



UNIVERSIDAD ANDINA

NÉSTOR CÁCERES VELÁSQUEZ

FACULTAD DE INGENIERÍA DE SISTEMAS

ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS



**REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN
DE INSOLVENCIA EN LA COOPERATIVA DE
CRÉDITO SANTA RAFAELA 2023**

TESIS PRESENTADA POR:

Bach. AUGUSTO FERNANDO GUTIERREZ HERRERA

**PARA OPTAR EL TÍTULO PROFESIONAL DE:
INGENIERO DE SISTEMAS**

JULIACA - PERÚ

2025



UNIVERSIDAD ANDINA

NÉSTOR CÁCERES VELÁSQUEZ

FACULTAD DE INGENIERÍA DE SISTEMAS

ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

**REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN
DE INSOLVENCIA EN LA COOPERATIVA DE
CRÉDITO SANTA RAFAELA 2023**

TESIS PRESENTADA POR:

Bach. AUGUSTO FERNANDO GUTIERREZ HERRERA

PARA OPTAR EL TÍTULO PROFESIONAL DE:

INGENIERO DE SISTEMAS

APROBADA POR EL JURADO REVISOR:


PRESIDENTE

:


Dr. PAUL MAMANI TISNADO

PRIMER MIEMBRO

:


Dr. JUAN CARLOS HERRERA MIRANDA


SEGUNDO MIEMBRO

:


Dr. RICHARD CONDORI CRUZ

ASESOR DE TESIS

:


Dr. JUAN BENITES NORIEGA

LÍNEA DE INVESTIGACIÓN:

CIENCIA DE LOS ORDENADORES – P24



RESOLUCIÓN N° 025-2025-UI.S-D-FIS-UANCV-J

Juliaca, 09 de enero de 2025.

VISTOS:

El Expediente: 2025-000245 (fecha y hora de Sustentación) de fecha 09 de enero de 2025 y el expediente: 2025-000246 (título) de fecha 09 de enero de 2025, del (la) bachiller **AUGUSTO FERNANDO GUTIERREZ HERRERA** quien solicita *nominación de jurados, fecha y hora de sustentación*, para rendir la sustentación y defensa de la tesis titulada **REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023**, conducente a la obtención del Título Profesional de INGENIERO DE SISTEMAS, que fue revisada por el Director de la Unidad de Investigación y el Decano de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS.

CONSIDERANDO:

Que, el Director de la Unidad de Investigación autoriza la ejecución de la propuesta de investigación según Resolución Nro. 340-2023-UI.P-D-FIS-UANCV-J (aprobar y autorizar la ejecución de la propuesta de investigación) y con Resolución. Nro. 366-2024-UI.R-D-FIS-UANCV-J (aprobar y autorizar el informe final de la investigación).

Que, de conformidad con el artículo 8°, numeral b) del Reglamento General de Grados y Títulos de la UANCV vigente, es procedente acceder a la petición del interesado.

Que, al haberse cumplido con los requisitos exigidos por el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos plasmado en la Resolución N° 0294-2023-UANCV-CU-R.

Y, estando a la opinión favorable del Director de la Unidad de Investigación y el Decano de la Facultad de Ingeniería de Sistemas, y las atribuciones que confiere el artículo 28° del Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos Resolución N° 0294-2023-UANCV-CU-R, que confiere facultades al Decano de la Facultad de Ingeniería de Sistemas.

SE RESUELVE:

ARTÍCULO PRIMERO.- DECLARAR APTO para la sustentación del informe Final de la Investigación (borrador de Tesis) titulada **REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023**, del bachiller **AUGUSTO FERNANDO GUTIERREZ HERRERA**, para optar el Título Profesional de INGENIERO DE SISTEMAS, en virtud de los considerandos expuestos.

ARTÍCULO SEGUNDO. - NOMINAR JURADOS para la sustentación y defensa de la tesis a los siguientes docentes:

Presidente : Dr. PAUL MAMANI TISNADO.

Primer miembro : Dr. JUAN CARLOS HERRERA MIRANDA.

Segundo miembro : Dr. RICHARD CONDORI CRUZ.

Asesor: : Dr. JUAN BENITES NORIEGA.

ARTÍCULO TERCERO. - PROGRAMAR FECHA Y HORA de sustentación como se detalla:

Modalidad, Lugar : Presencial, Pabellón de la Facultad de Ingeniería de Sistemas.

Fecha, Hora : 10 de enero de 2025, 16:00 Horas.

ARTÍCULO CUARTO. - DISPONER que la comisión de Grados y Títulos de la facultad, secretarías académicas y administrativas, quedan encargados del cumplimiento de la presente resolución.

Regístrese, comuníquese y archívese.



UNIVERSIDAD ANDINA
NÉSTOR CÁCERES VELÁSQUEZ

Dr. Juan Carlos Herrera Miranda
DECANO



RESOLUCIÓN N° 366-2024-UI-R-D-FIS-UANCV-J

Juliaca, 19 de Diciembre de 2024

VISTOS:

El Expediente: 2024-CU-19047 de fecha 19 de Diciembre de 2024, del Bach. **AUGUSTO FERNANDO GUTIERREZ HERRERA**, quien solicita Revisión del Informe Final de la Investigación (borrador de Tesis) y el Anexo (04 o 05) "Ficha de Opinión del Informe Final de la Investigación (borrador de Tesis)" que fue revisada por el Comité de Investigación de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS.

CONSIDERANDO:

Que, las Unidades de Investigación son unidades académicas que agrupan a docentes y estudiantes de diversas disciplinas, en razón del desarrollo de investigación científica, tecnológica y humanista de acuerdo al Estatuto Universitario Modificado 2020 de nuestra primera Casa Superior de Estudios.

Que, el (la) Bach. AUGUSTO FERNANDO GUTIERREZ HERRERA, quien solicita la revisión del Informe Final de la Investigación (borrador de Tesis) del tema titulada: REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023, conducente para optar el Título profesional de INGENIERO DE SISTEMAS.

Que, al haberse cumplido con los requisitos exigidos por el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos plasmado en la Resolución N° 0294-2023-UANCV-CU-R.

Que, el Comité de Investigación emitió su opinión favorable al Informe Final de la Investigación (borrador de Tesis).

Que, el Director de la Unidad de Investigación de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS, corrobora el asesoramiento en el Informe Final de la Investigación (borrador de Tesis) del ASESOR Dr. JUAN BENITES NORIEGA,

Estando, la opinión favorable del Comité de Investigación, en concordancia con el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos Resolución N° 0294-2023-UANCV-CU-R, de conformidad a lo que establece la Ley Universitaria N° 30220, Ley de Creación de la UANCV N° 23738 y Modificatoria N° 24661 y el Estatuto de la UANCV, que confiere facultades al Decano de la Facultad de Ingeniería de Sistemas.

SE RESUELVE:

ARTICULO PRIMERO. - APROBAR Y AUTORIZAR EL INFORME FINAL DE LA INVESTIGACIÓN (Borrador de Tesis) para la **REVISIÓN DE SIMILITUD TURNITIN**, del tema titulado: **REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023**, presentado por el (la) Bach. **AUGUSTO FERNANDO GUTIERREZ HERRERA**, para optar el Título Profesional de INGENIERO DE SISTEMAS, en virtud de los considerandos expuestos.

ARTICULO SEGUNDO. - RATIFICAR, como ASESOR al Dr. **JUAN BENITES NORIEGA**.

ARTICULO TERCERO. - DISPONER que la facultad, secretarías académicas y administrativas, quedan encargados del cumplimiento de la presente resolución.

Regístrese, comuníquese y archívese.



UNIVERSIDAD ANDINA
"NÉSTOR CÁCERES VELÁSQUEZ"

M.Sc. Juan Carlos Herrera Miranda
DECANO

C.c
Arch 2024
JCHM/ v1.1
Distribución: Asesor de Tesis, Interesado

Ciudad Universitaria Urbanización Taparachi Km 4.5 Salida Puno - Juliaca



RESOLUCIÓN N° 340-2024-UI.P-D-FIS-UANCV-J

Juliaca, 12 de noviembre de 2024

VISTOS:

El Expediente: 2024-013858 de fecha 12 de noviembre de 2024, del (la) Bach. **AUGUSTO FERNANDO GUTIERREZ HERRERA**; con el cual solicita Revisión de la Propuesta de Investigación y el Anexo (02 o 03) "Ficha de Opinión de la Propuesta de Investigación" que fue revisada por el Comité de Investigación de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS.

CONSIDERANDO:

Que, las Unidades de Investigación son unidades académicas que agrupan a docentes y estudiantes de diversas disciplinas, en razón del desarrollo de investigación científica, tecnológica y humanista de acuerdo al Estatuto Universitario Modificado 2020 de nuestra primera Casa Superior de Estudios.

Que, el (la) Bach. AUGUSTO FERNANDO GUTIERREZ HERRERA, solicito la revisión y aprobación de la Propuesta de Investigación de la tesis titulada: REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023; conducente para optar el Título Profesional de INGENIERO DE SISTEMAS.

Que, al haberse cumplido con los requisitos exigidos por el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos plasmado en la Resolución N° 0294-2023-UANCV-CU-R.

Que, el Comité de Investigación ha emitido opinión favorable a la propuesta de investigación.

Que, el Director de la Unidad de Investigación de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS, ratifico la propuesta del Asesor Dr. JUAN BENITES NORIEGA, quien debe estar acreditado y facultado para orientar y ayudar al asesorado en el proceso de elaboración del trabajo de investigación (Tesis).

Estando, la opinión favorable del comité de Investigación, en concordancia con el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos, Resolución N° 0294-2023-UANCV-CU-R, de conformidad a lo que establece la Ley Universitaria N° 30220, Ley de Creación de la UANCV N° 23738 y Modificatoria N° 24661 y el Estatuto de la UANCV, que confiere facultades al Decano de la Facultad de Ingeniería de Sistemas.

SE RESUELVE:

ARTÍCULO PRIMERO. - APROBAR Y AUTORIZAR LA EJECUCIÓN DE LA PROPUESTA DE INVESTIGACIÓN, titulada: **REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023**, presentado por el (la) Bach. **AUGUSTO FERNANDO GUTIERREZ HERRERA**, para optar el Título Profesional de INGENIERO DE SISTEMAS, en virtud de los considerandos expuestos.

ARTÍCULO SEGUNDO. - RECONOCER, como ASESOR al Dr. **JUAN BENITES NORIEGA**.

ARTÍCULO TERCERO. - DISPONER que la facultad, secretarías académicas y administrativas, quedan encargados del cumplimiento de la presente resolución.

Regístrese, comuníquese y archívese.



UNIVERSIDAD ANDINA
"NÉSTOR CÁCERES VELÁSQUEZ"
M.Sc. Juan Carlos Herrera Miranda
DECANO



AUGUSTO FERNANDO GUTIERREZ HERRERA

REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA ...

 TESIS DE PREGRADO

Detalles del documento

Identificador de la entrega

trn:oid:::13016:542899624

Fecha de entrega

23 dic 2025, 9:27 GMT-5

Fecha de descarga

23 dic 2025, 10:44 GMT-5

Nombre del archivo

T036_70443088_T.docx

Tamaño del archivo

9.4 MB

93 páginas

13.278 palabras

78.938 caracteres



TESIS UANCV

14% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Bibliografía
- Coincidencias menores (menos de 10 palabras)

Fuentes principales

- 9%  Fuentes de Internet
- 3%  Publicaciones
- 13%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.



Metadatos complementarios



Título de la Tesis	
REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023	
Datos de autor	
Nombres y apellidos	AUGUSTO FERNANDO GUTIERREZ HERRERA
Tipo de documento de identidad	DNI
Numero de documento de identidad	70443088
URL de ORCID	https://orcid.org/0009-0004-0438-8265
Datos de asesor	
Nombres y apellidos	JUAN BENITES NORIEGA
Tipo de documento de identidad	DNI
Numero de documento de identidad	06195745
URL de ORCID	https://orcid.org/0000-0003-3842-8435
Datos de jurado	
Presidente del jurado	
Nombres y apellidos	PAUL MAMANI TISNADO
Tipo de documento de identidad	DNI
Numero de documento de identidad	01314987
Miembro del jurado 1	
Nombres y apellidos	JUAN CARLOS HERRERA MIRANDA
Tipo de documento de identidad	DNI
Numero de documento de identidad	29606930
Miembro del jurado 2	
Nombres y apellidos	RICHARD CONDORI CRUZ
Tipo de documento de identidad	DNI
Numero de documento de identidad	02442917



Datos de investigación	
Línea de investigación	Ciencia de los ordenadores – P24
Grupo de investigación	No aplica.
Agencia de financiamiento	Sin financiamiento.
Ubicación geográfica de la investigación	País: Perú Departamento: Puno Provincia: Puno Distrito: Puno COOPERATIVA DE CRÉDITO SANTA RAFAELA Coordenadas: Latitud: -16.4244492 Longitud: -71.5323583 URL Maps: https://maps.app.goo.gl/zojQUCPG3feqPT398 
Año o rango de años en que se realizó la investigación	Noviembre 2024 – Enero 2025
URL de disciplinas OCDE https://concytec-pe.github.io/Peru-CRIS/vocabularios/ocde_ford.html	Ingeniería de sistemas y comunicaciones https://purl.org/pe-repo/ocde/ford#2.02.04 Ingeniería de procesos https://purl.org/pe-repo/ocde/ford#2.04.02



[Handwritten signature]

UNIVERSIDAD ANDINA
VICERRECTORADO DE INVESTIGACIÓN
DIRECCIÓN DE SISTEMAS Y COMUNICACIONES
M.Sc. Juan Carlos Herrera Miranda
DIRECTOR (a)
Oficina de Investigación F.S.



DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD

Yo AUGUSTO FERNANDO GUTIERREZ HERRERA, identificado con DNI
Nro. 70443088, en mi condición de egresado de:

- ☒ **Escuela Profesional**
☐ **Programa de Segunda Especialidad,**
☐ **Programa de Maestría o Doctorado**

INGENIERÍA DE SISTEMAS

informo que he elaborado el/la ☒ Tesis o ☐ Trabajo de Investigación, ☐ Trabajo Académico
denominada:

REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE
INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023

Asesorado por: Dr. JUAN BENITES NORIEGA

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

El incumplimiento de lo declarado da lugar a responsabilidad del declarante, en consecuencia; a través del presente documento asumo frente a terceros, la Universidad Andina Néstor Cáceres Velásquez y/o la Administración Pública toda responsabilidad que pueda derivarse por el trabajo final presentado. Lo señalado incluye responsabilidad pecuniaria incluido el pago de multas u otros por los daños y perjuicios que se ocasionen.

