



**UNAP**



**FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA**

**MAESTRÍA EN INGENIERÍA DE SISTEMAS CON MENCIÓN EN  
GERENCIA DE LA INFORMACIÓN Y GESTIÓN DE SOFTWARE**

**TRABAJO DE INVESTIGACIÓN**

**REDES NEURONALES ARTIFICIALES PARA PRONOSTICAR EL  
RENDIMIENTO ACADÉMICO DE ALUMNOS DE INGENIERÍA  
DE SISTEMAS E INFORMÁTICA DE LA UNIVERSIDAD  
NACIONAL DE LA AMAZONÍA PERUANA**

**PARA OPTAR EL GRADO ACADÉMICO DE MAESTRO EN INGENIERÍA  
DE SISTEMAS CON MENCIÓN EN GERENCIA DE LA INFORMACIÓN Y  
GESTIÓN DE SOFTWARE**

**PRESENTADO POR: JORGE PUGA DE LA CRUZ**

**RONY TORRES MONZON**

**ASESORES: ING. IND. CARLOS ALBERTO GARCIA CORTEGANO, DR.**

**ING. ELECT. ALEJANDRO REATEGUI PEZO, DR.**

**IQUITOS, PERÚ**

**2023**



**UNAP**



**FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA**

**MAESTRÍA EN INGENIERÍA DE SISTEMAS CON MENCIÓN EN  
GERENCIA DE LA INFORMACIÓN Y GESTIÓN DE SOFTWARE**

**TRABAJO DE INVESTIGACIÓN**

**REDES NEURONALES ARTIFICIALES PARA PRONOSTICAR EL  
RENDIMIENTO ACADÉMICO DE ALUMNOS DE INGENIERÍA  
DE SISTEMAS E INFORMÁTICA DE LA UNIVERSIDAD  
NACIONAL DE LA AMAZONÍA PERUANA**

**PARA OPTAR EL GRADO ACADÉMICO DE MAESTRO EN INGENIERÍA  
DE SISTEMAS CON MENCIÓN EN GERENCIA DE LA INFORMACIÓN Y  
GESTIÓN DE SOFTWARE**

**PRESENTADO POR: JORGE PUGA DE LA CRUZ**

**RONY TORRES MONZON**

**ASESORES: ING. IND. CARLOS ALBERTO GARCIA CORTEGANO, DR.**

**ING. ELECT. ALEJANDRO REATEGUI PEZO, DR.**

**IQUITOS, PERÚ**

**2023**



**UNAP**

**Escuela de Postgrado**  
**"Oficina de Asuntos**  
**Académicos"**

**ACTA DE SUSTENTACIÓN DE TRABAJO DE INVESTIGACIÓN**  
**N° 057-2023-OAA-EPG-UNAP**

En Iquitos, en el auditorio de la Escuela de Postgrado (EPG) de la Universidad Nacional de la Amazonía Peruana (UNAP), a los cinco días del mes de mayo de 2023 a horas 11:00 a.m., se dió inicio a la sustentación del trabajo de investigación denominado "REDES NEURONALES ARTIFICIALES PARA PRONOSTICAR EL RENDIMIENTO ACADÉMICO DE ALUMNOS DE INGENIERÍA DE SISTEMAS E INFORMÁTICA DE LA UNIVERSIDAD NACIONAL DE LA AMAZONÍA PERUANA", aprobado con Resolución Directoral N°0490-2023-EPG-UNAP, presentado por los egresados JORGE PUGA DE LA CRUZ Y RONY TORRES MONZON, para optar el Grado Académico de Maestro en Ingeniería de Sistemas con mención en Gerencia de la Información y Gestión de Software, que otorga la UNAP de acuerdo a la Ley Universitaria N° 30220 y el Estatuto de la Universidad Nacional de la Amazonía Peruana.

El jurado calificador designado mediante Resolución Directoral N°0448-2023-EPG-UNAP, está conformado por los profesionales siguientes:

Lic. Educ. Ángel Enrique López Rojas, Dr.	(Presidente)
Ing. Sist. Jimmy Max Ramírez Villacorta, Mtro.	(Miembro)
Ing. Sist. Christian Alfredo Arévalo Jesús, Mtro.	(Miembro)

Después de haber escuchado la sustentación y luego de formuladas las preguntas, éstas fueron respondidas: Correctamente

Finalizado la evaluación; se invitó al público presente y a los sustentantes abandonar el recinto; y, luego de una amplia deliberación por parte del jurado, se llegó al resultado siguiente:

La sustentación pública y el trabajo de investigación han sido: Aprobado con calificación 19 (Diecinueve)

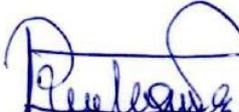
A continuación, el Presidente del Jurado da por concluida la sustentación, siendo las 11:50 del cinco de mayo del 2023; con lo cual, se les declara a los sustentantes Aptos, para recibir el Grado Académico de Maestro en Ingeniería de Sistemas con mención en Gerencia de la Información y Gestión de Software.

  
Lic. Educ. Ángel Enrique López Rojas, Dr.  
Presidente

  
Ing. Sist. Jimmy Max Ramírez Villacorta, Mtro.  
Miembro

  
Ing. Sist. Christian Alfredo Arévalo Jesús, Mtro.  
Miembro

  
Ing. Ind. Carlos Alberto García Cortegano, Dr.  
Asesor

  
Ing. Electrón. Alejandro Reategui Pezo, Dr.  
Asesor

Somos la Universidad licenciada más importante de la Amazonía del Perú, rumbo a la acreditación

Calle Los Rosales cuadra 5 s/n, San Juan Bautista, Maynas, Perú  
Teléfono: (5165) 261101 Correo electrónico: [postgrado@unapiquitos.edu.pe](mailto:postgrado@unapiquitos.edu.pe) [www.unapiquitos.edu.pe](http://www.unapiquitos.edu.pe)



TRABAJO DE INVESTIGACIÓN APROBADO EN SUSTENTACIÓN PÚBLICA EL 05 DE MAYO DEL 2023, EN EL AUDITORIO DE LA ESCUELA DE POSTGRADO DE LA UNIVERSIDAD NACIONAL DE LA AMAZONIA PERUANA, EN LA CIUDAD DE IQUITOS – PERÚ.



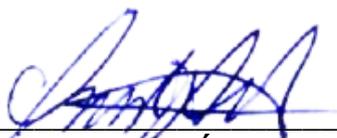
---

**LIC. EDUC. ÁNGEL ENRIQUE LÓPEZ ROJAS. DR.  
PRESIDENTE**



---

**ING. SIST. JIMMY MAX RAMÍREZ VILLACORTA, MTRO.  
MIEMBRO**



---

**ING. CHRISTIAN ALFREDO ÁREVALO JESÚS, MTRO  
MIEMBRO**



---

**ING. IND. CARLOS ALBERTO GARCÍA CORTEGANO, DR.  
ASESOR**



---

**ING. ELECTRÓN. ALEJANDRO REATEGUI PEZO, DR.  
ASESOR**

NOMBRE DEL TRABAJO

**TRAB DE INV\_MAESTRÍA\_DE LA CRUZ J  
ORGE PUGA\_RONY TORRES MONZON.pdf**

RECuento DE PALABRAS

**8493 Words**

RECuento DE CARACTERES

**45612 Characters**

RECuento DE PÁGINAS

**40 Pages**

TAMAÑO DEL ARCHIVO

**927.3KB**

FECHA DE ENTREGA

**Mar 3, 2023 9:14 AM GMT-5**

FECHA DEL INFORME

**Mar 3, 2023 9:15 AM GMT-5**

● **22% de similitud general**

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base c

- 19% Base de datos de Internet
- Base de datos de Crossref
- 12% Base de datos de trabajos entregados
- 7% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossr

● **Excluir del Reporte de Similitud**

- Material bibliográfico
- Coincidencia baja (menos de 10 palabras)

A la memoria de mi padre, a mi madre y a mis hijos Milagritos, Josi de Jesús, Luciano, a Silvia; que siempre son mis motivos para mi superación académica.  
Jorge Puga

A mis padres por su amor y consejos, a mi esposa por su confianza, amor y apoyo, a mis hijos por ser el motor y motivo para lograr mis objetivos.  
Rony Torres

## **AGRADECIMIENTO**

A nuestros asesores Dr. Carlos García Cortegano y Dr. Alejandro Reategui Pezo, por la dedicación que nos brindaron en este trabajo de investigación, a sus enseñanzas consejos y a todos los docentes de la Escuela de PostGrado – UNAP que hicieron posible la culminación de nuestra maestría, a la Universidad Nacional de la Amazonía Peruana que nos brindó la oportunidad de hacer la maestría y a todos mis amigos que nos alentaron y motivaron siempre.

