado de <https://klimb.pe>

Kolungade. (2020). Sentiment Analysis. Recuperado de <https://bit.ly/sentiment-analysis-kolungade>

La Cámara de Comercio de Lima. (2022). Transacciones de Fintechs peruanas sumarían US\$ 20,000 millones. Recuperado de <https://lacamara.pe/transacciones-de-fintechs-peruanas-sumarian-us-20-000-millones/>

La República. (2023). Cusco: Juzgado decidirá si obra de aeropuerto Chinchero sigue. Recuperado de <https://larepublica.pe/sociedad/2023/12/01/cusco-juzgado-decidira-si-obra-de-aeropuerto-chinchero-sigue-lrsd-29866>

La República. (2023). El ecosistema Fintech Perú crece desde 2014 aunque se ralentizó en el último año. Recuperado de <https://www.larepublica.co/especiales/anuario-ripe-2023/el-ecosistema-fintech-peru-crece-desde-2014-aunque-se-ralentizo-en-el-ultimo-ano-3514427>

La República. (2024). Fintech generarán más de un billón de dólares este 2024. Recuperado de <https://larepublica.pe/economia/2024/02/11/fintech-generaran-mas-de-un-billon-de-dolares-este-2024-727342>

Lau, W. W. F., & Yuen, M. T. (2020). Examining teacher-student relationships, students' self-perception, and student engagement: Evidence from Hong Kong secondary schools. International Journal of Special Education, 35(2), 210-228. Recuperado de <https://internationaljournalofspecialeducation.com/submission/index.php/ijse/article/view/883/665>

Martínez, P. (2018). Entendiendo la curva ROC y el AUC: dos medidas del rendimiento de un clasificador binario que van de la mano. Polmar Tisanahuja. Recuperado de <https://polmartisanahuja.com/entendiendo-la-curva-roc-y-el-auc-dos-medidas-del-rendimiento-de-un-clasificador-binario-que-van-de-la-mano/>

Martínez-Ávila, D., & Méndez-Rodríguez, E. (2004). Una metodología para la vigilancia tecnológica e inteligencia competitiva en organizaciones industriales. ACIMED, 12(4). Recuperado de <http://eprints.rclis.org/5000/1/aci040402.pdf>

Más Finanzas. (2023). BCRP: Las Fintech de divisas tienen tipos de cambio más favorables que la banca. Recuperado de <https://masfinanzas.com.pe/fintech/bcrp-las-fintech-de-divisas-tienen-tipos-de-cambio-mas-favorables-que-la-banca/>

Microsoft. (2023). Confussion Matrix. Recuperado de <https://learn.microsoft.com/es-es/dynamics365/finance/finance-insights/confusion-matrix>

OCTI - Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica. (2023). Boletín. Recuperado de <http://octi.concytec.gob.pe/index.php/boletin>

Olmedo-Granados, G. (2004). Vigilancia tecnológica en empresas tecnológicas: Caso de estudio en una empresa de telecomunicaciones. ACIMED, 12(2). Recuperado de <http://eprints.rclis.org/5174/1/sci17100.pdf>

OMPI (2018). REAL-TIME FRAUD DETECTION METHOD AND APPARATUS FOR INTERNET CREDIT LOAN SCENE. Recuperado de: https://patentscope.wipo.int/search/es/detail.jsf?docId=CN231362172&_cid=P12-LK0174-23055-2

OMPI (2019). P2P NETWORK LOAN CUSTOMER CREDIT SCORING METHOD AND SYSTEM BASED ON MACHINE LEARNING. Recuperado de https://patentscope.wipo.int/search/es/detail.jsf?docId=CN254004354&_cid=P12-LK0174-23055-2