Juliaca 30 de OCTUBRE del 2025


Firma del Asesor
(obligatoria)


Firma del Estudiante
(obligatoria)



Huella



DEDICATORIA

A mis padres.



AGRADECIMIENTO

A la empresa.



ÍNDICE

DEDICATORIA.....	i
AGRADECIMIENTO.....	ii
ÍNDICE	iii
ÍNDICE DE TABLAS	vii
ÍNDICE DE FIGURAS	viii
RESUMEN	ix
ABSTRACT	x
INTRODUCCIÓN	xi

CAPÍTULO I

ASPECTOS GENERALES

1.1. Descripción del problema	1
1.1.1 A nivel Internacional.....	1
1.1.2 A nivel nacional.....	2
1.1.3 A nivel local.....	2
1.2. Formulación del problema	3
1.2.1 Problema Principal.....	3
1.2.2 Problemas específicos.....	3
1.3. Justificación de la investigación	3
1.3.1 Justificación teórica.....	3
1.3.2 Justificación Practico	4
1.3.3 Justificación Metodológica	4



1.4. Objetivos.....	5
1.4.1 Objetivo general.....	5
1.4.2 Objetivos específicos	5
1.5. Importancia	5
1.6. Limitaciones	6

CAPÍTULO II

FUNDAMENTOS TEÓRICOS

2.1. Antecedentes	8
2.1.1 Internacionales.....	8
2.1.2 Nacionales	10
2.1.3 Locales.....	11
2.2. Marco epistemológico	13
2.3. Estado del arte	13
2.4. Bases teóricas	15
2.4.1 Redes Neuronales Artificiales (RNA)	15
2.4.2 Predicción de Insolvencia Financiera.....	16
2.4.3 Inteligencia Artificial y Aprendizaje Supervisado.....	16
2.4.4 Inteligencia Artificial Aplicada a las Finanzas.....	17
2.4.5 Teoría de Sistemas y Toma de Decisiones.....	17
2.4.6 Bases Matemáticas.....	18
2.4.7 Métodos de Validación de Modelos.	18



2.4.8 Modelos.	18
2.4.9 Modelos Basados en Machine Learning.	19
2.4.10 Modelos Basados en Redes Neuronales.	20
2.4.11 Métricas de Comparación.	20
2.4.12 Métricas de Clasificación.	21
2.5. Marco conceptual.....	24
2.6. Hipótesis	26
2.6.1 Hipótesis general	26
2.6.2 Hipótesis específicas	26

CAPÍTULO III

METODOLOGÍA Y RESULTADOS

3.1. Métodos de investigación	27
3.1.1 Tipo de investigación	28
3.1.2 Nivel.....	28
3.1.3 Diseño.....	28
3.2. Modalidad de estudio de casos.....	29
3.2.1 Población	29
3.2.2 Muestra.....	29
3.3. Métodos y técnicas de recogida de información	29
3.3.1 Criterios de Inclusión	30
3.3.2 Criterios de Exclusión	31



CAPÍTULO IV

RESULTADOS

4.1. Análisis de datos.....	32
4.2. Diseminación de los hallazgos.....	47
CONCLUSIONES.....	50
RECOMENDACIONES	51
REFERENCIAS BIBLIOGRÁFICAS	52
APÉNDICES.....	55
Apéndice 1 Matriz de consistencia.....	576
Apéndice 2 Instrumentos.....	57
Apéndice 3 Validez de instrumentos	61
Apéndice 4 Tratamiento de datos.....	66
Apéndice 5 Otros.....	69



ÍNDICE DE TABLAS

Tabla 1 Distribución de variables	34
Tabla 2 impacto de variables	35
Tabla 3 Liquidez.....	38
Tabla 4 Endeudamiento	39
Tabla 5 Rentabilidad	40
Tabla 6 Flujo de Caja.....	41
Tabla 7 Ingresos Anuales	42
Tabla 8 Insolvencia	43



ÍNDICE DE FIGURAS

Figura 1 lista de figuras	36
Figura 2 Rango de Liquidez	38
Figura 3 Rango de Endeudamiento	39
Figura 4 Rango de Rentabilidad.....	40
Figura 5 Rango de Flujo de Caja	41
Figura 6 Rango de Ingresos Anuales.....	42
Figura 7 Categoría	43
Figura 8 matriz de correlación.....	44
Figura 9 La Curva ROC	45



RESUMEN

Desarrollo del modelo En este estudio, se describe en detalle el proceso de diseño de un modelo predictivo basado en redes neuronales artificiales para predecir la insolvencia en la Cooperativa de Crédito Santa Rafaela durante 2023. El propósito del estudio es implementar un modelo que, utilizando los datos financieros históricos de la cooperativa y la inteligencia artificial de vanguardia, permitirá pronosticar de forma precisa y confiable la probabilidad de insolvencia, mejorando así el marco de toma de decisiones en torno a las finanzas. Por lo tanto, el enfoque de la investigación es cuantitativo, y el tipo de diseño metodológico es no experimental correlacional-predictivo. Los 5, 600 registros históricos se analizan en función de las variables financieras clave, que incluyen índices de liquidez, endeudamiento y rentabilidad, y se utilizan las técnicas de análisis exploratorio de los datos para estudiar estas variables. Para el desarrollo del modelo, se elige una arquitectura de redes neuronales con múltiples capas, conocida como perceptrón multicapa; utilizan los procesos de entrenamiento, validación y prueba para optimizar el modelo resultante. Se espera que el modelo cuente con una precisión mejorada del pronóstico de insolvencia y se validará a través de métricas como precisión, sensibilidad, agregando un rango de áreas bajo la curva. La aplicación de este modelo no solo permitirá a la cooperativa pronosticar mejor los riesgos financieros, sino que también le facilitará la adopción de medidas proactivas para evitarlos, lo que a su vez optimizará sus recursos humanos. activos y aumentará la competitividad en el mercado. Por lo tanto, esta investigación es una contribución valiosa para las finanzas al proporcionar una herramienta predictiva efectiva y para la academia al ofrecer información valiosa sobre la integración de la RNA en la evaluación del riesgo en las IF.

Palabras clave: Redes Neuronales Artificiales, Predicción, Insolvencia, Finanzas, Modelado Predictivo.



ABSTRACT

The present study focuses on designing a predictive model based on artificial neural networks (ANN) to predict insolvency in the Santa Rafaela Credit Cooperative during the year 2023. The primary objective is to develop a model that, utilizing historical financial data and advanced artificial intelligence techniques, accurately anticipates the probability of insolvency, thereby improving the cooperative's financial decision-making processes. The research adopts a quantitative approach with a non-experimental, correlational-predictive methodological design. A total of 5,600 historical records corresponding to key financial variables, such as liquidity ratios, debt ratios, and profitability, are analyzed using exploratory data analysis (EDA) and predictive modeling techniques. The model's development involves implementing a multilayer perceptron (MLP) neural network architecture, optimized through training, validation, and testing processes. The expected results include a significant improvement in the precision of insolvency predictions, validated through metrics such as accuracy, sensitivity, and area under the curve (AUC). It is concluded that the application of this model will not only enable the anticipation of financial risks but also optimize the cooperative's resources, enhancing its stability and competitiveness in the market. This work represents a relevant contribution both to financial practice, by providing a robust predictive tool, and to academia, by exploring the integration of neural networks in risk assessment for financial institutions.

Keywords: Artificial Neural Networks, Prediction, Insolvency, Finance, Predictive Modeling.



INTRODUCCIÓN

En el contexto actual, las instituciones financieras enfrentan crecientes desafíos relacionados con la gestión del riesgo crediticio, particularmente en la evaluación de la insolvencia. Este problema adquiere mayor relevancia en cooperativas de crédito, cuya estabilidad financiera impacta directamente a sus socios y a las comunidades que dependen de sus servicios.

En este sentido, las tecnologías emergentes, como las redes neuronales artificiales, presentan importantes oportunidades para mejorar la precisión y la eficiencia en la identificación de riesgos financieros.

La Cooperativa de Crédito Santa Rafaela, objeto de estudio, necesita desesperadamente desarrollar herramientas avanzadas que puedan prever la insolvencia prevista de sus clientes de manera efectiva. Por lo tanto, el presente estudio consiste en construir un modelo predictivo basado en RNA. De esta forma, se podrá analizar los datos financieros históricos y obtener buenas predicciones del riesgo de insolvencia. Este enfoque aborda las cuestiones clave y supera los desafíos de los métodos tradicionales. Como resultado, se propone un modelo más adaptativo y robusto en el contexto de los problemas actuales con la dinámica financiera. Este estudio utiliza un enfoque cuantitativo y la metodología es un diseño metodológico no experimental de correlación-predicción. Los 5,600 registros históricos de la cooperativa son empleados para el EDA y el modelado predictivo, lo que permite identificar las variables que pueden tener un impacto más significativo en la insolvencia. Estando basado en estos resultados, se implementa y valida un modelo con ese uso de las RNA con esa arquitectura no solo de las RNA multicapa, sino también de MLP. Un modelo optimizado se usa para garantizar



la máxima precisión y sensibilidad. La importancia del estudio se describe en su capacidad de prever los riesgos financieros y así asignar los recursos de manera más eficiente e influir en la toma de decisiones inmejorables. Además, este trabajo es relevante para las finanzas aplicadas, ya que contribuirá a la integración de la IA en la evaluación del riesgo en el crédito. Todavía, los resultados pueden ser usados como la base por investigadores futuros y los transformados al uso práctico por actores del mercado crediticio. El trabajo aborda los siguientes temas en detalle: ,

CAPÍTULO I : El problema, que presenta la problemática general y específica subyacente al tema y los objetivos e hipótesis de la investigación; , CAPÍTULO II : El marco teórico, que proporciona conocimientos sobre las RNA y cómo se pueden aplicar al riesgo financiero y la revisión de la literatura relevante; , CAPÍTULO III : Metodología de la investigación, con descripciones de la metodología empleada, el diseño de la investigación, la población y muestra, las técnicas de recolección de datos y los instrumentos de análisis; , CAPÍTULO IV : Resultados, evaluando los hallazgos del modelo constructivo y validado y discutiendo la precisión, la sensibilidad y la especificidad del modelo alcanzado., Conclusiones y recomendaciones, que reflejan las conclusiones del análisis y las recomendaciones para su utilización y estudios futuros.

.



CAPÍTULO I

ASPECTOS GENERALES

1.1. Descripción del problema

1.1.1 A nivel Internacional

En el contexto global, la evaluación de la solvencia en las instituciones financieras se ha convertido en un desafío crítico, ya que los mercados financieros maduran y la economía sigue siendo incierta. Según está científicamente comprobado, los métodos tradicionales utilizados para medir la insolvencia son insuficientes o inadecuados, aunque sean insuficientes. El problema radica en que los índices financieros no son lo suficientemente precisos como para capturar patrones complejos en los datos financieros. Las instituciones financieras internacionales se han expandido enormemente y siguen siendo más activas. Las instituciones pueden competir en el espacio financiero y se enfrentan a una mayor dinámica, riesgos de divisas y mayor progreso tecnológico. Por lo tanto, deben adoptar la inteligencia artificial y las herramientas basadas en redes neuronales para predecir más fácilmente los riesgos financieros. Este enfoque es fundamental para las cooperativas de crédito, ya que, como resultado de recursos financieros insuficientes, están mejor capacitadas para atender a las comunidades vulnerables en comparación con los bancos.



1.1.2 A nivel nacional

En el contexto nacional, las cooperativas de crédito en países en desarrollo, como Perú, desempeñan un papel importante en el acceso al financiamiento para comunidades desfavorecidas. No obstante, el caso, es que las cooperativas apenas cuentan con sistemas avanzados para monitorizar y reducir el riesgo de insolvencia; de esta forma, la insolvencia suele ser un fenómeno que interrumpe el funcionamiento de estas organizaciones y socava la confianza entre los socios. Sin embargo, dada la falta de sistemas avanzados para monitorear el riesgo de insolvencia, la insolvencia interrumpe la operación de las cooperativas y mina la confianza entre los socios. Varios estudios locales han demostrado que un porcentaje significativo de cooperativas enfrenta desafíos regulatorios con respecto al cumplimiento normativo financiero, prestando servicios sujetos a medidas de intervención reguladora y parada de la operación. Algoritmos de aprendizaje automático integrados, la creación de modelos predictivos avanzados sobre la base de Redes Neuronales Artificiales permite la cooperativa tomar decisiones informadas y preservar la sostenibilidad.

1.1.3 A nivel local

En la Cooperativa de Crédito Santa Rafaela, en las dificultades para determinar la insolvencia son agudas, como olas encrespadas por el manejo limitado de datos y técnicas analíticas tradicionales que no alcanzan las intrincadas corrientes financieras. Esta situación se ve agravada por la escasez de instrumentos tecnológicos que permitan una previsión precisa, aumentando el peligro de decisiones tomadas a ciegas, en la penumbra de la información insuficiente. La implementación de un marco neuronal de IA personalizado, a la medida de la cooperativa, "podría también mejorar sustancialmente la previsión de

solvencia, afinando las estrategias de riesgo y asegurando la perdurabilidad de los socios y la propia operación, como un faro en la tormenta”.

1.2. Formulación del problema

1.2.1 Problema Principal

¿Cómo diseñar un modelo basado en redes neuronales artificiales para predecir la insolvencia en la Cooperativa de Crédito Santa Rafaela en el año 2023?

1.2.2 Problemas específicos

1. ¿Cuáles son las variables financieras más relevantes que influyen en la insolvencia de la Cooperativa de Crédito Santa Rafaela en el año 2023??
2. ¿Qué arquitectura de red neuronal artificial es la más adecuada para analizar y predecir la insolvencia en la Cooperativa de Crédito Santa Rafaela??
3. ¿Qué tan precisa es la predicción del modelo de redes neuronales al validar sus resultados con datos históricos de la Cooperativa de Crédito Santa Rafaela en el año 2023?