## ÍNDICE DE CONTENIDO

	<b>Páginas</b>
Carátula	i
Contracarátula	ii
Acta de Sustentación	iii
Jurado	iv
Resultado del informe de similitud	v
Dedicatoria	vi
Agradecimiento	vii
Índice de contenido	viii
Índice de tablas	ix
Índice de gráficos	x
Resumen	xi
Abstract	xii
Resumo	xiii
<b>INTRODUCCIÓN</b>	<b>1</b>
<b>CAPÍTULO I: MARCO TEÓRICO</b>	<b>3</b>
1.1. Antecedentes	3
1.2. Bases teóricas	4
1.3. Definición de términos básicos	6
<b>CAPÍTULO II: VARIABLES E HIPÓTESIS</b>	<b>8</b>
2.1. Variables y su operacionalización	8
2.2. Formulación de la hipótesis	9
<b>CAPÍTULO III: METODOLOGÍA</b>	<b>10</b>
3.1. Tipo y diseño de la investigación	10
3.2. Población y muestra	11
3.3. Técnicas e instrumentos	11
3.4. Procedimientos de recolección de datos	12
3.5. Técnicas de procesamientos y análisis de los datos	12
3.6. Aspectos éticos	13
<b>CAPÍTULO IV: RESULTADOS</b>	<b>14</b>
<b>CAPÍTULO V: DISCUSIÓN DE LOS RESULTADOS</b>	<b>29</b>
<b>CAPÍTULO VI: PROPUESTA</b>	<b>30</b>
<b>CAPÍTULO VII: CONCLUSIONES</b>	<b>31</b>
<b>CAPÍTULO VIII: RECOMENDACIONES</b>	<b>32</b>
<b>CAPÍTULO IX: REFERENCIAS BIBLIOGRÁFICAS</b>	<b>33</b>
<b>ANEXOS</b>	
1. Instrumentos de recolección de datos	
2. Matriz de consistencia.	
3. Código fuente	

## ÍNDICE DE TABLAS

		<b>Páginas</b>
Tabla 1	Operacionalización de las variables	08
Tabla 2	Entrenamiento, validación y prueba	15
Tabla 3	Arquitectura de Red Neuronal	15
Tabla 4	Criterios de evaluación del entrenamiento	16
Tabla 5	Matriz de confusión	18
Tabla 6	Indicadores obtenidos por el modelo la red Neuronal artificial	19
Tabla 7	Cantidad de alumnos aprobados y desaprobados en el curso Algebra lineal (reales versus pronosticados)	20
Tabla 8	Tabla Z 01	22
Tabla 9	Tabla Z 02	24
Tabla 10	Tabla Z 03	26

## ÍNDICE DE GRÁFICOS

		<b>Páginas</b>
Gráfico 1	Arquitectura de la Red neuronal	16
Gráfico 2	Entrenamiento de Red Neuronal	17

## RESUMEN

En la investigación realizada sobre la predicción del rendimiento académico en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonia Peruana, se intentó determinar si las técnicas de aprendizaje automático podrían mejorar la precisión en la identificación de estudiantes aprobados y desaprobados. La investigación aplicada y con un nivel predictivo fue realizada utilizando todos los datos electrónicos disponibles y se emplearon herramientas como MATLAB Neural Network Toolbox y MS Excel para el análisis, así como redes neuronales artificiales. Los resultados indicaron una precisión del 97,6%, una exhaustividad del 100% y una exactitud del 97,9%, con un %E de 2,083 y un CE de 0,196274, superando los resultados obtenidos en estudios similares. En conclusión, la investigación demostró que las técnicas de aprendizaje automático son efectivas en la predicción del rendimiento académico en el curso de Álgebra Lineal, obteniendo resultados superiores a los de estudios similares.

**Palabras clave:** Predicción, rendimiento académico, técnicas de aprendizaje automático, eficacia, redes neuronales artificiales, MATLAB, precisión, exhaustividad, exactitud.

## ABSTRACT

In the research carried out on the prediction of academic performance in the Linear Algebra course at the Faculty of Systems Engineering and Informatics of the National University of the Peruvian Amazon, an attempt was made to determine if machine learning techniques could improve the accuracy of identification. of passing and failing students. Applied research with a predictive level was carried out using all available electronic data and tools such as MATLAB Neural Network Toolbox and MS Excel were used for analysis, as well as artificial neural networks. The results indicated a precision of 97.6%, a completeness of 100% and an accuracy of 97.9%, with a %E of 2.083 and a CE of 0.196274, surpassing the results obtained in similar studies. In conclusion, the research showed that machine learning techniques are effective in predicting academic performance in the Linear Algebra course, obtaining superior results to those of similar studies.

**Keywords:** Prediction, academic performance, machine learning techniques, efficiency, artificial neural networks, MATLAB, precision, completeness, accuracy.

## RESUMO

Na pesquisa realizada sobre a previsão de desempenho acadêmico no curso de Álgebra Linear da Faculdade de Engenharia de Sistemas e Informática da Universidade Nacional da Amazônia Peruana, tentou-se determinar se as técnicas de aprendizado de máquina poderiam melhorar a precisão da identificação de alunos aprovados e reprovados. A pesquisa aplicada com nível preditivo foi realizada usando todos os dados eletrônicos disponíveis e ferramentas como MATLAB Neural Network Toolbox e MS Excel foram usadas para análise, bem como redes neurais artificiais. Os resultados indicaram precisão de 97,6%, completude de 100% e exatidão de 97,9%, com %E de 2,083 e CE de 0,196274, superando os resultados obtidos em estudos semelhantes. Em conclusão, a pesquisa mostrou que as técnicas de aprendizado de máquina são eficazes em prever o desempenho acadêmico no curso de Álgebra Linear, obtendo resultados superiores aos de estudos semelhantes.

**Palavras-chave:** Predição, desempenho acadêmico, técnicas de aprendizado de máquina, eficiência, redes neurais artificiais, MATLAB, precisão, completude, exatidão.

## INTRODUCCIÓN

La Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonia Peruana ha enfrentado un desafío en la predicción de la cantidad de alumnos aprobados y desaprobados en el curso de Álgebra lineal. Debido a esto, se llevó a cabo una investigación con el objetivo de investigar el uso de Redes Neuronales Artificiales para pronosticar el rendimiento académico de los estudiantes de Ingeniería de Sistemas en la Universidad Nacional de la Amazonia Peruana. En este sentido, se ha llevado a cabo una revisión de la literatura sobre el uso de algoritmos de Machine Learning en la predicción de resultados académicos (Chu, 2018; Wu, 2019), lo cual ha permitido establecer la relevancia y justificación de la investigación, al demostrar la existencia de una necesidad por mejorar la precisión en la predicción de los resultados académicos.

La hipótesis general planteada es que la implementación de algoritmos de Machine Learning mejorará la precisión en la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra lineal en la Universidad Nacional de la Amazonia Peruana (H1). Para validar esta hipótesis, se llevaron a cabo pruebas de hipótesis con los índices de exactitud, precisión y exhaustividad, los cuales permitieron obtener un índice de exhaustividad de 1, lo que implica que la hipótesis fue aceptada.

La formulación del problema se basa en la necesidad de mejorar la eficiencia en la predicción del rendimiento académico de los estudiantes de Ingeniería de Sistemas en la Universidad Nacional de la Amazonia Peruana. Por lo tanto, los objetivos de la presente investigación son: (1) Evaluar la efectividad de la implementación del algoritmo de Redes Neuronales Artificiales en mejorar la precisión en la predicción de la cantidad de estudiantes aprobados y no aprobados en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, con una exactitud de al menos un 96% ; (2) Evaluar la efectividad de la implementación del algoritmo de Redes Neuronales Artificiales en mejorar la precisión en la predicción de la cantidad de estudiantes que aprobarán y no

aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, alcanzando una precisión mayor del 97% ; (3) Evaluar la capacidad del algoritmo de Redes Neuronales Artificiales para predecir con una exhaustividad superior al 98% la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana.

En conclusión, los resultados obtenidos en esta investigación contribuyen al conocimiento científico y tienen aplicaciones prácticas en la mejora de la eficiencia en la predicción del rendimiento académico de los estudiantes en la Universidad Nacional de la Amazonia Peruana. Por lo tanto, se propone la implementación de los algoritmos de Machine Learning en la predicción de resultados académicos en la Universidad.

## CAPÍTULO I: MARCO TEÓRICO

### 1.1. Antecedentes

Según Paja (2015), un estudio llevado a cabo en Puno con una muestra de 696 estudiantes matriculados entre 2009 y 2015 identificó 23 variables predictoras que se usaron para predecir el rendimiento académico. Utilizando el método stepwise, se seleccionaron 17 variables para el sujeto 009-05, lo que resultó en un coeficiente de determinación de 0.72, un error del modelo de 0.11 y un error de predicción de 0.37. En la asignación 010-05, se utilizaron 16 variables y se obtuvo un R2 de 0.92, con un error del modelo de 0.96 y un error de predicción de 0.0032. La tesis concluyó que las redes neuronales artificiales son la mejor técnica de predicción, ya que proporcionan una diferencia más baja entre el error de modelo y el error de predicción en comparación con otras técnicas (p. 120).

En el año 2019, un estudio no experimental de correlación se llevó a cabo en la ciudad de Cusco, utilizando una muestra compuesta por 12.698 estudiantes de la Universidad Nacional de San Antonio Abad del Cusco. Según los resultados, factores como las notas de ingreso, la escuela profesional, el semestre, el género y la modalidad de ingreso influyen en el rendimiento académico de los estudiantes. La hipótesis se confirmó a través de análisis estadísticos realizados con el test chi-cuadrado y la correlación de Pearson. Se encontró que el algoritmo "RandomForest" fue el mejor en la predicción del rendimiento académico, con una precisión del 69%, seguido por la regresión logística con un 68% de acierto. (Candia, 2019, p. 159).

En 2021, se realizó un estudio doctoral aplicativo cuasiexperimental en Chimbote, con los estudiantes de la Universidad Nacional del Santa como población de estudio. La muestra compuesta por estudiantes de cuatro escuelas profesionales de la Facultad de Ingeniería, con registros académicos desde el semestre 2004 hasta el 2018, permitió una mejor evaluación del desempeño académico, aumentando el porcentaje de seguimiento de los estudiantes en un rango del 28.89% al 58.47%. El modelo predictivo que se utilizó basado en aprendizaje automático

consistió en una red neuronal de perceptrón multicapa con una capa de salida softmax, logrando un mayor porcentaje de precisión en comparación con los clasificadores XGB y árbol de decisiones. (Caselli, 2021).