OpenAI. (s.f.). Recuperado de <https://openai.com/customer-stories/be-my-eyes>

OpenAI. (s.f.). Recuperado de <https://openai.com/customer-stories/stripe>

OpenAI. (s.f.). Recuperado de <https://openai.com/gpt-4>

OVTI. (s.f.). Perú presenta el Programa Especial de Prospectiva y Vigilancia Tecnológica para el país. Recuperado de <https://www.ovtt.org/peru-presenta-el-programa-especial-de-prospectiva-y-vigilancia-tecnologica-para-el-pais/>

Palomino, Velásquez, Marcos, Seclen (2019). ¿Cómo innovan las *fintech* peruanas? Una aproximación a partir de un estudio de casos múltiple. 360: Revista de Ciencias de la Gestión, ISSN 2415-5861, ISSN-e 2518-0495, N°. 4, 2019, págs. 38-66. Recuperado de <https://dialnet.unirioja.es/servlet/articulo?codigo=7185837>

Peña-Méndez, E. (2014). La vigilancia tecnológica en el fortalecimiento de la innovación empresarial. *Revista Investigación en Economía*, 68(12), 147-162. Recuperado de <https://revistascientificas.cuc.edu.co/economicascuc/article/view/3246/3745>

Pérez, L. (2018). Redes Neuronales Generativas Adversariales (GANs). *iArtificial*. Recuperado de <https://www.iartificial.net/redes-neuronales-generativas-adversarias-gans/>

Pérez, R. (2022). Cómo manejar el desbalance de datos. *Data Science PE*. Recuperado de <https://datasciencepe.substack.com/p/como-manejar-el-desbalance-de-datos>

Pérez-Montoro, M. (2005). Introducción a las fuentes de información. Recuperado de <https://riunet.upv.es/bitstream/handle/10251/7580/introduccion%20a%20las%20fuentes%20e%20informaci%c3%83%c2%b3n.pdf?sequence=1&isAllowed=y>

Pérez-Montoro, M. (2019). Vigilancia tecnológica e inteligencia competitiva. *Universitat de Barcelona*. Recuperado de <https://www.tdx.cat/handle/10803/365577#page=1>

Perú21. (2023). PBI CTI: Inversión: El Perú destina un 0.13% de su PBI a Ciencia, Tecnología e Innovación. Recuperado de <https://peru21.pe/economia/pbi-cti-inversion-el-peru-destina-un-013-de-su-pbi-a-ciencia-tecnologia-e-innovacion-como-impulsar-su-desarrollo-noticia/>

Ponce Cruz, P. (2011). *Inteligencia artificial con aplicaciones a la ingeniería*.

Pymes Latam. (2022). Alfin Banco se reinventó y se transformó en el primer banco que funciona completamente en la nube en Perú. Recuperado de: <https://pymes-latam.azurewebsites.net/es-xl/pymes/alfin-banco-se-reinvento-y-se-transformo-en-el-primer-banco-que-funciona-completamente-en-la-nube-en-peru/>

RAIA. (2019). Nuevas herramientas para la toma de decisiones: Vigilancia Tecnológica e Inteligencia Estratégica. Recuperado de <https://raia.revistasuai.ar/index.php/raia/article/view/32/63>

Ramírez, R. (2019). *Inteligencia artificial*. Plaza y Valdés. Recuperado de https://static0planetadelibroscom.cdnstatics.com/libros_contenido_extra/40/39308_Inteligencia_artificial.pdf

Redalyc.org. (2012). El concepto de vigilancia tecnológica: Definición, antecedentes y retos actuales. *Redalyc*. Recuperado de <https://www.redalyc.org/pdf/4778/477847114019.pdf>

Repositorio Alteca Asociación. (2021). Panorama Fintech LATAM 2022-2023. Recuperado de <https://repositorio.altecasociacion.org/bitstream/handle/20.500.13048/1900/paper%20159.pdf?sequence=1&isAllowed=y>