1.3. Justificación de la investigación

1.3.1 Justificación teórica

La insolvencia en cooperativas de crédito es un problema crítico que afecta la estabilidad económica de sus socios y comunidades. Si bien, tradicionalmente, la insolvencia se ha evaluado a través de técnicas de análisis de ratios financieros. Aunque los datos del ratio insolvencia son una herramienta útil en la toma de decisiones sobre si esperarías el incumplimiento de una empresa. No son capaces de representar patrones no lineales o complejos en los datos financieros. Esta investigación presenta una forma novedosa de identificar ofensores: el uso de redes



neuronales artificiales. Las redes neuronales artificiales son modelos de inteligencia artificial avanzados que pueden codificar pautas no lineales y, a menudo, sutilmente complejas. Es posible comparar esto con la investigación anterior sobre el uso de I.A. en el sector financiero. Este es otro ejemplo de adaptación de tecnologías existentes a problemas específicos.

1.3.2 Justificación Practico

Por lo tanto, el objetivo práctico del trabajo es proporcionar a la Cooperativa de Crédito Santa Rafaela una herramienta tecnológica avanzada que pueda prever fracasos con precisión. Este modelo permitirá a la cooperativa controlar de manera eficiente los riesgos financieros, racionalizar la asignación de recursos, y no gastar tiempo y dinero en la tierra porque el modelo les dice que la información que están comprando es falsa. La misma herramienta está diseñada para soportar un ambiente regulatorio más limitado y para impulsar una cultura laboral más segura. Así, a través de un modelo, la empresa aumenta su eficacia, mientras que las demás instituciones financieras similares pueden obtener su sistema a través de este mapa conceptual y obtener más datos.

1.3.3 Justificación Metodológica

En lo que respecta a la metodología, este trabajo estará basado en métodos cuantitativos y utilizará algoritmos de machine learning, en particular, redes neuronales. La actividad comienza con la recopilación de datos financieros históricos de la cooperativa y la preparación de estos datos para su inclusión en el modelo. Para la construcción del modelo, se utilizarán múltiples herramientas de programación, como Python, y bibliotecas de machine learning, como TensorFlow, PyTorch y así sucesivamente. Luego, el modelo será entrenado, validado y evaluado utilizando métricas, como el porcentaje de exactitud, sensibilidad y

función F. Dicho modelo no solo proporcionará un análisis consistente y replicable, sino que también puede usarse con la mismo propósito o con aplicaciones más prácticas con otras cooperativas de ahorro o similares. A través de cualquier lenguaje de programación, como Python, y bibliotecas de aprendizaje automático, como TensorFlow y PyTorch, se creará un modelo de aprendizaje automático y, posteriormente, se entrenará, se probará y se evaluará con indicadores de rendimiento como precisión, sensibilidad y F-Measure. En general, este enfoque asegura la robustez y la replicabilidad del análisis; los resultados pueden servir como base para futuras investigaciones o la implementación práctica en otras cooperativas similares o instituciones financieras.

1.4. Objetivos

1.4.1 Objetivo general

Diseñar un modelo basado en redes neuronales artificiales para predecir la insolvencia en de crédito Santa Rafaela 2023.

1.4.2 Objetivos específicos

1. Identificar las variables financieras más relevantes que influyen en la insolvencia de la cooperativa Santa Rafaela 2023.
2. Desarrollar un modelo de redes neuronales para analizar la insolvencia en la cooperativa de crédito Santa Rafaela 2023.
3. Validar la precisión del modelo utilizando datos históricos de la cooperativa Santa Rafaela 2023.

1.5. Importancia

En conclusión, la relevancia académica y tecnológica del presente estudio radica en el diseño de un modelo basado en redes neuronales artificiales para la



evaluación de insolvencia en la Cooperativa de Crédito Santa Rafaela. Se puede contribuir al campo del aprendizaje automático y su utilidad en el ámbito financiero. Además, este enfoque permite a AI y a la administración financiera estar más cerca gracias a la integración, lo que puede hacer que ambas partes estén más preparadas para usar herramientas avanzadas para resolver situaciones difíciles y tomar decisiones. En términos de importancia social y económica, se pretende fortalecer la estabilidad de una cooperativa que beneficia a las comunidades locales. En general, las cooperativas de crédito atienden a sectores social y económicamente marginados, por tanto, tener la capacidad de predecir y contener las insolvencias, garantizará una mayor sostenibilidad de los servicios financieros y el acceso al crédito para sus beneficiarios. Por último, en términos de la relevancia institucional, el modelo ofrecerá ventajas a la Cooperativa Santa Rafaela, permitiendo optimizar la administración del riesgo financiero, mejorando la eficacia operativa y disminuyendo los costes relacionados con los fallos de la evaluación de insolvencia. develop confidence based on the results obtained but also in terms of complying with the regulations.

1.6. Limitaciones

Disponibilidad y calidad de los datos: Factor El modelo depende de los datos históricos financieros disponibles, y la calidad y cantidad reales de los datos afectan la precisión del modelo. Cualquier falta de accesibilidad o incluso imprecisión en el sistema de datos afectaría el rendimiento del modelo. Factor.

Generalización del modelo: puesto que el modelo se construye sobre la base de un solo estudio de caso, puede ser que la estructura e indicadores financieros de otras cooperativas sean sustancialmente diferentes, limitando la aplicación general del modelo. Factor.



Capacidad informática: la implementación y el entrenamiento de ANN requieren una gran capacidad informática, el acceso insuficiente al software o al hardware daría lugar a un modelo simplificado y al tiempo prolongado antes de que se hagan y se usen modificaciones. Factor.

Interpretabilidad del modelo: aunque AANN son efectivas, la "caja negra" propia de la interpretación directa de las redes neuronales fue la razón de una cierta resistencia a su adopción por parte de los responsables de la toma de decisiones en la cooperativa. Factor.

Dependencia tecnológica: La adopción del modelo es un desafío para la cooperativa que no tiene personal capacitado, y los modelos requieren habilidades especiales para su mantenimiento y actualización. Factor.

Factores externos: Cualquier evento imprevisto, incluido un ajuste desfavorable en el sistema regulatorio u otras condiciones denominadas macroeconómicas, puede alterar el equilibrio financiero y, por tanto, limitar la aplicabilidad inmediata de las soluciones propuestas..



CAPÍTULO II

FUNDAMENTOS TEÓRICOS

2.1. Antecedentes

2.1.1 Internacionales.

En el ámbito internacional, Gozer (2019) estudió la evaluación de la insolvencia de las cooperativas de crédito en Brasil mediante redes neuronales artificiales y máquinas de soporte vectorial. El autor utilizó datos financieros de 31 cooperativas solventes e insolventes ubicadas en el estado de Paraná. Asimismo, los indicadores estaban basados en el sistema PEARLS, el cual ha sido reconocido como un mecanismo eficaz para evaluar la estabilidad financiera de estas instituciones. Los resultados mostraron que las máquinas de soporte vectorial superaban a los de redes neuronales en términos de precisión, especialmente en el caso de clasificación binomial de insolvencia. Sin embargo, las redes neuronales han demostrado un rendimiento excepcional al evaluar cooperativas de alto riesgo, lo cual subraya su importancia a la hora de iniciar las medidas financieras de recuperación. Amran et al. usaron metodologías relacionadas con los modelos de aprendizaje automático para gestionar los riesgos financieros en los bancos europeos. En particular, los autores utilizaron redes neuronales y modelos de regresión en datos históricos completados entre 2005 y 2015. Identificaron patrones



no lineales que los indicadores tradicionales no pudieron lidiar y, por lo tanto, predicen con más precisión insolvencias y áreas de asignación de recursos. Como resultado, alegaron que el uso de algoritmos de aprendizaje automático conlleva una mayor capacidad de predicción de insolvencias y un aumento de la competitividad en los mercados internacionales. De acuerdo, Zhang et al. implementaron redes neuronales para pronosticar insolvencia para instituciones financieras en China. Trabajando con un problema de clasificación y un marco de 200 empresas, los autores desarrollaron un modelo de clasificación utilizando la relación flujo de caja / activo y deuda / activo. Su precisión, alrededor del 92%, demostró ser una herramienta confiable para reconocer riesgos en la insolvencia. Además, la capacidad de las redes neuronales para adaptarse a diferentes condiciones económicas hace que estos modelos sean prácticos, en comparación con los métodos tradicionales. Finalmente, a través de su investigación exhaustiva, Hastie et al. se referían a las metodologías avanzadas para el pronóstico de insolvencias. Los autores centraron su atención en el uso de redes neuronales para modelar relaciones financieras no lineales y complejas y premiaron a esas líneas debido a la precisión. Sobre esta base, sugieren el uso de validación cruzada y métricas actualizadas para garantizar la precisión y confiabilidad de los modelos computacionales en finanzas. A partir de este documento, se crearon múltiples aplicaciones modernas. Lee y Chiu también presentaron un análisis del papel de redes neuronales profundas para administrar insolvencia bancaria en Corea del Sur. Utilizando datos históricos y un análisis de series de tiempo, los autores redujeron errores de clasificación significativamente. Una vez más, señalan la flexibilidad de las redes neuronales para adaptarse a entornos cambiantes.



2.1.2 Nacionales

Bautista analizó (2021) la implementación de sistemas de planificación en las MYPES del Perú y obtuvo resultados sobre la mejora de la estabilidad financiera con el empleo de herramientas tecnológicas. Basándose en el análisis de 44 artículos científicos, el autor subrayó la necesidad de la adopción de enfoques predictivos para reducir riesgos y optimizar recursos. El estudio demostró el papel de las tecnologías avanzadas, como las redes neuronales, en la mejora de la capacidad de gestión financiera en pequeñas empresas. Quispe y Ramos realizaron el estudio de la insolvencia en cooperativas de crédito del sur del Perú también recurriendo a las medidas financieras tradicionales y sugirieron las herramientas más sólidas. Según los estudios de 15 cooperativas, el uso de enfoque tradicionales no es suficiente para encontrar los patrones de riesgo, ya que la aproximación feloniosa a la insolvencia en las cooperativas. Sugirieron que las técnicas más avanzadas, como las redes neuronales, permitirían señalar predicciones más significativas a la insolvencia y, por lo tanto, garantizar la sostenibilidad de estas instituciones. Castillo implementó el modelo para la empresa de consumo masivo en Lima que se basó en herramientas predictivas de la información histórica. Este estudio mostró que el empleo de las tecnologías avanzadas optimiza los recursos y reduce los gastos operacionales, además de precisar los pronósticos. Aunque su realización fue en los formatos industriales, las conclusiones muestran que la aplicación de estas herramientas es adecuada en los sectores financieros, incluso en las cooperativas. Los autores de Rivera et al. utilizaron las redes neuronales para la clasificación de los riesgos financieros en los bancos locales. Con 85% de precisión, el modelo desarrollado demostró la efectividad en la predicción de insolvencias. El estudio subrayó el rol de la adopción



de las tecnologías de aprendizaje automático para la gestión del riesgo financiero en el sistema bancario peruano.

2.1.3 Locales

Muñoz Sánchez 2023. En su tesis sobre planificación de la producción en una asociación artesanal en Lambayeque, Muñoz Sánchez encontró significativas deficiencias en dirección de recursos financieros y operativos. Mediante el empleo de herramientas de análisis de procesos y mapeo de cadena de valor, estudió capacidad productiva de la asociación y su impacto en costos operativos. Conclusiones principales estuvieron desprovistas de un sistema planificado estructurado que resultó en ruturas de existencias y costos excesivos de adquisición de insumos. Este antecedente es de interés para gp en la insolvencia de cooperativas de crédito ya que recalca la necesidad de herramientas avanzadas para gestión eficiente de recursos financieros, lo que es esencial para la sostenibilidad de la operación.bruary 17, 2023.CommandType Muñoz Sánchez 2023.

Pérez y López (2022) Además, una investigación realizada por Pérez y López 2022 sobre la estabilidad financiera de las cooperativas en la región norte de Perú, examinaron los indicadores financieros clave y los patrones de riesgo en las carteras de préstamos. Utilizando los datos de varias cooperativas locales, los autores identificaron la alta tasa de morosidad y la debilidad de los controles internos como factores contribuyentes a la insolvencia. De acuerdo con Pérez y López 2022, los modelos de redes neuronales también deben ser implementados para lograr un mayor riesgo y mejor toma de decisiones de la asignación de recursos. Por lo tanto, el precedente destaca la necesidad de la implementación de



capacidades avanzadas, como las redes neuronales artificiales, para mejorar la evaluación de la solvencia en las cooperativas locales.

En cuanto a Quispe y Ramos (2021) investigaron en este sentido, el artículo revisa los indicadores financieros de los modelos rechazados y propuestos y proporciona modelos predictivos para obtener un pronóstico más preciso de la insolvencia. Los autores señalan que el uso de tecnologías predictivas avanzadas puede cambiar el paradigma de la gestión del riesgo financiero en las instituciones locales, por lo que este artículo puede considerarse como una referencia para las cooperativas de Guatemala y otras regiones. Así mismo, Sánchez y Vega examinaron los procedimientos financieros de las cooperativas en Cajamarca y analizaron la influencia de la planificación financiera en la solvencia y notaron que los modelos de gestión de activos y pasivos no eran claros para predecir un claro aumento de la probabilidad de insolvencia. A través del análisis de los datos anteriores, los autores propusieron un enfoque basado en inteligencia artificial para la toma de decisiones. Este artículo tiene el mismo nivel de relevancia que el anterior, ya que resalta la importancia de las tecnologías innovadoras para prevenir los riesgos financieros. Finalmente, Carranza sugirió un modelo simplificado de identificación de la insolvencia para la cooperativa de crédito en Piura basada en indicadores financieros básicos. La autora demostró que el cálculo de solo un subconjunto de indicadores era suficiente para prever el riesgo de insolvencia con alta precisión y recomendó la introducción de herramientas ayuda como Redes Neuronales para mejorar la eficiencia y precisión de las evaluaciones. Este artículo es especialmente relevante para las cooperativas locales ya que la investigación muestra que los enfoques simplificados deben mejorarse con inteligencia artificial.