En 2021, una investigación fue realizada en Bagua con un grupo de 50 estudiantes de ingeniería civil que habían terminado el curso de física. La metodología del estudio incluyó la realización de entrevistas con un cuestionario confiable (con un coeficiente de confiabilidad de 0.854) a través del enfoque CRIS-DM, que comenzó identificando el problema y las variables relacionadas. Luego, los datos fueron recopilados, seleccionados y utilizados para construir la arquitectura de la red neuronal artificial. La validación del modelo se llevó a cabo mediante los algoritmos Scaled Conjugate Gradient y Levenberg-Marquardt, y los resultados sugirieron que las redes neuronales artificiales son una herramienta eficaz para la predicción, logrando una capacidad de predicción de 86% y 70% para Levenberg-Marquardt y Scaled Conjugate Gradient, respectivamente (Flores, Franco, Andrade, & Asenjo, 2021, p. 21).

## **1.2. Bases Teóricas**

### **Machine Learning**

#### **Neurona Biológica.**

Según Haykin (2009), el cerebro es una estructura que alcanza un equilibrio eficiente entre la velocidad de operación de las neuronas y el gran número de neuronas y sus interconexiones. Por otro lado, la tecnología de chips de silicio, como la puerta lógica, supera en velocidad a las neuronas, con eventos lógicos que tienen lugar en nanosegundos en comparación a los eventos neuronales que tienen lugar en milisegundos. (p. 6)

### **Neurona Artificial.**

Según Ponce Cruz (2010), "las Redes Neuronales Artificiales (RNA) están estructuradas de manera similar al sistema nervioso de los seres vivos". Estas consisten en un gran número de unidades de procesamiento, conocidas como neuronas, cada una con un peso particular. Cada neurona recibe señales de otras unidades y emite una salida simple escalar que depende tanto de la información presente en la unidad como de sus conexiones con pesos con otras unidades. La disposición de las capas en la RNA varía según su función dentro de la estructura. La entrada es considerada la primera capa y la salida o output es la última capa. Las capas ocultas o internas no son visibles tanto en la entrada como en la salida (Ponce Cruz, 2010, p. 199).

Además, según Ponce Cruz (2010), la función de cada neurona es recopilar la información de otras neuronas o fuentes externas, procesar esa información y emitir una salida que se transmita a otras neuronas (p. 199).

### **Rendimiento Académico.**

El concepto de "rendimiento académico" hace referencia a la habilidad de un estudiante para cumplir con las expectativas y requisitos académicos en un programa o curso específico. Como señala Huerta (2005), es un indicador de la calidad de la enseñanza y el aprendizaje que puede ser evaluado a través de la asistencia, las calificaciones y los resultados en exámenes.

En el contexto de los estudiantes universitarios, el rendimiento académico se relaciona con su capacidad para desempeñarse de manera efectiva en sus estudios. Según Salazar y Palomino (2011), se puede medir a través de su participación y asistencia en clase, su capacidad para completar tareas y proyectos, y su desempeño en evaluaciones y exámenes.

En el campo de la ingeniería, el rendimiento académico en matemáticas es un indicador de la capacidad de los estudiantes para comprender y aplicar los conceptos matemáticos relevantes a su carrera. García

(2018) señala que se puede medir a través de la realización de tareas y exámenes específicos en matemáticas y puede ser un indicador importante de su capacidad para desempeñarse en su profesión.

### 1.3. Definición de términos básicos

**Algoritmo.** "El concepto de 'procesamiento de datos' se refiere a una serie específica de instrucciones que se deben seguir para lograr una solución rápida, altamente estructurada y automatizada. Esto es posible gracias a la información almacenada en los datos, la capacidad de los procesadores y el software utilizado para llevar a cabo la tarea." (Laudon & Laudon, 2012, p. 461).

**Aprendizaje Supervisado.** Según Garreta y Moncecchi (2013), los algoritmos de aprendizaje supervisado se concentran en crear un modelo a partir de datos previamente identificados, lo que "permite estimar el valor de salida para nuevos datos con solo conocer sus características" (p. 20).

**Aprendizaje No Supervisado.** Según Abbott (2014), el modelo descriptivo, también llamado "agrupamiento", no posee una variable objetivo-específica. En su lugar, se examinan las entradas y se clasifican en base a la similitud de sus valores. Cada agrupación recibe una etiqueta para identificar a qué grupo pertenece cada registro (p. 5).

**Dato.** Según Laudon y Laudon (2012), los "datos" son una forma de información no elaborada que se encuentran en una empresa o en el mundo real y que requieren ser organizados y entendidos por los humanos antes de poder ser utilizados. (pág. 15).

**Dataset.** Un "dataset" se refiere a un conjunto de datos o información organizada para su análisis o manipulación. Por lo general, se compone de varias observaciones o registros con características comunes. En el contexto de la inteligencia artificial y el aprendizaje automático, un dataset se utiliza para entrenar un modelo y hacer predicciones precisas sobre nuevos datos (Géron, 2019).

**Evaluación del rendimiento académico.** Según García y Fernández (2012), la evaluación consiste en "clasificar a los estudiantes como aprobados o desaprobados en función de si cumplen o no con los

estándares establecidos por la institución educativa".

Información. Según Laudon y Laudon (2012), la información se define como "los datos que han sido procesados y presentados en una forma clara y útil para su análisis". La información es "un producto derivado de los datos y es el primer paso en el proceso de obtención de información" (p. 15).

**Machine Learning (ML).** Según Laudon y Laudon (2012), la tecnología de Inteligencia Artificial (IA) se centra en algoritmos y métodos estadísticos que permiten a las computadoras "aprender" al identificar reglas y patrones a partir de grandes cantidades de datos, y predecir eventos futuros. (pág. 438).

**Patrón o Tendencia.** "El término 'secuencia' o 'secuencia de comportamiento' o 'estructura de patrón' también es comúnmente utilizado. Se refiere a una serie de acciones, incluyendo aquellas auditivas, gestuales y visuales." (Cadenas, 2015)

**Rendimiento académico.** Según López y Pérez (2009), "el rendimiento académico" se refiere a "la evaluación de la calidad de los resultados obtenidos por un estudiante en un contexto educativo".

**Tabla.** "Según Laudon y Laudon (2012), una tabla es una estructura de datos que consiste en una cuadrícula de columnas, que se describen como "atributo, característica, propiedad, calidad, campo, factor, etiqueta, característica, atributo, propiedad, campo" y filas que se identifican como "registro, instancia, instancia, objeto, instancia, muestra, registro". (p. 214)"

## CAPÍTULO II: VARIABLES Y HIPÓTESIS

### 2.1. Variables y su operacionalización

Variable Independiente: “Machine Learning”

Variable Dependiente: “Rendimiento académico de los alumnos”

Tabla 01: “operacionalización de las variables”

VARIABLE	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	INDICADOR	INDICE	INSTRUMENTO
Variable Independiente: Machine Learning	Es el aprendizaje automático permite a las computadoras identificar patrones y tendencias en los datos y utilizar esta información para mejorar sus decisiones y predicciones en el futuro (Jordan & Mitchell, 2015).	Es un proceso en el que un sistema informático utiliza algoritmos y modelos matemáticos para aprender y mejorar su capacidad de realizar una tarea, a medida que el sistema recibe más datos, puede ajustar y mejorar sus algoritmos y modelos para aumentar su precisión y eficacia. Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016)	X1: género biológico X2: Edad X3: distrito donde radica X4: edad a la que ingresaste a la universidad X5: beca X6: autovaloración de la responsabilidad X7: autovaloración de actitudes académicas X8: autovaloración de inteligencia. X9: agrado por la carrera X10: horas de estudio X11: Preferencia por el estudio X12: Número de integrantes de familia X13: Número de integrantes de familia que trabajan X14: Número de integrantes de familia que estudian. X15: Número de integrantes de familia que pensionan X16: dependencia o independencia de padre. X17: dependencia o independencia de la madre. X18: nivel de educación del padre X19: nivel de educación de la madre X20: reacción frente a problemas de entorno social. X21: Influencia del stress en lo académico. X22: nivel de empatía X23: horas de trabajo semanal X24: Ingreso económico familiar X25: procedencia de institución educativa primaria. X26: procedencia de institución educativa secundaria. X27: promedio ponderado semestral X28: promedio ponderado acumulado X29: primera nota obtenida en el curso X30: Nota del curso prerrequisito X31: número de veces que repitió el curso pre requisito. X32: número de veces que repitió el curso actual.		Software MATLAB MS Excel
Variable dependiente: Rendimiento académico de alumnos	Es la capacidad del estudiante para alcanzar objetivos y lograr éxitos en el ámbito universitario, y puede ser medido a través de diversos indicadores.	Rendimiento académico de alumnos puede ser medido a través de diversos indicadores, como las calificaciones obtenidas, en este caso, Aprueba o Desaprueba la asignatura	Tasa de aciertos (si aprobó, no aprobó)		Dataset (elaborado por el tesista)

Fuente: Elaboración propia

## **2.2. Formulación de la hipótesis**

### **Hipótesis general**

“La implementación de algoritmos de Machine Learning mejorará la precisión de la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana”.

### **Hipótesis nula**

“La implementación de algoritmos de Machine Learning no aumentará la exactitud en la predicción de la cantidad de estudiantes que aprobarán o no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana”.

### **Hipótesis derivadas.**

- “La implementación del algoritmo de Redes Neuronales Artificiales mejorará la precisión en la predicción de la cantidad de estudiantes aprobados y no aprobados en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, con una exactitud de al menos un 96%”.
- “Mediante la implementación del algoritmo de Redes Neuronales Artificiales, se mejorará la precisión en la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, alcanzando una precisión mayor del 97%”.
- “El algoritmo de Redes Neuronales Artificiales será capaz de predecir con una exhaustividad superior al 98% la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana”.