Repositorio de la Universidad del Pacífico. (2017). Impacto de la innovación en la productividad y el crecimiento económico en Perú. Recuperado de https://repositorio.up.edu.pe/bitstream/handle/11354/2055/Kelvin_Tesis_maestria_2017.pdf?sequence=1

ResearchGate. (2009). Algoritmos Genéticos: Una visión práctica. Recuperado de https://www.researchgate.net/publication/38292778_Algoritmos_Geneticos_Una_vision_practica

Revista Economía. (2023). Robots de software ya se usan en el Perú: reemplazarán el capital humano. Recuperado de <https://www.revistaeconomia.com/robots-de-software-ya-se-usan-en-el-peru-reemplazaran-el-capital-humano/>

Rodríguez, C. (2019). DGHNL: A New Deep Genetic Hierarchical Network of Learners for Prediction of Credit Scoring. ResearchGate. Recuperado de https://www.researchgate.net/publication/338112972_DGHNL_A_New_Deep_Genetic_Hierarchical_Network_of_Learners_for_Prediction_of_Credit_Scoring

Rueda, R., Aguirre, D., & Castañeda, L. (2007). Vigilancia tecnológica e inteligencia competitiva en la gestión del conocimiento. Revista EAN, 61, 97-115. Recuperado de <https://repositorio.unicartagena.edu.co/bitstream/handle/11227/245/modulo%20%20CTS%20No4-cienciometria.pdf?sequence=1>

Rustemli, A. (2006). A comparative study of personal values of teachers, students and parents. International Journal of Science and Technology, 2(2), 30-35. Recuperado de <https://docsdrive.com/pdfs/medwelljournals/ijscmp/2006/30-35.pdf>

San Diego Union-Tribune. (2023). El FMI pide a Perú que restaure confianza y estabilidad. Recuperado de <https://www.sandiegouniontribune.com/en-espanol/noticias/story/2023-02-09/el-fmi-pide-a-peru-que-restaure-confianza-y-estabilidad>

Sánchez, C. (2019). Máquina de Soporte Vectorial (SVM). Medium. Recuperado de <https://medium.com/@csarchiquerodriguez/maquina-de-soporte-vectorial-svm-92e9f1b1b1ac>

Sánchez-Medina, M., & Fernández-Güell, J. (2013). La vigilancia tecnológica y su relación con la innovación. Revista Oikonomics, 10, 23-45. Recuperado de https://oikonomics.uoc.edu/divulgacio/oikonomics/_recursos/documents/10/Oikonomics_10_cast_complet_Opencms_a4.pdf#page=22

ScalaHED. (2010). Vigilancia Tecnológica: Conceptos y definiciones básicas. ScalaHED. Recuperado de <https://gc.scalahed.com/recursos/files/r161r/w24792w/ATI/Vigilanciatecnologica.pdf>

ScienceDirect. Flexible loss functions for binary classification in gradient-boosted decision trees: An application to credit scoring (2024). Recuperado de https://www.sciencedirect.com/science/article/pii/S0957417423023783?ref=cra_js_challenge&fr=RR-1

Smith, J. (2008). Examining the effects of social media on adolescent mental health. *Journal of Adolescent Health*, 42(1), S17-S18. Recuperado de https://media.proquest.com/media/hms/PFT/1/BO9oR?_s=L14gXaWE%2F2WApWioc3jAB9heiSw%3D

Smith, J. D. (2021). Credit Card Fraud Detection with Automated Machine Learning Systems. ResearchGate. Recuperado de https://www.researchgate.net/publication/361263822_Credit_Card_Fraud_Detection_with_Automated_Machine_Learning_Systems

Smith, J. D. (2022). Predicting Credit Scores with Boosted Decision Trees. ResearchGate. Recuperado de https://www.researchgate.net/publication/365590539_Predicting_Credit_Scores_with_Boosted_Decision_Trees

Socure. (s.f.). First Payment Default. Recuperado de <https://www.socure.com/glossary/first-payment-default>