2.2. Marco epistemológico

Este estudio se enmarca en el paradigma positivista desde la perspectiva de la epistemología. Debido a que este paradigma se basa en el análisis objetivo y cuantitativo de los datos para validar las hipótesis y lograr conclusiones comprobables, es posible establecer relaciones causa y efecto entre las variables identificadas entre sí. Los factores financieros obtenidos y la probabilidad de insolvencia de la CCSR son ejemplos de tales variables relacionadas. El enfoque epistemológico de este estudio es empírico-analítico. Se caracteriza por la observación sistemática y la utilización de herramientas computacionales y estadísticas para analizar los datos recopilados históricos. Dada la aplicación de la inteligencia artificial, a saber, las redes neuronales artificiales, este estudio combina la computación y el campo de las estadísticas y las finanzas. Dado que este estudio no es experimental y tiene un diseño correlacional-predictivo, el enfoque positivista resuena en la recogida de datos existentes y el análisis riguroso de las relaciones existentes entre las variables, en este caso, el dije insolvencia de la CCSR. También se busca obtener resultados replicables y generalizables, es decir, principales características del positivismo científico. Este estudio considera válido epistemológicamente que el conocimiento sobre la insolvencia sea posible basado en la interpretación sistemática de los datos financieros existentes, en la elección de los modelos predictivos adecuados y en el uso de métricas de evaluación transparentes.

2.3. Estado del arte

En consecuencia, el estado del arte sobre la evaluación de insolvencia a través de modelos predictivos gira en torno al uso agregante del interés por parte



del sector de los modelos de inteligencia basados en redes neuronales artificiales. Las tendencias, los logros y los desafíos sobre el tema están presentados a continuación. Evaluación de Insolvencia en Instituciones Financieras. Los métodos tradicionales para abordar la insolvencia, es decir, el análisis discriminante y la regresión logística, son una práctica común en la industria en lo que respecta a la predicción de fallas. Sin embargo, los dos tienen una limitación evidente en entornos de alta dimensión y no lineales, lo que no les permite trabajar con un mayor arreglo de variables. Como sustituto, las redes neuronales artificiales son la base para descubrir patrones insospechados y procesar grandes cantidades de datos financieros heterogéneos. 2. Las redes neuronales artificiales en finanzas. Las redes neuronales artificiales han resultado ser un acercamiento diferente y más eficaz a la predicción de insolvencia. La literatura respalda el aprendizaje de perceptrón multicapa y redes recurrentes como un acercamiento sólido para analizar patrones en datos financieros a lo largo del tiempo y prever insolvencias con bastante precisión.. 3. Estudios relevantes. Aplicaciones. Los estudios de instituciones financieras en Europa y Asia dicen que la red neuronal artificial predice la insolvencia con alto nivel de precisión. Por ejemplo, Altman et al. , 2021 mostró que su RNA supera la indicación de precisión de los modelos tradicionales y además de eso, logra reducir significativamente falsos positivos a alrededor de 20%. Contexto Latinoamericano. En el contexto de América Latina, las RNA han surgido como una alternativa innovadora a modelos de riesgo crediticio establecidos. Por ejemplo,.. Herramientas y Técnicas. El diseño y desarrollo de RNA se facilita con las plataformas de código abierto como Python, TensorFlow y PyTorch, que permiten el desarrollo de modelos basados en RNA y optimizaciones. Además, las integra técnicas de EDA y selección de características respalda la



interpretabilidad y eficacia de los RNA.. 5. Desafíos Actuales.. 5.. Calidad de los datos. Datos financieros deficientes y falta de limpieza continua son los dos desafíos más críticos para los modelos de RNA. Interpretabilidad. Las RNA son extremadamente eficaces, pero faltan en interpretabilidad por parte de los tomadores de decisiones en la empresa no técnicos. Escalabilidad Compatibilidad con entornos económicos reales con respecto a la provisión permitir su implementación.

2.4. Bases teóricas

2.4.1 Redes Neuronales Artificiales (RNA)

Las redes neuronales artificiales son modelos computacionales inspirados en la estructura y el funcionamiento del cerebro humano. Una RNA es un sistema de nodos, llamados neuronas, interconectados e interrelacionados, agrupados por capas, entrada, ocultas y salida que tienen conexiones entre sí con un peso ajustable que se optimiza durante el entrenamiento. Arquitectura: Hay diferentes tipos, la complejidad varía según el diseño. En este estudio, se ocupa un perceptrón multicapa, una estructura de capas densamente conectadas, adecuada para problemas de clasificación. Funciones de activación: Para procesamiento de señales no lineales y predicciones de probabilidad, las funciones ReLU y softmax son esenciales. Entrenamiento: Aprendizaje a través del descenso de gradiente estocástico y retro-propagación del error. Stop la pérdida. Las redes neuronales artificiales son adecuadas para patrones informáticos multifacéticos y altamente dimensionales aprendizaje de datos; por lo tanto, es ideal para los problemas financieros multifacéticos; el flujo de múltiples variables no se adapta a un patrón unidimensional.

2.4.2 Predicción de Insolvencia Financiera

Insolvencia predicción. La insolvencia predicción siempre consiste en el análisis de si una empresa o un cliente en circunstancias adecuadas no será competente financieramente. Se trata de una tarea extremadamente importante en la gestión del riesgo en las instituciones financieras. Además, los indicadores financieros más importantes son la liquidez, el endeudamiento y la rentabilidad. Por lo tanto, el insolvencia modelo es aquel que predice el "éxito" en términos financieros de la empresa.. Más concretamente, para esta entrada, los autores utilizaron razones financieras, como el índice corriente, la deuda total y el margen de utilidad neta, para acreditar a este tipo de insolvencia. Además, los modelos predictivos se reciben RNA models, que son mucho mejores que cualquier modelo clásico, como la regresión logística o el análisis discriminante tradicional. Sin embargo, la insolvencia predicción es todo el proceso real de evaluación de riesgos financieros. Eso significa que este proceso se basa en los indicadores financieros y en el insolvencia modelo.

2.4.3 Inteligencia Artificial y Aprendizaje Supervisado.

El aprendizaje supervisado es un enfoque en el que un modelo se entrena con un conjunto de datos, es decir, una entrada y salida, que está etiquetado para hacer predicciones precisas. Bishop 2006 habría sido el aprendizaje supervisado en aplicaciones de clasificación y regresión como la predicción de insolvencia. Por otro lado: a utiliza funciones de activación como ReLU y softmax para procesar la información en las capas ocultas y genera salidas probabilísticas en la capa final b. Las métricas como precisión, sensibilidad, área bajo la curva AUC son críticas para validar el rendimiento del modelo.

2.4.4 Inteligencia Artificial Aplicada a las Finanzas

La IA ha revolucionado la industria financiera a través de herramientas avanzadas para analizar las tendencias de los datos y la toma de decisiones basadas en estos datos a través de modelos predictivos.. Aprendizaje supervisado: Bishop Se refiere al aprendizaje supervisado como un método comúnmente utilizado en problemas de clasificación, asumiendo que tiene un conjunto de datos etiquetados. Con RNA en Finanzas: Martínez y Gómez explicaron que las RNA abordan de manera efectiva la modelación de datos completos e incompletos en finanzas, permitiendo a las instituciones prever la insolvencia y mitigar el riesgo en su nivel más bajo posible. Tendencias mundiales: las RNA son cada vez más populares en las instituciones financieras globales, con sus tasas de precisión excediendo los métodos tradicionales en años anteriores en un 15-20%. La aplicación de RNA en la predicción de la insolvencia promueve una toma de decisiones estratégicas y estabilidad en las instituciones.finanzas.

2.4.5 Teoría de Sistemas y Toma de Decisiones.

La investigación se basa en la teoría de sistemas, lo que implica que las organizaciones financieras son sistemas abiertos con los que interactúan continuamente. Por lo tanto, la predicción de insolvencia, como un proceso central de la indagación, se realiza para proporcionar información relevante para las decisiones estratégicas que aseguran la armonía y equilibrio del sistema financiero. Von Bertalanffy , como ha señalado antes, argumenta que, en general, un sistema que trabaja debe responder y adaptarse a los cambios de su entorno. Por lo tanto, el sistema financiero debería organizar su respuesta a la amenaza de la insolvencia para lograr la armonía. La integración de RNA en la predicción de insolvencia también se hace en papel con este supuesto, ya que le permite a la institución

reconocer los riesgos y abordarlos antes de que ocurran, garantizando la estabilidad operativa.

2.4.6 Bases Matemáticas.

Gradiente cálculo: Este es críticamente lanzado en RNA para la optimización de pesos. Álgebra lineal: se usa para expresar y manipular los datos de pesos y entrada en las matrices. Estadística descriptiva e inferencial: este es esencial EDA y pruebas de modelos.

2.4.7 Métodos de Validación de Modelos.

La validez y la confiabilidad de un modelo predictivo se logran mediante métricas y métodos estadísticos que evalúan su desempeño. Algunas de las métricas de evaluación y métodos aplicados incluyen: métricas de evaluación como pinche; sensibilidad; especificidad; el área bajo la curva; validación cruzada; y regularización. Todas las métricas y métodos anteriores asegurarán que el modelo sea robusto, preciso y útil en la práctica financiera.

2.4.8 Modelos.

En la investigación, se emplearán modelos comparativos para evaluar el desempeño del modelo de redes neuronales artificiales (RNA) en la predicción de insolvencia y contrastarlo con técnicas tradicionales y modernas utilizadas en el campo financiero. Los modelos comparativos seleccionados son:

2.4.8.1. Modelos Tradicionales.

Estos modelos son ampliamente utilizados en la predicción financiera y permiten establecer una línea base para evaluar el desempeño de las RNA.

Regresión Logística:

Este modelo estadístico es útil para problemas de clasificación binaria, como solvente o insolvente.

Permite interpretar la relación entre las variables independientes (ratios financieros) y la probabilidad de insolvencia.

Métricas clave: precisión, sensibilidad, especificidad, y área bajo la curva (AUC).

Análisis Discriminante:

Técnica estadística que clasifica observaciones en grupos basados en variables predictivas.

Es popular en la evaluación de riesgos financieros, pero tiene limitaciones al manejar datos no lineales.

2.4.9 Modelos Basados en Machine Learning.

Se emplean modelos modernos de aprendizaje supervisado que compiten en precisión y capacidad de generalización con las RNA.

Árboles de Decisión:

Proveen una estructura jerárquica para dividir datos en función de variables significativas.

Ventajas: fácil interpretación.

Limitaciones: propensos al sobreajuste.

Random Forest:

Conjunto de múltiples árboles de decisión que mejora la precisión al reducir la varianza.

Ideal para conjuntos de datos con muchas variables predictivas.



Máquinas de Soporte Vectorial (SVM):

Algoritmo efectivo para clasificación con datos no lineales.

Utiliza kernels para mapear datos en dimensiones más altas y encontrar el mejor hiperplano separador.

K-Nearest Neighbors (KNN):

Clasifica observaciones basándose en la proximidad a los vecinos más cercanos.

Limitación: sensibilidad al ruido en los datos..

2.4.10 Modelos Basados en Redes Neuronales.

Dentro del enfoque de RNA, se realizarán comparaciones internas con arquitecturas variantes para identificar la más adecuada.

Perceptrón Multicapa (MLP):

Arquitectura de red neuronal básica utilizada en esta investigación.

Se optimiza mediante la experimentación con capas y nodos.

Redes Neuronales Recurrentes (RNN):

Útiles para datos temporales o secuenciales, como series históricas financieras.

Redes Neuronales Convolucionales (CNN):

Aunque son más comunes en procesamiento de imágenes, pueden ser adaptadas para datos estructurados.

2.4.11 Métricas de Comparación.

Para comparar los modelos, se utilizarán las siguientes métricas:

Precisión: Proporción de predicciones correctas.

Sensibilidad (Recall): Capacidad del modelo para identificar insolencias reales.

Especificidad: Capacidad del modelo para identificar correctamente las entidades solventes.

F1-Score: Promedio armónico entre precisión y sensibilidad.

Área Bajo la Curva (AUC): Mide la capacidad del modelo para distinguir entre clases.

Matriz de Confusión: Para evaluar los aciertos y errores en cada clase.

El uso de estos modelos comparativos permitirá validar la efectividad de las RNA frente a técnicas tradicionales y otras de machine learning, asegurando una evaluación integral de su desempeño en la predicción de insolvencia.

2.4.12 Métricas de Clasificación.

Las métricas específicas que se evaluarán en esta investigación para medir el rendimiento del RNA y comparar con otros modelos de predicción son:

1. Métricas de Clasificación

Estas métricas son esenciales para evaluar la capacidad del modelo para clasificar correctamente las observaciones en solvente o insolvente.

Precisión (Accuracy):

Proporción de predicciones correctas sobre el total de casos.

Fórmula:.

$$\text{Precisión} = \frac{TP + TN}{TP + TN + FP + FN}$$

Donde:



- TP : Verdaderos Positivos.
- TN : Verdaderos Negativos.
- FP : Falsos Positivos.
- FN : Falsos Negativos.

Sensibilidad (Recall o True Positive Rate):

Capacidad del modelo para identificar correctamente las observaciones positivas (insolvencias reales).

Fórmula:

$$\text{Sensibilidad} = \frac{TP}{TP + FN}$$

Especificidad (True Negative Rate):

Capacidad del modelo para identificar correctamente las observaciones negativas (solventencias reales).

Fórmula:

$$\text{Especificidad} = \frac{TN}{TN + FP}$$

F1-Score:

Promedio armónico entre precisión y sensibilidad, útil cuando existe un desequilibrio entre clases.

Fórmula:

$$\text{F1-Score} = 2 \cdot \frac{\text{Precisión} \cdot \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}}$$

2. Métricas de Evaluación de la Curva ROC

La curva ROC (Receiver Operating Characteristic) evalúa el desempeño del modelo en términos de sensibilidad y tasa de falsos positivos.

Área Bajo la Curva (AUC):

Mide la capacidad del modelo para distinguir entre clases positivas y negativas.

Un valor cercano a 1 indica un buen desempeño.

3. Métricas de Error

Para comprender el margen de error en las predicciones del modelo.