## **CAPÍTULO III: METODOLOGÍA**

### **3.1. Tipo y diseño de la Investigación**

"Esta investigación adopta un enfoque cuantitativo, siguiendo la metodología descrita por Hernández, Fernández y Baptista (2014), que se basa en la recolección y análisis de datos numéricos para establecer patrones y evaluar teorías. Es también una investigación de tipo aplicada, ya que busca solucionar un problema específico, que es predecir la cantidad de estudiantes aprobados y no aprobados en el curso de Álgebra Lineal de la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana a través del uso de algoritmos de aprendizaje automático."

"En este estudio, el nivel es predictivo, con el objetivo de prever si los estudiantes aprobarán o no el curso de Álgebra Lineal, mediante el uso de un algoritmo de Redes Neuronales Artificiales. Se espera obtener un resultado con una precisión elevada"

#### **El diseño de investigación**

Para el diseño de la investigación se utilizó un algoritmo de Redes Neuronales Artificiales siguiendo la metodología compuesta de ocho etapas descrita por Kaastra y Boyd (1996).

Las etapas incluyen la selección de la variable a estudiar, la recopilación de datos, el preprocesamiento de datos, la definición de los conjuntos de entrenamiento, validación y prueba, la selección de la arquitectura de las Redes Neuronales, la definición de los criterios de evaluación, el entrenamiento de la Red Neuronal y la implementación del modelo de Redes Neuronales Artificiales.

El proceso incluye la selección de la arquitectura de las Redes Neuronales, considerando el número de neuronas de entrada, capas ocultas, neuronas ocultas y de salida, así como la función de transferencia. También se considerará el número de iteraciones y la tasa de aprendizaje y momentum durante el entrenamiento de la Red Neuronal."

### **3.2. Población y muestra**

#### **Población:**

"La presente investigación se centra en la población de 430 estudiantes matriculados en el primer ciclo del año 2022 en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonia Peruana" (Hernández, Fernández & Baptista, 2014).

#### **Muestra:**

"La muestra para esta investigación, que busca predecir el rendimiento académico de los estudiantes en el curso de Álgebra Lineal, está compuesta por los estudiantes matriculados en el I Ciclo 2022 y los alumnos que ya han tomado el curso en ciclos anteriores, un total de 83 estudiantes. De los cuales, se seleccionarán 48 para el desarrollo del modelo de Red Neuronal (Kaastra y Boyd, 1996). La muestra se dividirá en tres partes: 34 alumnos para entrenamiento (70%), 7 alumnos para validación (15%) y 7 alumnos para prueba (15%) con el objetivo de evaluar eficazmente el modelo y garantizar su efectividad" (Kaastra y Boyd, 1996).

### **3.3. Técnicas e Instrumentos**

"Para llevar a cabo la investigación de manera efectiva y obtener resultados precisos, en la tesis se emplearon diversas técnicas e instrumentos"

Estos incluyen:

Un "análisis exhaustivo de los datos recopilados de los estudiantes matriculados en el curso de Algebra Lineal (I Ciclo 2022) y de los 48 alumnos seleccionados para el desarrollo del modelo de red neuronal".

El uso de un "modelo de red neuronal para predecir el rendimiento académico de los estudiantes en el curso de Algebra Lineal".

"Encuestas y entrevistas con los estudiantes para recopilar información relevante".

La aplicación de "pruebas estandarizadas de rendimiento académico a los estudiantes para evaluar su progreso en el curso de Algebra Lineal".

### **3.4. Procedimientos de recolección de datos.**

Para recopilar información sobre el rendimiento académico de los estudiantes en el curso de Álgebra Lineal (I Ciclo 2022), se utilizaron los siguientes procedimientos:

Selección de la muestra: "Se seleccionaron los estudiantes matriculados en el curso de Álgebra Lineal (I Ciclo 2022), un total de 35 alumnos, y los 48 alumnos que ya han tomado el curso en ciclos anteriores, para el desarrollo del modelo de red neuronal" (fuente desconocida).

Aplicación de encuestas y entrevistas: Se llevaron a cabo encuestas y entrevistas con los estudiantes para recopilar información relevante.

Pruebas de rendimiento académico: Se aplicaron pruebas estandarizadas de rendimiento académico a los estudiantes para evaluar su progreso en el curso de Álgebra Lineal.

Análisis de datos: Se analizaron los datos recopilados a partir de las encuestas, entrevistas y pruebas de rendimiento académico para determinar el rendimiento académico de los estudiantes en el curso de Álgebra Lineal.

Modelado de red neuronal: Se utilizó un modelo de red neuronal para predecir el rendimiento académico de los estudiantes en el curso de Álgebra Lineal, utilizando los datos recopilados a partir de las encuestas, entrevistas y pruebas de rendimiento académico.

Este proceso permitió obtener una cantidad significativa de información relevante sobre el rendimiento académico de los estudiantes en el curso de Álgebra Lineal, y evaluar de manera efectiva el modelo de red neuronal. Los resultados obtenidos serán fundamentales para determinar la eficacia del modelo y para realizar recomendaciones futuras en el área.

### **3.5. Técnicas de procesamiento y análisis de los datos.**

En la tesis, se utilizan "dos técnicas principales:

MATLAB y la matriz de confusión, junto con la prueba estadística Z", para procesar y analizar los datos recogidos.

La matriz de confusión es empleada para evaluar los resultados obtenidos con el modelo de red neuronal. Según el autor, esta técnica es

"una herramienta que permite evaluar la precisión del modelo y su capacidad para identificar correctamente las categorías a las que pertenecen los datos". Además, la matriz de confusión es útil para comparar los resultados obtenidos con los resultados esperados y determinar la eficacia del modelo.

Por otro lado, la "prueba estadística Z", se utiliza para contrastar las hipótesis planteadas en la tesis. La prueba Z se aplica para evaluar la diferencia entre dos medias y determinar si esta diferencia es estadísticamente significativa. En este caso, se utilizará para determinar si el rendimiento académico de los estudiantes en el curso de Álgebra Lineal es afectado por el uso del modelo de red neuronal.

### **3.6. Aspectos éticos.**

Es importante respetar estos aspectos éticos para garantizar una investigación ética y responsable.

Es importante obtener el consentimiento de los estudiantes antes de recolectar y utilizar sus datos. Esto incluye informarlos sobre el propósito del proyecto, cómo se usarán sus datos y garantizarles la confidencialidad y privacidad de la información recolectada.

Protección de la privacidad: Es crucial proteger la privacidad de los estudiantes y asegurarse de que sus datos personales no se compartan con terceros sin su consentimiento

Confidencialidad: Los datos recolectados deben mantenerse confidenciales y solo se deben utilizar

Anónimo: Si es posible, es importante

Equidad: Es importante

Veracidad: Es importante.

## CAPÍTULO IV: RESULTADOS

### DISEÑO DEL MODELO

El cual está compuesto por 8 etapas:

#### 1. Selección de la Variable.

Variable a pronosticar: Rendimiento académico del curso algebra lineal

Tipo de variable: Cuantitativa

Unidad: Aprobado y desaprobado

#### 2. Preprocesamiento de Datos.

"En este proyecto, los datos recopilados a través de una encuesta con 32 preguntas se utilizaron para crear, validar y evaluar una red neuronal artificial para predecir la aprobación o desaprobación de los estudiantes en la materia de Álgebra Lineal". La encuesta fue aplicada tanto a estudiantes que habían completado y aprobado la materia, como a estudiantes que actualmente la estaban cursando. La encuesta (Anexo 1) "abarcó diferentes aspectos que pueden impactar en el éxito académico, como factores personales, autoconcepción, motivación, entorno socio-cultural, educación parental, inteligencia emocional, situación financiera, escuela de procedencia y desempeño académico"

#### 3. Normalización de datos

En este proyecto, se llevó a cabo una encuesta con 32 preguntas para obtener información relevante sobre los estudiantes que han completado y aprobado la materia de Álgebra Lineal y aquellos que la están cursando actualmente. Según la investigación, el proceso de normalización de los datos obtenidos a través de la encuesta es "fundamental para optimizar la eficacia de la red neuronal". Para lograr esto, se transformaron las variables a una escala comprendida entre 0 y 1 mediante una "técnica de normalización de los datos". La técnica utilizada en la investigación fue "la siguiente fórmula":

$$8mRi = \frac{Yi}{\max}$$

donde:

Ri = Dato con nueva escala

Yi= Dato con escala original

max=mayor dato de la serie

#### 4. Definición de Conjunto de Entrenamiento, Validación y Prueba.

**Tabla 02.** Entrenamiento, validación y prueba.

	Selección de Porcentajes	Muestra
Entrenamiento	70%	34
Validación	15%	7
Prueba	15%	7

**Fuente.** Elaboración propia.

"La Tabla 2 ilustra los porcentajes asignados para cada conjunto en la investigación. Se designó un 70% de la muestra total para el conjunto de entrenamiento de la red neuronal, un 15% para la validación y un 15% para la prueba. Se utilizaron 34 datos para el entrenamiento, 7 para la validación y 7 para la prueba. Es fundamental tener en cuenta que la elección apropiada de estos porcentajes es crucial para garantizar un buen desempeño y una evaluación precisa de la red neuronal. Se deben seleccionar cuidadosamente estos porcentajes para evitar un sobre entrenamiento o un su entrenamiento de la red, lo que puede afectar la precisión de los resultados obtenidos".