Stakeholders. (2022). Préstamos para emprendedores crecieron durante la pandemia. Recuperado de <https://stakeholders.com.pe/ciencia-innovacion-y-tecnologia/innovacion-y-emprendimientos/prestamos-para-emprendedores-crecieron-durante-la-pandemia/>

Startupeable. (2020). Fintech Perú. Recuperado de <https://startupeable.com/fintech-peru/#:~:text=El%20n%C3%BAmero%20de%20fintech%20startups,2020%20frente%20al%20a%C3%B1o%20anterior.>

Stripe. (s.f.). Recuperado de <https://stripe.com/docs>

Superintendencia de Banca, Seguros y AFP (SBS). (s.f.). Modelo de Credit Scoring en instituciones microfinancieras. Recuperado de: https://www.sbs.gob.pe/Portals/0/jer/pres_doc_basilea/I_MODELO_DE_CREDIT_SCORING_EN_IMFs.pdf

Superintendencia de Banca, Seguros y AFP. (2022). Ecosistema Fintech. Recuperado de <https://www.sbs.gob.pe/Portals/0/Archivos/2022/Ecosistema%20Fintech-2022.06.02.pdf>

Superintendencia Nacional de Aduanas y de Administración Tributaria (2021). Alerta de comercio exterior. Recuperado de <https://www.siicex.gob.pe/siicex/documentosportal/alertas/documento/doc/79431536radE2E60.pdf>

Tavera, J. (2013). Dinámica de la inflación en el Perú: ¿Es la tasa de inflación un pésimo predictor de la tasa de crecimiento económico? *Revista del Instituto de Investigaciones de Ciencias Económicas*, 10(20), 21-42. Recuperado de <https://www.redalyc.org/pdf/1814/181452083002.pdf>

Universidad de Lima. (2020). Las cuatro modalidades de fraudes en tarjetas de crédito con mayor incidencia vía online en Perú. Recuperado de: <https://repositorio.ulima.edu.pe/bitstream/handle/20.500.12724/15294/Trabajo.pdf?sequence=1&isAllowed=y>

Universidad de Piura. (2023). Las Fintechs cubren nichos a los que la banca tradicional no llega. Recuperado de <https://www.udep.edu.pe/hoy/2023/06/las-fintechs-cubren-nichos-a-los-que-la-banca-tradicional-no-llega/>

Universidad Internacional de La Rioja. (2022). Fintech: la revolución de los servicios financieros. *México Unir*. Recuperado de <https://mexico.unir.net/economia/noticias/fintech/>

Universidad Politécnica de Madrid. (2022). Inteligencia Competitiva y Vigilancia Tecnológica en la empresa. Universidad Politécnica de Madrid. Recuperado de <https://oa.upm.es/70014/>

Vodanovic & Asociados. (2022). PANORAMA Fintech LATAM 2022-2023. Recuperado de <https://vodanovic.pe/wp-content/uploads/2022/11/PANORAMA-FINTECH-LATAM-2022-2023.pdf>

Wireless Communications and Mobile Computing. (2021). A Machine Learning Approach for Weather Prediction, 2021, Article ID 6079582. Recuperado de <https://downloads.hindawi.com/journals/wcmc/2021/6079582.pdf>

Xataka. (2023). GPT-4: ¿Qué es, cómo funciona, cómo usarlo, qué puedes hacer con este modelo de lenguaje? Recuperado de <https://www.xataka.com/basics/gpt-4-que-como-funciona-como-usarlo-que-puedes-hacer-este-modelo-lenguaje-inteligencia-artificial>

Xataka. (2023). GPT-4 da un salto de nivel brutal respecto a ChatGPT: nueve ejemplos para comprobarlo en persona. Recuperado de <https://www.xataka.com/robotica-e-ia/gpt-4-salto-nivel-brutal-respecto-a-chatgpt-nueve-ejemplos-para-comprobarlo-persona>