Log-Loss (Pérdida Logarítmica):

Evalúa la probabilidad asignada por el modelo a las clases correctas. Penaliza fuertemente las predicciones incorrectas con alta confianza.

Fórmula:

$$\text{Log-Loss} = -\frac{1}{N} \sum_{i=1}^N [y_i \cdot \log(p_i) + (1 - y_i) \cdot \log(1 - p_i)]$$

Donde:

- y_i : Clase verdadera (0 o 1).
- p_i : Probabilidad predicha por el modelo para la clase 1.

4. Métricas de Interpretabilidad

Estas métricas ayudan a evaluar la utilidad práctica del modelo en un contexto financiero.

Matriz de Confusión:

Muestra la distribución de predicciones correctas e incorrectas para cada clase (solvente e insolvente).

Ganancia Cumulativa (Cumulative Gain):

Evalúa la eficacia del modelo en identificar las observaciones positivas más importantes (insolvencias) en los primeros percentiles de las predicciones.

2.5. Marco conceptual

Redes Neuronales Artificiales (RNA)

Definición: Las redes neuronales artificiales son sistemas computacionales inspirados en la estructura y funcionamiento del cerebro humano, diseñadas para procesar información y aprender patrones a partir de datos. (Haykin, 1998).

Componentes principales:

Neuronas: Elementos básicos que procesan la información.

Insolvencia

una entidad no puede cumplir con las obligaciones financieras conforme a los términos definidos. Es uno de los indicadores más importantes de la estabilidad financiera. las causas principales son las siguientes: falta de liquidez- la incapacidad de realizar activos al efectivo. alto apalancamiento: nivel de endeudamiento en comparación con los activos. Perdida de ingresos: disminución de la capacidad para tener ganancias. Los indicadores financieros clave son los siguientes: la razón de circulante: relación acorde con los activos circulantes contra la compensación. relación deuda/activos: relación entre deuda total y activos totales. rentabilidad: margen de beneficio neto.

Predicción Financiera

Métodos estadísticos como regresión logística y análisis discriminante. Herramientas avanzadas: Modelos de aprendizaje automático, como RNA, que ofrecen mayor precisión al identificar patrones complejos.



Aprendizaje Automático (Machine Learning)

Definición: Es la rama de la inteligencia artificial que permite que los sistemas aprendan automáticamente a partir de datos y mejoren su rendimiento sin intervención explícita. Algunos tipos relevantes son:

Aprendizaje supervisado: el modelo se entrena con datos etiquetados.

Aprendizaje no supervisado: identificación de patrones en los datos sin etiquetas proporcionadas de antemano.

Algoritmos en la investigación: las RNA se consideran una técnica de aprendizaje supervisado.

Indicadores del Sistema PEARLS

Nombre: Calificación-insolvencia

a. Definición: Juego de medidas financieras utilizadas para determinar la solidez de la cooperativa de crédito;

b. Componentes clave:

i. Protección almacenamiento frente a las pérdidas;

ii. Estructura financiera de activos y pasivos;

iii. Rentabilidad de alta capacidad para ganar dinero

c. Relevancia : los indicadores mencionados son necesarios para cuantificar la probabilidad de quiebra..

Modelos Predictivos

Validación y prueba: Evaluación del desempeño del modelo con métricas específicas.

Métricas utilizadas:

Precisión, sensibilidad, especificidad, área bajo la curva (AUC).

Validación Cruzada

Definición: Método que se encarga de evaluar la capacidad predictiva de todo modelo dividiendo la información en los conjuntos de entrenamiento y prueba.

-Importancia: Se reduce el peligro del sobreajuste y garantiza a la generalización del modelo ante nuevos datos.

2.6. Hipótesis

2.6.1 Hipótesis general

El diseño de un modelo basado en redes neuronales artificiales permitirá predecir de manera precisa la insolvencia en la Cooperativa de Crédito Santa Rafaela en el año 2023.

2.6.2 Hipótesis específicas

1. La identificación de las variables financieras más relevantes mejora la capacidad predictiva del modelo para evaluar la insolvencia en la Cooperativa de Crédito Santa Rafaela.
2. El desarrollo de un modelo de redes neuronales con una arquitectura adecuada permite analizar y predecir con alta precisión la insolvencia en la Cooperativa de Crédito Santa Rafaela.
3. La validación del modelo mediante datos históricos de la Cooperativa Santa Rafaela garantizará una precisión suficiente para ser utilizado como herramienta en la toma de decisiones financieras.



CAPÍTULO III

METODOLOGÍA Y RESULTADOS

El enfoque de este estudio es cuantitativo. Esto se debe a que implica la recopilación y el análisis de datos numéricos de desempeño financiero relacionados con la obra de beneficencia Cooperativa de Crédito Santa Rafaela. Este enfoque se hace posible a través de técnicas de aprendizaje automático como la red neuronal artificial, que puede medir variables específicas como solvencia, liquidez y rentabilidad. Además, el enfoque cuantitativo es ideal para describir fenómenos complejos financieros y para producir resultados replicables y generalizables.

3.1. Métodos de investigación

Por lo tanto, el método será empírico-analítico, que consiste en la observación, recolección, procesamiento y análisis de datos cuantitativos. Este método tiene: un método descriptivo para identificar y describir los indicadores financieros identificados anteriormente; un método correlacional para analizar las relaciones entre los indicadores financieros anteriores y la probabilidad de insolvencia; y un método predictivo para crear un modelo basado en redes neuronales, lo que permitirá hacer predicciones sobre la insolvencia en función de datos obtenidos.

3.1.1 Tipo de investigación

El tipo de investigación es aplicado, ya que es necesario resolver el problema práctico de la evaluación y predicción de la insolvencia en la Cooperativa de Crédito Santa Rafaela. Al mismo tiempo, el objetivo consiste en generar conocimiento útil para aplicar directamente en la gestión financiera de la cooperativa. Asimismo, este tipo de investigación combina la innovación tecnológica y el análisis financiero y, por lo tanto, es especialmente pertinente en la era digital.

3.1.2 Nivel

Correlacional : Pues se busca identifica las relaciones entre los indicadores financieros con relación a la insolvencia.

Predictivo: Al implementar un modelo basado en redes neuronales artificiales que pueda prever la insolvencia en base a los patrones históricos y actuales.

3.1.3 Diseño

El diseño es no experimental, transversal y descriptivo-predictivo:

No experimental: No se manipularán variables; los datos se recolectarán y analizarán tal como se presentan en los registros históricos y actuales de la cooperativa.

Transversal: La recolección de datos se realizará en un único período de tiempo, aunque los datos abarcan varios años.

Descriptivo-predictivo: El diseño no solo describe las relaciones entre las variables financieras, sino que también desarrolla un modelo predictivo para anticipar insolvencias..

3.2. Modalidad de estudio de casos

3.2.1 Población

La población de este estudio está constituida por los datos financieros históricos y actuales de la Cooperativa de Crédito Santa Rafaela, correspondientes al período 2018-2023. Esto incluye estados financieros, balances, indicadores de solvencia, registros de préstamos, morosidad y otras métricas relacionadas con la gestión financiera de la cooperativa. La población también abarca la totalidad de las operaciones que impactan la solvencia, incluyendo la calidad de la cartera de préstamos, la gestión de ingresos y gastos, y los niveles de liquidez.

3.2.2 Muestra

La muestra se seleccionará de manera no probabilística por conveniencia, considerando los datos más representativos y completos de los años 2022 y 2023. Esto incluye:

Indicadores financieros clave: Ratios de liquidez, rentabilidad, solvencia y calidad de la cartera.

Registros específicos: Datos de al menos 30 períodos contables (mensuales o trimestrales) que incluyan variables críticas para la evaluación de la solvencia. Se analizarán 5600 datos o registros.

3.3. Métodos y técnicas de recogida de información

El enfoque metodológico es cuantitativo, empleando técnicas de:

Análisis documental: Para recopilar datos financieros relevantes de la cooperativa.

Análisis exploratorio de datos (EDA): Para identificar patrones, tendencias y relaciones significativas entre las variables financieras.

Modelado predictivo: Utilizando redes neuronales artificiales para desarrollar y entrenar un modelo que evalúe la solvencia o insolvencia de la cooperativa.

El instrumento principal será una base de datos estructurada que incluirá los indicadores financieros clave. Esta base será procesada mediante:

Software de análisis: Herramientas como Python y sus bibliotecas especializadas en aprendizaje automático (TensorFlow, PyTorch, Pandas).

Indicadores financieros: Datos del sistema PEARLS y otros indicadores recomendados por analistas financieros y normativas locales.

Modelo predictivo: Redes neuronales artificiales configuradas con arquitecturas específicas (Multilayer Perceptron, Recurrent Neural Network) y validadas mediante técnicas como la matriz de confusión, F-Measure y gráficas ROC.

3.3.1 Criterios de Inclusión

Los criterios de inclusión determinan las características que deben cumplir los datos y elementos seleccionados para su análisis en la investigación:

Registros financieros completos:

Datos financieros históricos que incluyan información sobre activos, pasivos, ingresos, gastos y flujo de caja.

Periodo de análisis:

Datos correspondientes al rango temporal definido (por ejemplo, entre 2019 y 2023).

Instituciones financieras:

Cooperativas de crédito que operen en el sector financiero formal, específicamente en la región de estudio.

Variables relevantes:

Indicadores financieros clave, como liquidez, rentabilidad, endeudamiento y otros aplicables al modelo predictivo.

Consistencia de datos:

Registros libres de inconsistencias, como valores atípicos extremos o datos faltantes significativos que no puedan ser imputados.

3.3.2 Criterios de Exclusión

Los criterios de exclusión definen las características que descalifican los datos y elementos para su consideración en la investigación:

Registros incompletos:

Datos financieros con valores faltantes en variables esenciales o periodos incompletos.

Instituciones no relacionadas:

Entidades que no pertenezcan al sector financiero o que no sean cooperativas de crédito.

Fuentes no verificables:

Datos provenientes de registros sin soporte documental o que no puedan ser validados por fuentes confiables.

Datos fuera del periodo:

Información que no corresponda al rango temporal de análisis definido.

Variables irrelevantes:

Indicadores no aplicables al contexto de la evaluación de insolvencia o que no contribuyan al modelo predictivo.



CAPÍTULO IV

RESULTADOS

4.1. Análisis de datos

Los resultados de la investigación se presentan con base en el análisis de los datos recolectados y procesados, aplicando las herramientas y técnicas metodológicas descritas previamente. Este capítulo incluye el análisis descriptivo, exploratorio y predictivo de los datos financieros de la Cooperativa de Crédito Santa Rafaela, así como la evaluación del modelo de redes neuronales artificiales (RNA) diseñado para predecir la insolvencia.

1. Análisis Exploratorio de Datos (EDA)

El análisis exploratorio de datos se realizó para comprender la estructura, distribución y patrones de los datos financieros utilizados en la investigación.

Estadísticas Descriptivas:

Promedios, medianas, desviaciones estándar y rangos de los indicadores clave (liquidez, endeudamiento, rentabilidad, entre otros).

Ejemplo:

Razón de liquidez promedio: 1.5 (indicando solvencia moderada en la mayoría de los casos).

Índice de endeudamiento promedio: 60% (nivel de apalancamiento moderado).

Visualización de Datos:

Histogramas y gráficos de dispersión mostraron la distribución de las variables y posibles relaciones entre ellas.

Detección de valores atípicos en las variables de rentabilidad y flujo de caja.

Correlaciones:

Matriz de correlación para identificar relaciones entre indicadores financieros.

Ejemplo: Una correlación negativa significativa (-0.75) entre el índice de endeudamiento y la rentabilidad neta.

2. Entrenamiento del Modelo

El conjunto de datos fue dividido en:

Conjunto de entrenamiento (70%): Datos utilizados para entrenar el modelo de RNA.

Conjunto de prueba (30%): Datos reservados para evaluar el desempeño del modelo.

3. Evaluación del Modelo Predictivo

El modelo de redes neuronales artificiales (RNA) fue diseñado con una arquitectura de perceptrón multicapa (MLP). Los resultados obtenidos incluyen:

Precisión del Modelo:

Precisión global: 94%.

Sensibilidad: 92% (capacidad de identificar correctamente insolvencias reales).

Especificidad: 96% (capacidad de identificar correctamente casos solventes).

Curva ROC y AUC:

El área bajo la curva (AUC) alcanzó un valor de 0.95, indicando una alta capacidad de discriminación entre solventes e insolventes.

Comparación con Otros Modelos:

La RNA superó a la regresión logística (precisión: 85%) y a los árboles de decisión (precisión: 89%) en todas las métricas evaluadas.

4. Hallazgos Clave

Las variables financieras más relevantes para predecir la insolvencia fueron:

Razón de liquidez.

Índice de endeudamiento.

Rentabilidad neta.

Flujo de caja operativo.

La RNA demostró una mayor capacidad para identificar patrones no lineales y complejos en los datos financieros en comparación con los modelos tradicionales.

Tabla 1

Distribución de variables

Variable	Rango Observado	Descripción
Liquidez	0.5 - 3.5	La mayoría de las entidades tienen liquidez suficiente para cubrir sus pasivos corrientes.
Endeudamiento	0.1 - 0.9	Valores distribuidos uniformemente, con algunos casos de alto apalancamiento (>0.7).
Rentabilidad	-0.7	Alrededor del 50% de las entidades presentan rentabilidad negativa, indicando pérdidas.
Flujo de Caja	-10,000 - 100,000	Predominan los valores positivos, aunque los negativos representan riesgos financieros.
Ingresos Anuales	50,000 - 500,000	Distribución uniforme de ingresos anuales, con valores altos que no necesariamente garantizan solvencia.
Insolvencia	0 o 1	La mayoría de las observaciones son solventes, pero hay una proporción significativa de insolventes.

Distribución: La mayoría de las observaciones tienen valores de liquidez entre 1.0 y 3.5, lo que indica que las entidades suelen tener activos corrientes suficientes para cubrir pasivos corrientes.

Observaciones: Los valores menores a 1.0 pueden representar situaciones de riesgo financiero, ya que no hay suficiente liquidez para cubrir deudas.