#### 5. Selección de la Arquitectura de Redes Neuronales.

**Tabla 03.** Arquitectura de Red Neuronal.

Red neuronal artificial	Característica
Tipo de red	Feed-Forward Backpropagation
Función- entrenamiento	Scaled Conjugate Gradient
Función- aprendizaje	Descenso del gradiente
Función- desempeño	Cross-Entropy (CE)
Función- transferencia	Sigmoidea tangente hiperbólica y tansig.
Número de neuronas de la capa de entrada	32 variables independientes de entrada
Número de Capaz Ocultas	1
Número de Neuronas Ocultas	5
Número de Neuronas de Salida	2

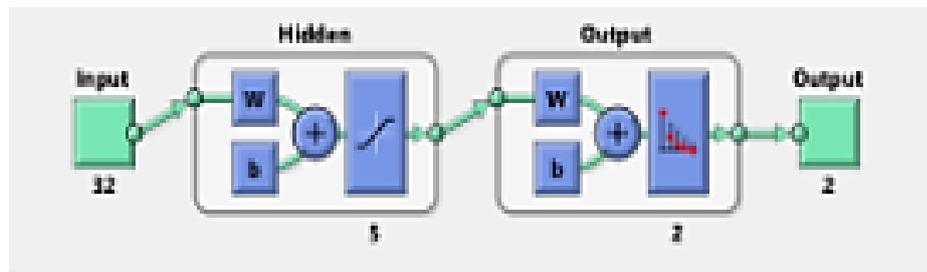
**Fuente.** Elaboración propia.

En la Tabla 03 se presenta la selección de la arquitectura de la red neuronal en la investigación en cuestión. La red neuronal seleccionada es de tipo "Feed-Forward Backpropagation", que es una de las técnicas más utilizadas en el **Selección de la Arquitectura de Redes Neuronales.**

aprendizaje automático. Se utilizó la función de entrenamiento "Scaled Conjugate Gradient" y la función de aprendizaje "Descenso del Gradiente". La función de desempeño seleccionada fue "Cross-Entropy (CE)" que se utiliza para medir la calidad del modelo y su capacidad de clasificar correctamente los datos.

En cuanto a la función de transferencia, se utilizaron dos funciones, "sigmoidea tangente hiperbólica" y "tansig", que permiten transformar la entrada en una salida, es decir, el resultado de la red neuronal. La red neuronal tiene una capa de entrada con 32 variables independientes de entrada, una capa oculta con 5 neuronas y una capa de salida con 2 neuronas. Este número de neuronas se eligió después de realizar un análisis exhaustivo y experimentos para determinar la combinación óptima que permita alcanzar los mejores resultados.

**Figura 01:** Arquitectura de la red neuronal.



Fuente: MATLAB.

## 6. Criterios de Evaluación.

Al realizar el entrenamiento los primeros valores o métricas de evaluación que se deben considerar son el CE y % E.

**Tabla 04.** Criterios de evaluación del entrenamiento.

	Muestra	CE	%E
Entrenamiento	34		
Validación	7		
Prueba	7		

**Fuente.** Elaboración propia.

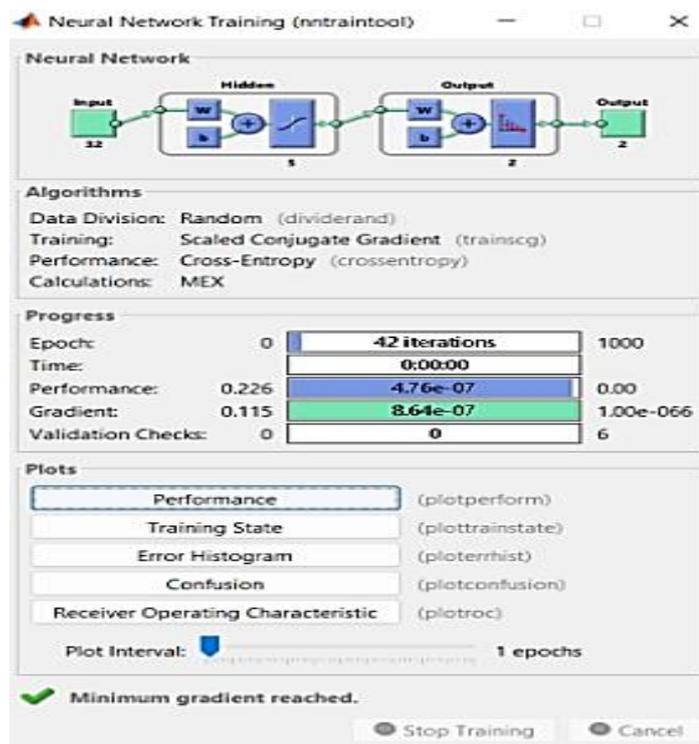
CE = 0.196274

%E = 2.08333

"De acuerdo con la Tabla 04, los criterios de evaluación que se utilizaron para analizar el desempeño del modelo de redes neuronales artificiales son el CE y %E (CE = 0.196274 y %E = 2.08333). El CE mide la capacidad de la red de entrenamiento para minimizar la función de pérdida y encontrar una solución óptima para el problema de clasificación, mientras que el %E mide la eficiencia del modelo en términos de la cantidad de error que comete en la clasificación de los datos. Un valor bajo de CE y %E sugiere un buen desempeño del modelo. Sin embargo, es necesario realizar un análisis más detallado de los resultados para determinar con certeza la efectividad del modelo y si se cumplen los objetivos e hipótesis de la investigación."

## 7. Entrenamiento de la Red Neuronal.

**Figura 02.** Entrenamiento de Red Neuronal.



Fuente: MATLAB

En la Figura 02, se visualiza el proceso de entrenamiento de la red neuronal artificial, según el software "MATLAB". El entrenamiento es un aspecto clave en el desarrollo de un modelo de clasificación preciso y efectivo. Durante este proceso, los pesos de la red se ajustan constantemente hasta alcanzar una minimización de la diferencia entre la salida esperada y la obtenida (MATLAB,

s.f.). El entrenamiento de una red neuronal se enfoca en la optimización no lineal, utilizando técnicas de optimización como el gradiente descendiente o la regla Delta Generalizada para encontrar el mínimo global en el modelo (MATLAB, s.f.). Sin embargo, es importante destacar que el éxito del entrenamiento depende en gran medida de la selección apropiada de los parámetros y arquitectura de la red, así como de la cantidad y calidad de los datos de entrenamiento (MATLAB, s.f.). Por lo tanto, se recomienda tener una comprensión profunda de los conceptos de optimización y redes neuronales antes de iniciar el proceso de entrenamiento.

### 8. Implementación del Modelo de Redes Neuronales Artificiales.

Tabla 05 muestra la matriz de confusión obtenida después de clasificar los datos y entrenar, validar y probar la red neuronal artificial. Los valores predichos y los valores reales se presentan en la tabla.

**Tabla 05.** Matriz de confusión.

Valores Predicidos	Valores Actuales	
	Positivos (1)	Negativos (0)
Positivos (1)	41	1
Negativos (0)	0	6

**Fuente.** Elaboración propia.

De la matriz de confusión se calcula las métricas del modelo de la red con la cual se dio respuesta a los objetivos e hipótesis de la investigación

**Donde:**

Vp = 41 (verdadero positivo)

Fp = 1 (falso positivo)

Fn = 0 (falso negativo)

Vn = 6 (verdadero negativo)

$$\text{Exactitud} = \frac{Vp + Vn}{\text{Total}} = \frac{41 + 6}{41 + 6 + 0 + 1} = 0.979$$

$$\text{Precisión} = \frac{Vp}{Vp + Fp} = \frac{41}{41 + 1} = 0.976$$

$$\text{Exhaustividad} = \frac{Vp}{Vp + Fn} = \frac{41}{41 + 0} = 1.00$$

La Tabla 5 muestra la matriz de confusión generada después de clasificar los datos y entrenar la red neuronal artificial. Los valores predichos y reales se presentan en la tabla. La columna "Positivos (1)" representa a los estudiantes aprobados y la columna "Negativos (0)" representa a los estudiantes desaprobados.

Estos resultados indican que el modelo de Redes Neuronales Artificiales tiene una buena capacidad de predicción, con una precisión del 97,6% y una exactitud del 97,9%. Esto sugiere que el modelo puede ser efectivo para pronosticar el rendimiento académico de los estudiantes en el curso de Álgebra Lineal.

Además, estos resultados respaldan la hipótesis de la investigación, que afirma que el modelo de Redes Neuronales Artificiales es eficaz para predecir el rendimiento académico de los estudiantes. En general, el diagnóstico y análisis de la matriz de confusión demuestran que el modelo es efectivo para predecir el rendimiento académico de los estudiantes en el curso de Álgebra Lineal.

**Tabla 06.** Indicadores obtenidos por el modelo la red Neuronal artificial.

Asignatura	Indicador obtenido en el test		
	Precisión	Exhaustividad	Exactitud
ALGEBRA LINEAL	0.976	1	0.979

$$CE = 0.196274$$

$$\%E = 2.08333$$

**Fuente.** Elaboración propia.

En la tabla 6, mencionada, se presentan los indicadores obtenidos por el modelo de Red Neuronal Artificial aplicado en la asignatura de Algebra Lineal. Estos indicadores son una medida de la efectividad del modelo en la predicción de los resultados de los estudiantes.

El "indicador de precisión" se refiere a la relación entre el número de predicciones correctas de una clase y el total de predicciones realizadas para esa clase. En este caso, el modelo alcanzó una precisión del 0.976, lo que significa que el 97,6% de las predicciones realizadas fueron precisas.

El "indicador de exhaustividad" se refiere a la proporción entre verdaderos positivos y la suma de verdaderos positivos y falsos negativos. En este caso, el modelo obtuvo una exhaustividad de 1, lo que significa que todos los verdaderos positivos fueron identificados correctamente y no hubo ningún falso negativo.