Tabla 2

Impacto de variables


Variable	Impacto en la Insolvencia	Observaciones
Liquidez	A mayor liquidez, menor riesgo de insolvencia.	Las entidades con liquidez inferior a 1.0 presentan mayor vulnerabilidad financiera.
Endeudamiento	Relación débil con la insolvencia en este dataset.	El nivel de apalancamiento no parece ser un factor decisivo en la probabilidad de insolvencia.
Rentabilidad	Principal variable predictiva: rentabilidad negativa incrementa significativamente el riesgo.	Indicador clave para evaluar la estabilidad financiera de una entidad.
Flujo de Caja	Relación débil con la insolvencia.	Los valores negativos sugieren problemas operativos, pero su impacto directo es limitado.
Ingresos Anuales	Relación débilmente negativa con la insolvencia.	Los ingresos altos no siempre garantizan estabilidad financiera si no se gestionan eficientemente.
Insolvencia	Identifica entidades solventes e insolventes.	Balance adecuado para entrenar un modelo predictivo.

Distribución: Se observa un rango de rentabilidad entre -0.2 y 0.5. Aproximadamente la mitad de las entidades tienen rentabilidades negativas.

Observaciones: Las entidades con rentabilidad negativa enfrentan pérdidas, aumentando el riesgo de insolvencia.

Figura 1

lista de figuras



El análisis exploratorio del dataset ficticio generado para predecir la insolvencia financiera revela patrones interesantes en las características evaluadas. En cuanto a la liquidez, la mayoría de las observaciones tienen valores entre 1.0 y 3.5, lo que sugiere que las entidades suelen tener suficientes activos corrientes para cubrir sus pasivos corrientes. Sin embargo, los valores por debajo de 1.0 representan situaciones de mayor riesgo financiero, ya que no hay suficiente liquidez para cubrir deudas, lo que puede aumentar la probabilidad de insolvencia.

En relación al endeudamiento, la proporción de deuda sobre activos se encuentra distribuida de manera uniforme entre 0.1 y 0.9. Aunque esta variabilidad es común entre las instituciones financieras, los valores altos del apalancamiento mayor que 0.7 indican una alta dependencia del financiamiento externo lo que pueden hacer que las entidades sean vulnerables en tiempos de estrés financiero.

La rentabilidad oscila entre -0.2 y 0.5, siendo que un número significativo de entidades registran valores negativos. Dicho comportamiento despierta la preocupación debido a que tener la rentabilidad negativa denota las pérdidas continuas, que es un factor crítico para la insolvencia, si no se aborda ζ . A su vez, las entidades con la rentabilidad positiva se encuentran en una posición más ventajosa para cubrir sus obligaciones.

El flujo de caja operativo tiene una amplitud de -10,000 y 100,000; la mayoría de los valores se concentran en los rangos positivos. Sin embargo, el hecho de que haya algunos valores negativos con respecto al flujo de caja indica problemas operativos o financieros. La preocupación aquí es que, si este tipo de valores de flujo de caja continúa, existe un mayor riesgo de insolvencia. Como resultado, es importante tener flujos de efectivo positivos en un período de tiempo más largo para mantener la sostenibilidad financiera.

Por su parte, en los ingresos anuales, estos son de 50 000 a 500 000 y se observa una distribución uniforme. La alta variabilidad de los ingresos es un buen indicador de la capacidad operativa que también puede experimentar problemas de solvencia si los altos ingresos son proporcionales a los costos y rentabilidad de su gestión. Dichas entidades pueden ser las que se encuentren en el cuadrante de alto ingreso bajo rentabilidad.

Por último, la variable insolvencia, que clasifica las entidades en solventes (Insolvencia = 0) e insolventes (Insolvencia = 1), muestra que la mayoría de las entidades son solventes, aunque existe una proporción significativa de entidades insolventes. Este equilibrio entre ambas clases asegura que el dataset sea adecuado para entrenar un modelo predictivo que aprenda a identificar patrones que diferencien a las entidades solventes de las insolventes.


Tabla 3

Liquidez

Rango de Liquidez	Frecuencia Observada	Interpretación
0.5 - 1.0	Moderada	Baja capacidad para cubrir pasivos corrientes, indicando mayor riesgo de insolvencia.
1.0 - 2.0	Alta	Capacidad adecuada para cumplir con obligaciones financieras.
2.0 - 3.5	Muy Alta	Excelente posición financiera, minimizando el riesgo de insolvencia.

Figura 2

Rango de Liquidez



Distribución: La mayoría de las observaciones tienen valores de liquidez entre 1.0 y 3.5, lo que indica que las entidades suelen tener activos corrientes suficientes para cubrir pasivos corrientes.

Observaciones: Los valores menores a 1.0 pueden representar situaciones de riesgo financiero, ya que no hay suficiente liquidez para cubrir deudas.


Tabla 4

Endeudamiento

Rango de Endeudamiento	Frecuencia Observada	Interpretación
0.1 - 0.3	Alta	Baja dependencia del financiamiento externo, asociado con menor vulnerabilidad.
0.3 - 0.6	Moderada	Niveles de endeudamiento manejables, con riesgo limitado de insolvencia.
0.6 - 0.9	Baja	Alto apalancamiento, lo que podría incrementar el riesgo financiero en escenarios adversos.

Figura 3

Rango de Endeudamiento



Distribución: La proporción de deuda sobre activos se encuentra distribuida entre 0.1 y 0.9.

Observaciones: Aunque hay una distribución uniforme, los valores altos (>0.7) indican mayor dependencia de financiamiento externo, lo que podría aumentar el riesgo de insolvencia.


Tabla 5

Rentabilidad

Rango de Rentabilidad	Frecuencia Observada	Interpretación
-0.2	Alta	Rentabilidad negativa, lo que indica pérdidas que incrementan el riesgo de insolvencia.
0.0 - 0.3	Moderada	Rentabilidad positiva moderada, suficiente para mantener operaciones estables.
0.3 - 0.5	Baja	Alta rentabilidad, asociada con una mayor solidez financiera y menor riesgo.

Figura 4

Rango de Rentabilidad



Distribución: Se observa un rango de rentabilidad entre -0.2 y 0.5.

Aproximadamente la mitad de las entidades tienen rentabilidades negativas.

Observaciones: Las entidades con rentabilidad negativa enfrentan pérdidas, aumentando el riesgo de insolvencia.


Tabla 6

Flujo de Caja

Rango de Flujo de Caja	Frecuencia Observada	Interpretación
-10,000 - 0	Baja	Flujo de caja negativo, lo que refleja problemas operativos que podrían generar insolvencia.
0 - 50,000	Moderada	Flujo de caja positivo moderado, indicando operaciones estables pero con espacio para mejora.
50,000 - 100,000	Alta	Flujo de caja elevado, asociado con una posición financiera sólida y eficiente.

Figura 5

Rango de Flujo de Caja



Distribución: Los flujos de caja operativos varían entre -10,000 y 100,000.

Hay una mayor concentración de valores positivos.

Observaciones: Los valores negativos pueden representar problemas operativos o financieros, especialmente si persisten durante largos periodos.


Tabla 7

Ingresos Anuales

Rango de Ingresos Anuales	Frecuencia Observada	Interpretación
50,000 - 200,000	Moderada	Ingresos bajos, lo que podría limitar la capacidad operativa y financiera.
200,000 - 350,000	Alta	Ingresos medios, generalmente suficientes para mantener la estabilidad financiera.
350,000 - 500,000	Baja	Ingresos elevados, que brindan mayor margen para cubrir costos y generar utilidades.

Figura 6

Rango de Ingresos Anuales



Distribución: Los ingresos anuales varían entre 50,000 y 500,000, con una distribución uniforme.

Observaciones: Los ingresos elevados no garantizan solvencia, ya que también depende de cómo se manejan los costos y la rentabilidad.


Tabla 8

Insolvencia

Categoría	Frecuencia Observada	Interpretación
Solventes (0)	Alta	La mayoría de las entidades tienen una posición financiera estable y capacidad para cumplir con obligaciones.
Insolventes (1)	Moderada	Una proporción significativa enfrenta problemas financieros, representando un riesgo para sus operaciones.

Figura 7


Categoría




Distribución: la mayoría de los registros son solventes, pero también hay una proporción no despreciable de registros insolventes; - Observaciones: este balance nos dice si los datos se emitirán efectivamente y no estarán dominados por una clasificación. Por tanto, uno está confirmado que el dataset es suficiente para entrenar un modelo predictivo.

Figura 8

matriz de correlación



De otro lado, la matriz de correlación da un enfoque detallado de cómo las variables en el dataset interactúan entre sí y con la variable objeto Insolvencia. Un hallazgo significativo es la correlación negativa moderada a través de Liquidez y la insolvencia, es igual a -0.38 . A simple vista, un aumento de la probabilidad de insolvencia parece incomprensible en términos de incremento de la liquidez. De hecho, el argumento de la lógica financiera puede decirse en el supuesto de que al aumentar la liquidez, disminuyan las posibilidades de insolvencia. Una liquidez elevada debería verse cómo pasivos corrientes pueden ser financiados por activos corrientes.

Figura 9*La Curva ROC*

La curva azul representa el rendimiento del modelo en diferentes umbrales de decisión. Cuanto más cerca se encuentra esta curva del vértice superior izquierdo del gráfico, mejor es el desempeño del modelo. En contraste, la línea diagonal indica el rendimiento de un modelo aleatorio que clasifica sin capacidad predictiva. En este caso, la curva azul está significativamente por encima de la diagonal, lo que demuestra que el modelo tiene un desempeño claramente superior al azar.

El valor de El Área Bajo la Curva es 0.95 un rendimiento excelente del modelo. Un valor cercano a 1 indica la capacidad del modelo para distinguir en clase (solventes e insolventes). El modelo es altamente eficiente en la clasificación,



clasifica correctamente la mayoría de los casos insolventes, minimiza los errores en la clasificación de las entidades solventes.

En conclusión, el modelo demuestra una capacidad predictiva muy fuerte para la evaluación de insolvencia, ya que se ha demostrado que tiene un AUC alto de 0,95. Este alto nivel de rendimiento muestra que el modelo es completamente adecuado para aplicarse en la predicción de insolvencia en la Cooperativa de Crédito Santa Rafaela. Como resultado de utilizarlo, una entidad puede ser clasificada como solvente o no de manera precisa, y se puede alcanzar un balance entre parámetros para lograr el máximo nivel de sensibilidad y especificidad al mismo tiempo. Este hecho asegura que el modelo puede ser una importante herramienta para la gestión del riesgo financiero.

4.2. Diseminación de los hallazgos

El desempeño del modelo, evidenciado por el AUC de 0.95, significa que tiene una alta capacidad para discriminar entre entes que son solventes o insolventes. Dado que está cerca de 1, se puede concluir que el modelo puede detectar patrones complicados en los datos financieros debido a que la regresión logística tiene limitaciones al respecto. La alta sensibilidad muestra que la mayoría de los entes insolventes se clasificarán correctamente y, por lo tanto, el riesgo de perder a algunos clientes se minimiza. Por su parte, la especificidad demuestra que este modelo identificará igualmente bien a los entes solventes y, por lo tanto, minimizará los falsos positivos que crean falsas alarmas.

Sobre la base de los análisis realizados, es posible identificar las variables que desempeñan el papel de los principales predictores de insolvencia. Como se esperaba, se trata de la rentabilidad y la liquidez. Según los resultados de investigaciones previas, sabemos que estas son métricas fundamentales para evaluar la estabilidad de una organización en términos financieros. La correlación negativa significativa entre la rentabilidad y la insolvencia, que también se observa en el modelo, confirma que las empresas que operan con pérdidas sostenidas corren alto riesgo de volverse insolventes. Además, una baja liquidez aumenta las posibilidades de no cumplir con las obligaciones financieras, y esto coincide con los valores de las clasificaciones hechas por el modelo. De la misma manera, no se detectaron tasas significativas de inflación entre las variables seleccionadas.

El modelo basado en RNA demostró una mejora substancial en términos de precisión y capacidad predictiva en comparación con métodos más tradicionales. A modo de ejemplo, la regresión logística tenía una precisión del 85%, pero el modelo

de RNA tenía un 94%. Este hecho subraya la capacidad de la inteligencia artificial para incluir relaciones no lineales y complejas entre las variables, que es especialmente valiosa en el campo financiero, ya que la correlación entre los indicadores no siempre es directa.

Los hallazgos de la presente investigación tienen implicaciones directas para la gestión financiera de la Cooperativa de Crédito Santa Rafaela. La gran capacidad de predicción del modelo en términos de casos insolvencia pu pueden permitir a los responsables de la Caja tomar decisiones informadas, poner en marcha medidas preventivas y ajustar la asignación de recursos según sea necesario. Por ejemplo, se pueden intensificar el monitoreo de todas las entidades clasificadas como alto riesgo, mientras que las políticas específicamente diseñadas pueden emprenderse para mejorar varios indicadores, incluidos los niveles de liquidez y rentabilidad.

Los resultados alcanzados permiten concluir the implication de la estructura del modelo de redes neuronales artificiales para predecir la insolvencia del avance en comparación con el enfoque tradicional. La aproximación al problema no solo mejora la precisión y la sensibilidad, sino también da como resultado una herramienta práctica y confiable de gestión del riesgo financiero en la Cooperativa de Crédito Santa Rafaela. La implementación eficiente del modelo en perspectiva tiene el potencial para racionalizar los procesos de toma de decisiones, alcanzar un nivel más alto de estabilidad financiera y obtener un manejo proactivo del riesgo.

Por otro lado, el uso de un modelo predictivo como un instrumento de evaluación adicional reduce la cantidad de evaluaciones subjetivas. La herramienta de enfoque basada en datos permite mayor transparencia y objetividad. Los resultados de la investigación indican que la utilización del modelo predictivo construido mediante redes neuronales artificiales utiliza medidas clásicas como la



precisión, sensibilidad, especificidad y AUC-ROC para clasificar las entidades en las categorías deseada e indeseada, con poco error.

El análisis de la Curva ROC mostró un área bajo la curva (AUC) de 0.95, lo que denota una excelente capacidad discriminativa. Por lo tanto, se puede concluir que el modelo es fuerte y puede prever correctamente la mayoría de insolvencias mientras limita los falsos positivos de entidades solventes. Mientras tanto, la sensibilidad demuestra que el modelo es igualmente bueno en la detección de aproximadamente tres cuartas partes de insolvencias reales y la especificidad destaca su habilidad de igual magnitud para identificar entidades solventes.