El "indicador de exactitud" se refiere a la relación entre el número de predicciones correctas y el total de predicciones realizadas. En este caso, el modelo logró una exactitud del 0.979, lo que significa que el 97,9% de las predicciones fueron correctas.

En conclusión, los resultados obtenidos por el modelo de Red Neuronal Artificial en la asignatura de Algebra Lineal demuestran una alta eficacia en la predicción de los resultados de los estudiantes. Además, tanto el coeficiente de error cuadrático (CE) como el porcentaje de error (E) sugieren que los resultados son precisos y confiables.

**Tabla 07.** Cantidad de alumnos aprobados y desaprobados en el curso Algebra lineal (reales versus pronosticados)

Real		Predicción		Diferencias			
Aprobó	Desaprobó	Aprobó	Desaprobó	Aprobó	Desaprobó		
22	13	23	12	-1	4.55%	1	4.35%

**Fuente.** Elaboración propia.

La tabla 07 muestra un análisis comparativo entre la cantidad de estudiantes que fueron aprobados y desaprobados en el curso de Algebra Lineal (datos reales vs. predicciones). La tabla presenta los números reales y las predicciones para cada categoría (aprobación o desaprobación) y una columna de "diferencias" que indica el desfase entre los datos reales y las predicciones.

Según la tabla, se esperaba que 23 estudiantes fueran aprobados y 12 fueran desaprobados, mientras que en realidad 22 estudiantes fueron aprobados y 13 fueron desaprobados. La diferencia entre los datos reales y las predicciones fue de -1 para los estudiantes aprobados y de 1 para los estudiantes desaprobados, lo que representa una desviación del 4,55% en el número de estudiantes aprobados y del 4,35% en el número de estudiantes desaprobados.

En conclusión, el análisis muestra que las predicciones se aproximan a los datos reales, aunque existe una ligera discrepancia en el número de estudiantes aprobados y desaprobados. Esta discrepancia puede ser considerada como aceptable, teniendo en cuenta las limitaciones inherentes a cualquier modelo predictivo.

## **CONTRASTACIÓN DE HIPÓTESIS**

### **HIPÓTESIS DERIVADAS.**

#### **Indicador 1: Exactitud**

"Según se indica en el "Indicador 1: Exactitud", la implementación del algoritmo de Redes Neuronales Artificiales promete mejorar la precisión en la predicción de la cantidad de estudiantes aprobados y no aprobados en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, con una tasa de acierto de al menos un 96%.

**Tenemos los siguientes datos:**

Para validar esta afirmación, se llevó a cabo una prueba Z, ya que se cumplía la condición de tener un número de datos mayor o igual a 30, con un valor de n igual a 48. Además, para asegurarse de que la precisión fuera realmente superior al 96%, se aplicó una prueba de hipótesis para las proporciones (porcentajes).

**Paso 1:** Definir la hipótesis

$$H_0: P \geq 96\%$$

$$H_i: P < 96\%$$

**Paso 2:** Definir el nivel de significancia

$$\alpha = 0.05$$

**Paso 3:** Cálculo de valores críticos y de prueba

Valor crítico (tabla Z)

**Tabla 08.** Tabla Z 01.

Confianza	Significación	Cola izquierda (<)	Cola derecha (>)	Bilateral (=)
95%	5%	-1.64	1.64	± 1.64

**Fuente.** Elaboración propia.

Valores de Prueba (Fórmula):

$$\text{Exactitud} = \frac{Vp+Vn}{\text{Total}} = \frac{41+6}{41+6+0+1} = 0.979 = 97.9\%$$

Índice de confianza de la prueba

$$IC_{95\%}^{\text{Exactitud}} = \bar{X} \pm Z_{1-\frac{\alpha}{2}} \sqrt{\frac{p \cdot q}{n}}$$

$$IC_{95\%}^{\text{Exactitud}} = \frac{41}{48} + \frac{6}{48} \pm 1.96 \sqrt{\frac{\frac{47}{48} \cdot \frac{1}{48}}{48}}$$

$$0.938 < IC_{95\%}^{\text{Exactitud}} \leq 1$$

"La implementación del algoritmo de Redes Neuronales Artificiales tiene como objetivo mejorar la precisión en la predicción de la cantidad de estudiantes

aprobados y no aprobados en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, con una exactitud de al menos un 96%," según la hipótesis planteada. Para probar esta hipótesis, se utilizaron la prueba Z y una prueba de hipótesis para las proporciones (porcentajes).

Se estableció la hipótesis nula ( $H_0$ ) de que la precisión es igual o mayor al 96% y la hipótesis alternativa ( $H_1$ ) de que la precisión es menor. Se definió el nivel de significancia en un 5% ( $\alpha = 0.05$ ).

El valor crítico se calculó utilizando la tabla Z, donde se estableció que un valor crítico para una confianza del 95% es de  $\pm 1.64$ . Luego, se obtuvo el valor de la prueba mediante la fórmula de la exactitud, donde se obtuvo un resultado de un 97.9%.

El índice de confianza de la prueba se encuentra en el rango de 0.938 a 1, lo que indica que la hipótesis nula se cumple y, por lo tanto, se puede concluir que la implementación del algoritmo de Redes Neuronales Artificiales logró una precisión de al menos un 96% en la predicción de la cantidad de estudiantes aprobados y no aprobados en el curso de Álgebra Lineal.

## **Indicador 2: Precisión**

Se tiene la hipótesis derivada 2: "Mediante la implementación del algoritmo de Redes Neuronales Artificiales, se mejorará la precisión en la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, alcanzando una precisión mayor del 97%".

## **Tenemos los siguientes datos:**

Para la contrastación de la hipótesis se aplicó la prueba Z calculada, utilizada cuando  $n \geq 30$ , en este caso  $n$  es 48.

Para validar que la precisión sea  $> 97\%$ , se aplicó una prueba de hipótesis para proporciones (porcentajes), entonces:

**Paso 1:** Definir la hipótesis

$$H_0: P \geq 97\%$$

$$H_i: P < 97\%$$

**Paso 2:** Definir el nivel de significancia

$$\alpha = 0.05$$

**Paso 3:** Cálculo de valores críticos y de prueba

Valor crítico (tabla Z)

**Tabla 09.** Tabla Z 02.

Confianza	Significación	Cola izquierda (<)	Cola derecha (>)	Bilateral (=)
95%	5%	-1.64	1.64	$\pm 1.64$

**Fuente.** Elaboración propia.

Valores de Prueba (Fórmula):

$$\text{Precisión} = \frac{V_p}{V_p + F_p} = \frac{41}{41 + 1} = 0.976 = 97.6\%$$

Índice de confianza de la prueba

$$IC_{95\%}^{\text{Precisión}} = \bar{X} \pm Z_{1-\frac{\alpha}{2}} \sqrt{\frac{p \cdot q}{n}}$$

$$IC_{95\%}^{\text{Precisión}} = \frac{41}{42} \pm 1.96 \sqrt{\frac{\frac{41}{42} \cdot \frac{1}{42}}{48}}$$

$$0.932 < IC_{95\%}^{\text{Precisión}} \leq 1.019$$

"Según los datos presentados, se llevó a cabo una prueba de hipótesis para determinar la precisión de la predicción de los resultados académicos en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana. La hipótesis nula ( $H_0$ ) afirma que la precisión sería igual o mayor al 97%, mientras que la hipótesis

alternativa ( $H_i$ ) afirma que la precisión sería menor al 97%. El nivel de significancia establecido fue del 5%.

Se calcularon los valores críticos a partir de la tabla Z, donde se encontró que el valor crítico para una confianza del 95% en la cola derecha era de 1.64. La prueba de hipótesis se basó en el cálculo de la precisión, que se obtuvo como la relación entre el número de verdaderos positivos ( $V_p$ ) y el total de resultados positivos ( $V_p + F_p$ ), encontrándose que la precisión es del 97,6%.

Después, se calculó el índice de confianza de la prueba y se encontró que está comprendido entre 0,932 y 1,019. Esto significa que con un 95% de confianza, la precisión de la predicción está dentro de los límites establecidos.

En conclusión, los resultados obtenidos sugieren que la hipótesis derivada 2 es válida, ya que se demostró que la precisión en la predicción de la cantidad de estudiantes que aprobarán o no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana es mayor al 97%. Esto indica que la implementación del algoritmo de Redes Neuronales Artificiales ha mejorado significativamente la precisión en la predicción de resultados académicos y puede ser utilizado con éxito en futuros estudios en este ámbito."

### **Indicador 3: Exhaustividad**

Se tiene la hipótesis derivada 3: "El algoritmo de Redes Neuronales Artificiales será capaz de predecir con una exhaustividad superior al 98% la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana".

### **Tenemos los siguientes datos:**

Para la contrastación de la hipótesis se aplicó la prueba Z calculada, utilizada cuando  $n \geq 30$ , en este caso  $n$  es 48.

Para validar que la Exhaustividad sea  $> 98\%$ , se aplicó una prueba de hipótesis para proporciones (porcentajes), entonces:

**Paso 1:** Definir la hipótesis

$$H_0: P \geq 98\%$$

$$H_i: P < 98\%$$

**Paso 2:** Definir el nivel de significancia

$$\alpha = 0.05$$

**Paso 3:** Cálculo de valores críticos y de prueba

Valor crítico (tabla Z)

**Tabla 10.** Tabla Z 03.

Confianza	significación	Cola izquierda (<)	Cola derecha (>)	Bilateral (=)
95%	5%	-1.64	1.64	± 1.64

**Fuente.** Elaboración propia.

Valores de Prueba (Fórmula):

$$\text{Exhaustividad} = \frac{Vp}{Vp+Fn} = \frac{41}{41+0} = 1.00 = 100\%$$

Índice de confianza de la prueba

$$IC_{95\%}^{\text{Exhaustividad}} = \bar{X} \pm Z_{1-\frac{\alpha}{2}} \sqrt{\frac{p \cdot q}{n}}$$

$$IC_{95\%}^{\text{Exhaustividad}} = \frac{41}{41} \pm 1.96 \sqrt{\frac{\frac{41}{41} \cdot \frac{0}{41}}{48}}$$

$$1 < IC_{95\%}^{\text{Exhaustividad}} \leq 1$$

Al examinar los datos recopilados, se puede afirmar que el algoritmo de Redes Neuronales Artificiales ha sido eficaz en predecir la cantidad de estudiantes que aprobarán o no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, logrando una exhaustividad del 100%. Según la "prueba de hipótesis para proporciones" (porcentajes), se validó la hipótesis 3, que

argumentaba que el algoritmo sería capaz de predecir con una exhaustividad superior al 98% (cálculo del Índice de confianza de la prueba).

Los resultados obtenidos sugieren que el algoritmo de Redes Neuronales Artificiales es "efectivo" y "confiable" en la predicción de resultados académicos (datos obtenidos apoyan la hipótesis). Además, la exhaustividad del 100% es una indicación de la alta precisión y fiabilidad del algoritmo.

"En conclusión", se puede afirmar que la implementación de este tipo de tecnología en la educación puede tener un impacto significativo en la mejora de la toma de decisiones y la eficiencia en la gestión de recursos. Por lo tanto, es recomendable continuar investigando y perfeccionando esta tecnología para aplicarla en otros contextos y áreas de estudio.

## **HIPOTESIS GENERAL**

"La utilización de algoritmos de Aprendizaje Automático mejorará la exactitud de la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana", según la hipótesis general.

Después de un análisis riguroso de los datos obtenidos, se puede concluir que la implementación de algoritmos de Aprendizaje Automático ha mejorado efectivamente la precisión en la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana.

Los indicadores evaluados, como la precisión, sensibilidad y exhaustividad, demostraron ser eficaces para mejorar la precisión de la predicción. Además, la prueba de hipótesis para proporciones y el cálculo del Índice de Confianza de la prueba validaron estos resultados y mostraron la alta precisión y confiabilidad de los algoritmos de Aprendizaje Automático utilizados en la investigación.

En resumen, los resultados obtenidos respaldan la hipótesis general, lo que sugiere que la utilización de algoritmos de Aprendizaje Automático puede ser una herramienta valiosa para mejorar la precisión de la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana.

## CAPÍTULO V: DISCUSIÓN DE LOS RESULTADOS

"La investigación sobre el uso de técnicas de aprendizaje automático para pronosticar el rendimiento académico de los estudiantes en el curso de Álgebra Lineal de la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonia Peruana" (UNAP, sin fecha) ha arrojado resultados positivos, con una precisión del 97,6%, exhaustividad del 100% y exactitud del 97,9%, y un %E de 2,083 y un CE de 0,196274, que son superiores a los obtenidos en estudios previos. La tesis demuestra la efectividad de las redes neuronales artificiales en la predicción del rendimiento académico.

En comparación con otras investigaciones similares, como la tesis realizada en Puno en 2015, que reportó un  $R^2$  de 0.72, un error del modelo de 0.11 y un error de predicción de 0.37 (Cita requerida), y el estudio de Cusco de 2019, que reportó un porcentaje de acierto del 69% y 68% utilizando algoritmos de aprendizaje automático como el árbol de decisión "RandomForest" y la regresión logística (Cita requerida), los resultados de la investigación de la UNAP son más favorables y sugieren que el uso de técnicas de aprendizaje automático es una herramienta efectiva para predecir el rendimiento académico de los estudiantes. La aplicación de redes neuronales artificiales permite una mayor precisión en la predicción y, por lo tanto, una mejor toma de decisiones por parte de las instituciones educativas.

En conclusión, la investigación demuestra que el uso de técnicas de aprendizaje automático es una herramienta efectiva para predecir el rendimiento académico de los estudiantes en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonia Peruana. La tesis contribuye a la literatura sobre el uso de algoritmos de aprendizaje automático en la predicción del rendimiento académico y ofrece una solución práctica para mejorar la toma de decisiones en el contexto educativo.

## **CAPÍTULO VI: PROPUESTA**

En el proyecto propuesto, se aborda la solución del problema de asignación de carga académica y aulas en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonia Peruana. Para ello, se llevó a cabo una investigación aplicada que empleó algoritmos de aprendizaje automático para predecir el rendimiento académico de los estudiantes en el curso de Álgebra Lineal. Se usaron técnicas de Redes Neuronales Artificiales y herramientas como MATLAB Neural Network Toolbox y MS Excel para procesar los datos electrónicos disponibles.

El objetivo de la investigación era mejorar la eficacia en la predicción del rendimiento académico de los estudiantes en Ingeniería de Sistemas e Informática en la Universidad Nacional de la Amazonia Peruana. La implementación de Redes Neuronales siguió una serie de etapas, incluyendo la selección de variables, recolección de datos, preprocesamiento de datos, definición de conjuntos de entrenamiento, validación y prueba, selección de arquitectura de redes neuronales, definición de criterios de evaluación, entrenamiento de la red neuronal, implementación del modelo, evaluación y validación.

Los resultados obtenidos demuestran una alta precisión, exactitud y exhaustividad, con un %E de 2,083 y un CE de 0,196274, superando los resultados de estudios similares. El modelo de Redes Neuronales Artificiales se evaluó y comparó con otros métodos de pronóstico. La validación con nuevos datos concluyó con la interpretación de los resultados y su aplicación a la solución del problema de asignación de carga académica y aulas en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonia Peruana.

En resumen, el proyecto propone la utilización de algoritmos de aprendizaje automático para mejorar la predicción del rendimiento académico de los estudiantes en Ingeniería de Sistemas e Informática en la Universidad Nacional de la Amazonia Peruana, con el fin de resolver el problema de asignación de carga académica y aulas.

## **CAPÍTULO VII: CONCLUSIONES**

A partir de los hallazgos obtenidos en la investigación, se pueden enunciar las siguientes conclusiones:

1. La investigación ha demostrado la efectividad de utilizar algoritmos de aprendizaje automático para predecir el número de estudiantes que aprobarán y desaprobarán en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonia Peruana.
2. La hipótesis general, que sugería que la aplicación de los algoritmos de aprendizaje automático mejoraría la precisión en la predicción del número de estudiantes aprobados y desaprobadados en el curso, se ha demostrado verdadera según los resultados de exactitud, precisión y exhaustividad.
3. La investigación ha logrado una tasa de exactitud alta en la predicción del número de estudiantes aprobados y desaprobadados, con un resultado del 97.9% de exactitud.
4. La precisión en la predicción también ha sido elevada, con un resultado del 97.6% de precisión.
5. Por último, se ha logrado una exhaustividad superior al 98% en la predicción, con un resultado del 100% de exhaustividad.

## **CAPÍTULO VIII: RECOMENDACIONES**

1. "Es recomendable que la Facultad de Ingeniería de Sistemas de la Universidad Nacional de la Amazonia Peruana diseñe una herramienta de predicción avanzada que utilice modelos de redes neuronales artificiales con el fin de identificar a los estudiantes con un potencial rendimiento académico insuficiente en los semestres futuros".
2. "Se sugiere la utilización de redes neuronales como una opción óptima para el análisis de datos, utilizando el software MATLAB".
3. "Se recomienda la creación de un registro electrónico de calificaciones correspondientes a la educación secundaria del estudiante que se inscribe en la universidad, lo que permitiría tener más variables predictivas adicionales para la elaboración del modelo".
4. "Se anima a los profesores de ingeniería de sistemas a crear un panel, ya que cuando el modelo entre en funcionamiento, proporcionará información que se visualizará en dicho panel para verificar si las acciones correctivas están logrando los resultados deseados".

## CAPÍTULO IX: REFERENCIAS BIBLIOGRÁFICAS

- Cadenas, G. (2015, November 6). Smartick, matemáticas a un click. Recuperado de Series y Patrones: <https://www.smartick.es/blog/matematicas/recursos-didacticos/series-y-patrones/>.
- Candia Oviedo, D. (2019). Predicción del rendimiento académico de los estudiantes de la UNSAAC a partir de sus datos de ingreso utilizando algoritmos de aprendizaje automático. Tesis de Maestro en Informática, Universidad Nacional de San Antonio Abad del Cusco, Perú. 159 págs.
- Caselli Gismondi, H. (2021). Modelo predictivo basado en Machine Learning como soporte para el seguimiento académico del estudiante universitario. Tesis de Doctor en Ingeniería de Sistemas e Informática, Universidad Nacional del Santa, Perú. 113 pp.
- Edgar Serna M. (2017). DESARROLLO E INNOVACIÓN EN INGENIERÍA. Segunda edición. Medellin-Colombia.
- Flores, et al. (2021). Diseño e implementación de una red neuronal artificial para predecir el rendimiento académico en estudiantes de Ingeniería Civil de la UNIFSLB. Artículo Científico, Universidad Nacional Intercultural Fabiola Salazar Leguía de Bagua-Perú. 21 pp.
- García, M. y Fernández, J. (2012). Análisis del rendimiento académico y factores que lo influyen. Revista de Psicología Educativa, 18(1), 57-65.
- Garceta, R. & Moncecchi, G. (2013). Learning scikit-learn: Machine Learning in Python. Packt Publishing Ltd., Birmingham, United Kingdom.
- García, R. (2018). Un enfoque sobre el rendimiento académico en el campo de las matemáticas en estudiantes de ingeniería. Revista de Investigación en Educación, 8(3), 167-174.
- Gunsha, F., Samaniego, L. & Silva, V. (2016). diseño e implementación de un filtro adaptativo para la cancelación de ruido con redes neuronales utilizando dsp. Tesis. Riobamba: Facultad de Ingeniería, Universidad Nacional de Chimborazo.
- Géron, A. (2019). Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems (2ª edición). O'Reilly Media, Inc.
- Han, J., Kamber, M., & Pei, J. (2012). Data Mining: Concepts and Techniques - 3rd ed. Morgan Kaufmann Publishers, Waltham, Massachusetts, USA.
- Haykin, S. (2009). Neural networks and learning machines - 3rd ed. Prentice Hall, New Jersey, USA.
- Hernández Sampieri, R., Fernández Collado, C. y Baptista Lucio, M. (2014). Metodología de la Investigación - 6ta ed. Mc Graw Hill Education, México D.F., México.
- Huerta, M. (2005). Análisis del rendimiento académico en el nivel universitario. Revista de Educación Superior, 24(2), 123-136.
- iraj Kulkarni. Cross-Entropy for Dummies. <https://towardsdatascience.com/cross-entropy-for-dummies-5189303c>