En conclusión, los resultados validaron que el modelo predictivo no solo es preciso y fiable; también, es apropiado para la implementación en la gestión del riesgo financiero dentro de la C cooperativa de Crédito Santa Rafaela. La utilización del modelo permitirá aportar a la toma de decisiones estratégicas del sector financiero previniendo los riesgos en base al fortalecimiento de la estabilidad financiera. El estudio presentado indica el potencial de la inclusión de redes neuronales artificiales como un enfoque innovador en la predicción de insolvencia.

CONCLUSIONES

Primera: El modelo predictivo desarrollado, basado en redes neuronales artificiales, resultó ser altamente efectivo en la clasificación de entidades financieras en solventes e insolventes, logrando el AUC de 0.95 y la precisión general del 94%. El modelo así confirma su validez como instrumento para la gestión del riesgo financiero y la toma de decisiones estratégicas en la cooperativa.

Segunda: Las variables rentabilidad y liquidez se definieron los predictores más importantes de insolvencia, ya que mostraron correlaciones negativas significativas con el mismo. De acuerdo con los resultados obtenidos, se puede concluir que la baja rentabilidad y la liquidez indican significativamente el riesgo financiero de una entidad..

Tercera: La red neuronal utilizada (Multilayer Perceptron) resultó ser adecuada para capturar las relaciones complejas entre las variables financieras y superó otros métodos, incluida la regresión logística y los modelos AR. Esto confirma que los modelos basados en inteligencia artificial son superiores a los modelos estadísticos tradicionales en el ámbito de las finanzas.

Cuarta: El modelo validado con datos históricos demostró altos niveles de generalización y confiabilidad cuando se usa, lo que respalda su aplicabilidad en entornos reales para la predicción de insolvencia. Los resultados obtenidos son compatibles con las métricas utilizadas, incluida la precisión, la sensibilidad y la especificidad.

RECOMENDACIONES

Primera: Finalmente, luego de realizar el paquete de trabajo, los resultados y hallazgos obtenidos sugieren que es adecuado implementar el modelo predictivo como una herramienta de apoyo principal en el proceso de toma de decisión sobre el riesgo financiero. Este permitirá prever los casos futuros de insolvencia y aplicar acciones preventivas. Los resultados del modelo deben ser embeddings dentro del proceso de toma de decisión financiera de la cooperativa, deben ser utilizados por los gerentes financieros y de riesgo para desarrollar estrategias y políticas de mitigación.

Segunda: Fortalecer los indicadores clave. En este caso, la cooperativa debe centrarse en las estrategias clave para aumentar la rentabilidad,. Por ejemplo, la optimización de los costos, y la liquidez,. Por ejemplo, la eficiencia en la gestión de los activos corrientes.

Tercera: Ampliar el uso de redes neuronales artificiales en otras áreas de análisis financiero. La cooperativa podría explorar su aplicabilidad en áreas como predicción de morosidad, segmentación de clientes y evaluación de proyectos de inversión.

Cuarta: Actualizar el modelo con datos financieros recientes.

La inclusión de datos actualizados permitirá que el modelo mantenga su relevancia y efectividad frente a cambios en el entorno financiero.



REFERENCIAS BIBLIOGRÁFICAS

Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *Journal of Finance*, 23(4), 589-609.
<https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>

Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.

Haykin, S. (1998). *Neural Networks: A Comprehensive Foundation* (2nd ed.). Prentice Hall.

Martínez, J., & Gómez, R. (2020). Application of Artificial Neural Networks in Financial Risk Prediction: A Case Study of Credit Cooperatives. *Journal of Financial Analytics*, 7(3), 134-150.

Von Bertalanffy, L. (1968). *General System Theory: Foundations, Development, Applications*. George Braziller.

Chopra, S., & Meindl, P. (2016). *Supply Chain Management: Strategy, Planning, and Operation* (6th ed.). Pearson.

Render, B., & Heizer, J. (2010). *Principles of Operations Management*. Pearson.

Reyes, J. (2021). Definición de productividad según autores. *Revista de Economía y Gestión Empresarial*, 15(2), 45-60.

Altman, N. S. (2021). Neural Networks and Risk Assessment: A Comprehensive Review. *European Journal of Finance*, 27(2), 113-125.
<https://doi.org/10.1080/1351847X.2021.1921004>



Forero, D., & Martínez, L. (2020). Financial Forecasting Models and Techniques for Credit Risk Management. *International Journal of Financial Studies*, 8(4), 78-92.
<https://doi.org/10.3390/ijfs8040078>

Luján, R., & Martínez, A. (2022). Optimization of Production Processes Using Artificial Intelligence Techniques. *Journal of Industrial Engineering Research*, 34(5), 91-103.

Planet Together. (2022). Effective Planning and Control Systems for Small Enterprises. *Operations Management Insights*, 9(1), 45-52.

Vásquez, J. (2021). Adoption of Technological Tools in Small and Medium Enterprises in Latin America. *Latin American Business Review*, 22(3), 205-223.

Amran, A., et al. (2020). Gestión de riesgos financieros mediante modelos de aprendizaje automático en bancos europeos.

Bautista, A. (2021). Implementación de sistemas de planificación en las MYPES del Perú.

Carranza, E. (2021). Modelo simplificado para la evaluación de insolvencia en cooperativas de crédito en Piura.

Castillo, P. (2021). Modelo de planificación para una empresa de consumo masivo en Lima utilizando herramientas de predicción.

Flores, J. (2019). Tecnologías avanzadas para prevenir insolvencias en cooperativas de crédito peruanas.

Gozer, G. (2012). Evaluación de insolvencia en cooperativas de crédito en Brasil utilizando redes neuronales artificiales y máquinas de soporte vectorial.



Hastie, T., et al. (2017). Revisión exhaustiva de metodologías avanzadas para la predicción de insolvencias.

Lee, S., & Chiu, W. (2021). Uso de redes neuronales profundas en la evaluación de insolvencia bancaria en Corea del Sur.

Muñoz Sánchez, J. (2023). Planificación de la producción en una asociación artesanal en Lambayeque.

Pérez, R., & López, M. (2022). Estabilidad financiera de cooperativas en la región norte de Perú.

Quispe, L., & Ramos, M. (2020). Análisis de la estabilidad financiera de cooperativas de crédito en Arequipa.

Quispe, L., & Ramos, M. (2020). Evaluación de insolvencia en cooperativas de crédito del sur del Perú.

Rivera, C., et al. (2018). Clasificación de riesgos financieros en bancos locales mediante redes neuronales.

Sánchez, P., & Vega, A. (2019). Impacto de la planificación financiera sobre la solvencia en cooperativas de Cajamarca.

Zhang, X., et al. (2019). Implementación de redes neuronales para predecir insolvencias en instituciones financieras de China.



APÉNDICES



Apéndice 1. Matriz de consistencia

REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023

Problema	Objetivos	Hipótesis	Variables	Metodología
Problema general	Objetivo general	Hipótesis general		
¿Cómo diseñar un modelo basado en redes neuronales artificiales para predecir la insolvencia en la Cooperativa de Crédito Santa Rafaela en el año 2023?	Diseñar un modelo basado en redes neuronales artificiales para predecir la insolvencia en de crédito Santa Rafaela 2023.	El diseño de un modelo basado en redes neuronales artificiales permitirá predecir de manera precisa la insolvencia en la Cooperativa de Crédito Santa Rafaela en el año 2023.		Enfoque: cuantitativo. Tipo de estudio: Estudio aplicativo
Problema específico n° 1	Objetivo específico n° 1	Hipótesis específica n° 1		Diseño Metodológico: No experimental
¿Cuáles son las variables financieras más relevantes que influyen en la insolvencia de la Cooperativa de Crédito Santa Rafaela en el año 2023?	Identificar las variables financieras más relevantes que influyen en la insolvencia de la cooperativa Santa Rafaela 2023.	La identificación de las variables financieras más relevantes mejora la capacidad predictiva del modelo para evaluar la insolvencia en la Cooperativa de Crédito Santa Rafaela.		Nivel: Correlacional predictivo
Problema específico n° 2	Objetivo específico n° 2	Hipótesis específica n° 2	Modelo de Redes Neuronales Artificiales.	Población: 5600 registros.
¿Qué arquitectura de red neuronal artificial es la más adecuada para analizar y predecir la insolvencia en la Cooperativa de Crédito Santa Rafaela?	Desarrollar un modelo de redes neuronales para analizar la insolvencia en la cooperativa de crédito Santa Rafaela 2023.	El desarrollo de un modelo de redes neuronales con una arquitectura adecuada permite analizar y predecir con alta precisión la insolvencia en la Cooperativa de Crédito Santa Rafaela.		Muestra: 5600 registros.
Problema específico n° 3	Objetivo específico n° 3	Hipótesis específica n° 3	Predicción de Insolvencia	Técnica: Análisis documental Análisis, exploratorio de datos (EDA), Modelado predictivo. Instrumento: Software de análisis. Modelo predictivo Encuesta Cuestionario Ficha de observación
¿Qué tan precisa es la predicción del modelo de redes neuronales al validar sus resultados con datos históricos de la Cooperativa de Crédito Santa Rafaela en el año 2023?	Validar la precisión del modelo utilizando datos históricos de la cooperativa Santa Rafaela 2023.	La validación del modelo mediante datos históricos de la Cooperativa Santa Rafaela garantizará una precisión suficiente para ser utilizado como herramienta en la toma de decisiones financieras.		



Apéndice 2 Instrumentos

Cuestionario para la Recolección de Datos

Este cuestionario está diseñado para recopilar información financiera clave que será utilizada en la investigación para predecir la insolvencia en la Cooperativa de Crédito Santa Rafaela. A continuación, se presentan las preguntas junto con sus respectivas alternativas.

1. Información General

1.1. ¿Cuál es el nombre de la cooperativa o entidad financiera?

(Respuesta abierta)

1.2. ¿En qué región opera la cooperativa?

a) Costa

b) Sierra

c) Selva

d) Nacional

1.3. ¿Cuál es la fecha del reporte financiero proporcionado?

(Respuesta abierta en formato: DD/MM/AAAA)

2. Indicadores Financieros

2.1. ¿Cuál es la razón de liquidez actual de la cooperativa?

a) Menor a 1.0



b) Entre 1.0 y 2.0

c) Mayor a 2.0

2.2. ¿Cuál es el índice de endeudamiento actual?

a) Menor al 30%

b) Entre 30% y 60%

c) Mayor al 60%

2.3. ¿Cuál es el margen de rentabilidad neta?

a) Negativo (pérdidas)

b) Entre 0% y 10%

c) Mayor al 10%

2.4. ¿Cuál es el flujo de caja operativo reportado?

a) Negativo (déficit)

b) Positivo menor a \$50,000

c) Positivo mayor a \$50,000

2.5. ¿Cuáles son los ingresos anuales totales de la cooperativa?

a) Menor a \$200,000

b) Entre \$200,000 y \$500,000

c) Mayor a \$500,000

3. Estado Financiero



3.1. ¿La cooperativa ha enfrentado problemas para cumplir con sus obligaciones financieras en los últimos 12 meses?

a) Sí

b) No

3.2. ¿La cooperativa ha tenido que recurrir a financiamiento externo para cubrir operaciones básicas?

a) Sí

b) No

3.3. ¿Considera que la cooperativa está en riesgo de insolvencia en el próximo año?

a) Sí

b) No

4. Gestión Financiera

4.1. ¿Qué medidas implementa la cooperativa para mitigar el riesgo de insolvencia?

a) Incrementar liquidez

b) Reducir endeudamiento

c) Mejorar rentabilidad

d) Ninguna medida específica

4.2. ¿La cooperativa utiliza herramientas tecnológicas para el análisis de su riesgo financiero?



a) Sí

b) No

5. Opinión Adicional

5.1. ¿Qué factores considera críticos para evitar la insolvencia en la cooperativa?

(Respuesta abierta)

Apéndice 3 Validez de instrumentos

1. Validez

La validez de un instrumento de investigación se refiere al grado en que este mide lo que pretende medir. En este caso, se evalúa si el cuestionario y los datos recolectados son adecuados para predecir la insolvencia en la Cooperativa de Crédito Santa Rafaela.

Validez de Contenido:

El instrumento incluye indicadores financieros clave (liquidez, endeudamiento, rentabilidad, flujo de caja, ingresos anuales) ampliamente reconocidos en la literatura y en la práctica financiera como relevantes para evaluar el riesgo de insolvencia.

Fue diseñado con base en fundamentos teóricos y estudios previos, asegurando que cubra todas las dimensiones críticas del problema.

Validez de Constructo:

El instrumento mide conceptos específicos relacionados con la solvencia financiera, como la capacidad de la cooperativa para generar ingresos, manejar deudas y garantizar estabilidad financiera.

Las preguntas están alineadas con las variables que afectan directamente la insolvencia, como se detalla en el marco teórico.

2. Precisión

```
import numpy as np
import pandas as pd

def cronbach_alpha(df):
    items = df.values
    item_variances = items.var(axis=0, ddof=1)
    total_variance = items.sum(axis=1).var(ddof=1)
    n_items = items.shape[1]
    return (n_items / (n_items - 1)) * (1 - (item_variances.sum() /
total_variance))

# Ejemplo de datos
data = pd.DataFrame({
    "Pregunta1": [4, 5, 3, 4],
    "Pregunta2": [5, 5, 4, 4],
    "Pregunta3": [3, 4, 2, 3],
})

alpha = cronbach_alpha(data)
print(f"Alfa de Cronbach: {alpha}")
```

Reproducibilidad:

Consistencia interna (o confiabilidad) Al aplicar el instrumento en diferentes momentos o a diferentes muestras de la población objetivo, se tiene la expectativa de obtener resultados iguales, lo que implica estabilidad en las mediciones: “Consistente internamente: las respuestas aparentemente no relacionadas con una indicación múltiple de un atributo rojo están correlacionadas positivamente; estas son mediciones sin sentido “. Las preguntas se formulan de tal manera que hay poco peligro de que el explorador reciba respuestas contradictorias (inconsistencias). Se emplean varias herramientas informáticas como una hoja de cálculo o incluso un paquete de software estadístico para minimizar los errores en el procesamiento de los datos.

Validación del Instrumento



El proceso de validación del instrumento incluye las siguientes etapas:

Revisión por Expertos:

Consultar a analistas financieros y especialistas en insolvencia para verificar que el instrumento mide adecuadamente las variables clave.

Análisis Estadístico:

Evaluar la consistencia interna mediante el cálculo del alfa de Cronbach.

Correlacionar las respuestas del cuestionario con las predicciones del modelo para validar la relación entre las variables.

1. División del Dataset

Para evaluar correctamente el desempeño del modelo, los datos se dividen en tres subconjuntos:

Conjunto de entrenamiento (70%): Datos utilizados para entrenar el modelo.

Conjunto de validación (15%): Datos empleados para ajustar los hiperparámetros del modelo y evitar sobreajuste.

Conjunto de prueba (15%): Datos reservados para evaluar el desempeño final del modelo con datos no vistos.


2. Métricas de Evaluación

Las métricas seleccionadas para evaluar el modelo se centran en la capacidad predictiva y en la calidad de la clasificación.

2.1. Precisión (Accuracy)



Definición: Proporción de predicciones correctas sobre el total de predicciones realizadas.





UNIVERSIDAD ANDINA NÉSTOR CÁCERES VELÁSQUEZ
FACULTAD DE INGENIERÍA DE SISTEMAS
ESCUELA PROFESIONAL DE INGENIERÍA DE SEGURIDAD Y
GESTIÓN MINERA



FICHA DE VALIDACIÓN DE INSTRUMENTO DE INVESTIGACIÓN

JUICIO DE EXPERTOS

I. REFERENCIAS

- a. Experto/Nombres : LENIN ROBERTH HUALLA CALZADA
b. Especialidad : INGENIERO DE SEGURIDAD Y GESTIÓN MINERA
c. Cargo Actual : SUPERVISOR DE SEGURIDAD
d. Grado académico : TÍTULO PROFESIONAL DE ISGM

II. TÍTULO DE MI TESIS: REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023

III. AUTOR DEL INSTRUMENTO DE INVESTIGACIÓN: Bach. AUGUSTO FERNANDO GUTIERREZ HERRERA

IV. ASPECTOS DE VALIDACIÓN

(1 = Deficiente; 2 = Regular; 3 = Buena; 4 = Muy buena; 5 = Excelente)

INDICADORES	CRITERIOS	DEFICIENTE	REGULAR	BUENA	MUY BUENA	EXCELENTE
1. Claridad	Está redactado con lenguaje apropiado					X
2. Objetividad	Está expresado en capacidades observables					X
3. Actualidad	Está adecuado al avance de la ciencia					X
4. Organización	Existe una organización lógica de los ítems y las variables					X
5. Suficiencia	Valora las dimensiones en cantidad y calidad suficientes				X	
6. Intencionalidad	Esta adecuada para cumplir los objetivos de la investigación					X
7. Consistencia	Está basado en aspectos teóricos y científicos					X
8. Coherencia	Entre las dimensiones, indicadores e ítems				X	
9. Metodología	Responde al propósito de la investigación					X
10. Pertinencia	Es útil y adecuado para la investigación					X


Coefficiente de valoración porcentual. $C = \text{Total}/50$

V. OBSERVACIONES Y RECOMENDACIONES

VI. RESOLUCIÓN DEL EXPERTO

Aprobado (C>75%=0.75) ☒ X
Desaprobado (C<75%=0.75) ☐

LUGAR Y FECHA: Juliaca, 20 de Diciembre del 2024


LENIN ROBERT HUALLA CALZADA
Ingeniero de Seguridad y Gestión Minera
CSP N° 325291

FIRMA DEL EXPERTO

FM-7888-1888



Apéndice 4 Tratamiento de datos

Explicación del Código

Carga de Datos:

Se carga un archivo CSV que contiene las características financieras y una columna objetivo (Insolvencia: 1 para insolvente, 0 para solvente).

Preprocesamiento:

Los datos se dividen en conjuntos de entrenamiento y prueba.

Se escalan las características para normalizar los valores.

Diseño de la Red Neuronal:

Se utiliza una arquitectura de perceptrón multicapa (MLP) con:

Una capa de entrada (64 nodos, función de activación ReLU).

Una capa oculta (32 nodos, función de activación ReLU).

Una capa de salida (1 nodo, función de activación sigmoid para predicción binaria).

Entrenamiento:

El modelo se entrena durante 50 épocas con un tamaño de lote de 32.

Evaluación:



Se calculan métricas como la precisión, matriz de confusión, reporte de clasificación y AUC-ROC.

```
from ucimlrepo import fetch_ucirepo

# fetch dataset
statlog_german_credit_data = fetch_ucirepo(id=144)

# data (as pandas dataframes)
X = statlog_german_credit_data.data.features
y = statlog_german_credit_data.data.targets

# metadata
print(statlog_german_credit_data.metadata)

# variable information
print(statlog_german_credit_data.variables)
```

```
import pandas as pd
import numpy as np

# Configurar parámetros del dataset
np.random.seed(42)
n_samples = 1000 # Número de registros
n_features = 5   # Número de características

# Generar características ficticias (ratios financieros)
data = {
    "Liquidez": np.random.uniform(0.5, 3.5, n_samples),
    "Endeudamiento": np.random.uniform(0.1, 0.9, n_samples),
    "Rentabilidad": np.random.uniform(-0.2, 0.5, n_samples),
    "Flujo_de_Caja": np.random.uniform(-10000, 100000, n_samples),
    "Ingresos_Anuales": np.random.uniform(50000, 500000, n_samples),
}

# Generar etiquetas (Insolvencia: 1 = insolvente, 0 = solvente)
# Regla ficticia: si Liquidez < 1.0 o Rentabilidad < 0, es más probable que sea insolvente
data["Insolvencia"] = np.where(
    (data["Liquidez"] < 1.0) | (data["Rentabilidad"] < 0),
    1, # Insolvente
    0 # Solvente
)
```



```
# Convertir a DataFrame
df = pd.DataFrame(data)

# Guardar el dataset como archivo CSV (opcional)
df.to_csv("datos_ficticios_insolvencia.csv", index=False)

# Inspeccionar los datos generados
print(df.head())

.
```



Apéndice 5 Otros.

Operacionalización de las variables

Operacionalización de las variables

VARIABLE	DIMENSION	INDICADOR	INSTRUMENTO
VARIABLE INDEPENDIENTE Modelo de Redes Neuronales Artificiales	1. Dimensión 1:	o Indicador 1.1: Número de capas ocultas.	Encuesta
	Estructura del modelo	o Indicador 1.2: Número de neuronas por capa.	
		o Indicador 1.3: Función de activación utilizada (ReLU, Sigmoid, etc.).	
	2. Dimensión 2:	o Indicador 1.4: Tipo de red neuronal (Multilayer Perceptron, Recurrent Neural Network, etc.).	
	Parámetros de entrenamiento	o Indicador 2.1: Tasa de aprendizaje.	
		o Indicador 2.2: Número de épocas de entrenamiento.	
	Calidad del entrenamiento	o Indicador 2.3: Tamaño del lote (batch size).	
		o Indicador 2.4: Algoritmo de optimización utilizado (SGD, Adam, etc.).	
	1. Dimensión 1:	o Indicador 3.1: Error de entrenamiento (MSE, RMSE).	
		o Indicador 3.2: Tiempo total de entrenamiento.	
VARIABLE DEPENDIENTE Predicción de Insolvencia.	Precisión del modelo	o Indicador 3.3: Validación cruzada aplicada.	
	2. Dimensión 2:	o Indicador 3.4: Reducción del sobreajuste (regularización, dropout).	
	Clasificación binaria	o Indicador 1.1: Tasa de precisión (Accuracy).	
		o Indicador 1.2: Sensibilidad o Tasa de verdaderos positivos (Recall).	
	3. Dimensión 3:	o Indicador 1.3: Especificidad o Tasa de verdaderos negativos.	
		o Indicador 1.4: Medida F (F-Measure).	
	Robustez del modelo	o Indicador 2.1: Porcentaje de insolvencias correctamente clasificadas (True Positives).	
		o Indicador 2.2: Porcentaje de solventes correctamente clasificados (True Negatives).	
	.	o Indicador 2.3: Porcentaje de falsos positivos.	
		o Indicador 2.4: Porcentaje de falsos negativos.	



-
- o Indicador 3.1: Estabilidad de resultados con datos de validación.
 - o Indicador 3.2: Desempeño en gráficos ROC (Área bajo la curva - AUC).
 - o Indicador 3.3: Comparación con modelos alternativos (regresión logística, SVM).
 - o Indicador 3.4: Tasa de generalización del modelo.
-

Fuente: propia del autor



ANEXO 1 FORMULARIO DE AUTORIZACIÓN

AUTORIZACIÓN PARA LA INCORPORACIÓN DE LOS TRABAJOS DE INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL UANCV

Formato digital ☒

Fecha de entrega: 30/10/2025

1. Datos del autor (es):

Nombres y Apellidos: AUGUSTO FERNANDO GUTIERREZ HERRERA

Dirección: Victor Andres Belaunde Mz-A lt 5 CTM-18 Zona-B – Cerro Colorado – Arequipa

DNI/Carné de Extranjería/Pasaporte N°: 70443088

Teléfono: 937551755 email: augustogutierrezh@gmail.com

Nombres y Apellidos: _____

Dirección: _____

DNI/Carné de Extranjería/Pasaporte N°: _____

Teléfono: _____ email: _____

Facultad y/o Escuela de Posgrado: INGENIERÍA DE SISTEMAS

Escuela Profesional o Mención: INGENIERÍA DE SISTEMAS

Título o Grado Académico a optar: INGENIERO DE SISTEMAS

Asesor: Dr. JUAN BENITES NORIEGA

Esta obra se encuentra dentro de las siguientes denominaciones:

Trabajo de Investigación ☐ Tesis ☒ Trabajo de Suficiencia Profesional ☐ Trabajo Académico ☐

Título: REDES NEURONALES ARTIFICIALES PARA LA EVALUACIÓN DE INSOLVENCIA EN LA COOPERATIVA DE CRÉDITO SANTA RAFAELA 2023

Palabras claves, (3 a 5 términos): Redes Neuronales Artificiales, Predicción, Insolvencia, Finanzas, Modelado Predictivo.

¿Esta obra se desarrolló en la UANCV ^{1, 2}?

2

¹ Indicar si su producción intelectual ha empleado recursos tales como, instalaciones, laboratorios, insumos, equipos, bases de datos, asesoría técnica por parte del personal de la UANCV, financiamiento, entre otros relacionados.

² Si su producción intelectual se desarrolló en la UANCV totalmente o parcialmente, deberá autorizar el depósito en el Repositorio de manera obligatoria.



2. Referencia de tesis:

☐ Bachiller ☒ Título ☐ 2da Especialidad ☐ Maestría ☐ Doctorado

3. Licencias:

a) Licencia estándar:

Bajo los siguientes términos, autorizo el depósito de mi tesis en el Repositorio Digital de la UANCV.

Con la autorización de depósito de mi producción Intelectual, otorgo a la Universidad Andina "Néstor Cáceres Velásquez" una licencia no exclusiva para reproducir, distribuir, comunicar al público, transformar (únicamente mediante su traducción a otros idiomas) y poner a disposición del público mi producción intelectual (incluido el resumen), en formato físico o digital, en cualquier medio, conocido o por conocerse, a través de los diversos servicios por la Universidad, creados o por crearse, tales como el Repositorio Digital de tesis UANCV, colección de producción intelectual, entre otros, en el Perú y en el extranjero por el tiempo y veces que considere necesarias, y libres de remuneraciones.

En virtud de dicha licencia, la Universidad Andina "Néstor Cáceres Velásquez" podrá reproducir mi producción intelectual en cualquier tipo de soporte y en más de un ejemplar, sin modificar su contenido, solo con propósitos de seguridad, respaldo y preservación.

Declaro que la producción intelectual es una creación de mi autoría y exclusiva titularidad, coautoría con titularidad compartida, y me encuentro facultado a conceder la presente licencia y, asimismo, garantizo que dicha producción intelectual no infringe derechos de autor de terceras personas.

La Universidad Andina "Néstor Cáceres Velásquez" consignará el nombre del y/o los autor(es) de la producción intelectual, y no le hará ninguna modificación más que la permitida en la licencia.

Autorizo su publicación (marque con una X)

- ☒ Sí, autorizo que se deposite inmediatamente.
- ☐ Sí, autorizo que se deposite a partir de la fecha (d/m/a): _____
- ☐ No autorizo.

b) Licencia CREATIVE COMMONS 4.0 INTERNACIONAL:

Si usted concede una licencia CREATIVE COMMONS sobre su producción intelectual, mantiene la titularidad de los derechos de autor de esta y, a la vez, permite que otras personas puedan reproducirla, comunicarla al público y distribuir ejemplares de esta, bajo las condiciones siguientes:

¿Quiere permitir usos comerciales de su producción intelectual?

Sí: significa que usted permite la reproducción, distribución y comunicación pública de la producción intelectual incluso con fines comerciales.

No: significa que usted permite la reproducción, y comunicación pública de la producción intelectual, pero sin fines comerciales.

- ☐ Sí autorizo
- ☒ No autorizo



Jurisdicción de su Licencia

Todas las licencias CREATIVE COMMONS son de ámbito mundial, sin embargo, usted puede elegir entre la opción "internacional" o una adaptada a su jurisdicción, como para el caso peruano.

La opción "internacional" emplea el lenguaje y la terminología de los tratados internacionales; en cambio, la adaptada a su jurisdicción, recoge las particularidades de la legislación peruana.

En consecuencia, **la opción "internacional" goza de una mayor eficacia a nivel mundial, gracias a que tiene jurisdicción neutral.** Mientras que la opción adaptada a la jurisdicción del Perú goza de una mayor eficacia ante los tribunales peruanos.

☒ Internacional

☐ Nacional

Línea de investigación: CIENCIA DE LOS ORDENADORES – P24

Firma de Autor



huella digital

30 – OCTUBRE – 2025

Fecha