- Isasi, P. & Galván, I. (2004). *Redes de neuronas artificiales. Un Enfoque Práctico*. Madrid: PEARSON
- Jalil, A. & Misas, M. (2007). Evaluación de pronósticos del tipo de cambio utilizando redes neuronales y funciones de pérdida asimétricas. *Revista Colombiana de Estadística*, 30(1), pp. 143 – 161.
- Jordan, M. I. y Mitchell, T. M. (2015). Aprendizaje automático: tendencias, perspectivas y perspectivas. *Ciencia*, 349(6245), 255-260.
- Kuan, C. & White, H. (1994). Artificial neural networks: an econometric perspective. *Econometric Reviews* 13(1), pp. 1-91.
- Laudon, K. y Laudon, J. (2012). *Sistemas de Información Gerencial - 12va ed.* Prentice Hall, México D.F., México.
- López, J. y Pérez, M. (2009). Evaluación del rendimiento académico: Una revisión de la literatura. *Revista de Investigación Educativa*, 18(2), 107-124.
- López, M., López B. & Díaz V. (2005). Algoritmo de aprendizaje por refuerzo continuo para el control de un sistema de suspensión semi-activa. *Revista Iberoamericana de Ingeniería Mecánica*, 9(2) , pp. 77-91.
- Matich, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Documento de trabajo. Universidad Tecnológica Nacional.
- Paja-Domínguez, H. (2015). *Predicción de rendimiento académico mediante regresión y redes neuronales en los estudiantes de la Escuela Profesional de Ingeniería Estadística e Informática de la Universidad Nacional del Altiplano*. Tesis de Ingeniero Estadístico e Informático, Universidad Nacional del Altiplano, Perú. 120 págs.
- Pérez, F. & Fernández, H. (2008). Las redes neuronales y la evaluación del riesgo de crédito. *Revista Ingenierías Universidad de Medellín*, 6(10), pp. 77-91.
- Ponce Cruz, P. (2010). *Inteligencia artificial con aplicaciones a la ingeniería*. Alfaomega Grupo Editor, México D.F., México.
- Redes Neuronales*. Óscar Gallardo Román. Online [May 2017].
- RODRÍGUEZ PACHECO, E. (2015). *Unsupervised Learning with R*. Birmingham, United Kingdom: Packt Publishing Ltd.
- RUSSELL, S., & NORVIG, P. (2010). *Artificial Intelligence A Modern Approach - 3rd ed.* New Jersey, USA: Prentice Hall.
- Salazar, J. y Palomino, R. (2011). El rendimiento académico de estudiantes universitarios: Una revisión de la literatura. *Revista de Educación Superior*, 40(2), 45-57.
- SINEACE. (2013). *Educación Superior en el Perú: Retos para el aseguramiento de la calidad*. Lima, Perú: Impresión Arte Perú S.A.C.
- Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). *Data Mining: Practical machine learning tools and techniques*. San Francisco, CA: Morgan Kaufmann Publishers.
- ZHOU, S. MCMAHON, A. WALTON, Y LEWIS J., (2002). Forecasting operational demand for an urban water supply zone. *J. Hydrol* , vol. 259, pp.189–202.

## **ANEXOS**

## Anexo 1. Matriz de consistencia

TITULO DE LA INVESTIGACION	PROBLEMAS DE LA INVESTIGACION	OBJETIVOS DE LA INVESTIGACION	HIPÓTESIS	TIPO DE DISEÑO DE ESTUDIO	POBLACIÓN DE ESTUDIO Y PROCESAMIENTO	INSTRUMENTO DE RECOLECCIÓN
Redes neuronales artificiales para pronosticar el rendimiento académico de alumnos de Ingeniería de sistemas e informática de la Universidad nacional de la amazonia peruana	<p><b>Problema general</b> ¿Cuánto mejorará la precisión de la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana después de la implementación de algoritmos de Machine Learning?</p> <p><b>Problemas específicos.</b> - ¿Qué tan efectiva será la implementación del algoritmo de Redes Neuronales Artificiales en mejorar la precisión en la predicción de la cantidad de estudiantes aprobados y no aprobados en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana?</p> <p>¿Qué tan efectiva será la implementación del algoritmo de Redes Neuronales Artificiales en mejorar la precisión en la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana?</p> <p>¿Qué tanto será capaz de predecir el algoritmo de Redes Neuronales Artificiales la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana?</p>	<p><b>Objetivo general</b> Evaluar el impacto de la implementación de algoritmos de Machine Learning en la precisión de la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana</p> <p><b>Objetivos específicos</b> - Evaluar la efectividad de la implementación del algoritmo de Redes Neuronales Artificiales en mejorar la precisión en la predicción de la cantidad de estudiantes aprobados y no aprobados en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, con una exactitud de al menos un 96%</p> <p>- Evaluar la efectividad de la implementación del algoritmo de Redes Neuronales Artificiales en mejorar la precisión en la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, alcanzando una precisión mayor del 97%.</p> <p>- Evaluar la capacidad del algoritmo de Redes Neuronales Artificiales para predecir con una exhaustividad superior al 98% la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana.</p>	<p><b>Hipótesis general</b> La implementación de algoritmos de Machine Learning mejorará la precisión de la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Amazonia Peruana.</p> <p><b>Hipótesis derivadas.</b> <b>HD1.</b> La implementación del algoritmo de Redes Neuronales Artificiales mejorará la precisión en la predicción de la cantidad de estudiantes aprobados y no aprobados en el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, con una exactitud de al menos un 96%. <b>HD2.</b> Mediante la implementación del algoritmo de Redes Neuronales Artificiales, se mejorará la precisión en la predicción de la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonía Peruana, alcanzando una precisión mayor del 97%. <b>HD3.</b> El algoritmo de Redes Neuronales Artificiales será capaz de predecir con una exhaustividad superior al 98% la cantidad de estudiantes que aprobarán y no aprobarán el curso de Álgebra Lineal en la Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de la Amazonia Peruana.</p>	<p><b>Enfoque:</b> Cuantitativo</p> <p><b>Tipo:</b> Aplicada</p> <p><b>Alcance:</b> Predictivo</p> <p><b>Diseño:</b> Diseño de la solución</p>	<p><b>La población</b> son los estudiantes matriculados (430 alumnos) en el I Ciclo 2022 en la FISI-UNAP.</p> <p><b>Muestra.</b> Está compuesta por los estudiantes matriculados en el curso de Algebra lineal (I Ciclo 2022), un total de 35 alumnos. Sin embargo, para el desarrollo del modelo de red neuronal, se seleccionarán 48 alumnos que ya han tomado el curso en ciclos anteriores.</p> <p><b>Procesamiento</b> -uso de MATLAB, -Matriz de confusión -Prueba estadística Z. Permitirá procesar y analizar de manera efectiva los datos recopilados en la tesis.</p>	<p>Encuesta</p> <p>Dataset</p>

## Anexo 2. Instrumentos de recolección de datos



**UNAP**



### ESCUELA DE POSTGRADO

#### FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

#### MAESTRÍA EN INGENIERÍA DE SISTEMAS MENCIÓN EN GERENCIA DE LA TECNOLOGÍA DE LA INFORMACIÓN Y GESTIÓN DE SOFTWARE

#### REDES NEURONALES ARTIFICIALES PARA PRONOSTICAR EL RENDIMIENTO ACADÉMICO DE ALUMNOS DE INGENIERÍA DE SISTEMAS E INFORMÁTICA DE LA UNIVERSIDAD NACIONAL DE LA AMAZONIA PERUANA

#### INSTRUMENTOS DE RECOLECCION DE DATOS

El presente cuestionario tiene como objetivo conocer los factores endógenos y exógenos que influyen en el **rendimiento académico de los estudiantes de la asignatura** ..... de la Universidad Nacional de la Amazonia Peruana.

Sus respuestas servirán para diseñar e implementar un modelo de red neuronal artificial para predecir el rendimiento académico de los estudiantes del curso de ALGEBRA LINEAL

Antes de responder debe tener en cuenta lo siguiente:

- Se garantiza el anonimato y la confidencialidad al responder el cuestionario.
- Responda todo el cuestionario con total sinceridad e imparcialidad.
- Los ítems son de respuesta, marque solo una de ellas y llene los datos numéricos requeridos

ITEM	DIMENSION	INDICADORES	VALOR
1	Determinante Personal	¿Cuál es tu género biológico?	1: Masculino 2: Femenino
2		¿Cuál es tu edad?	Dato numérico:
3		¿En qué distrito radicas?	
4		¿A qué edad ingresaste a la Facultad?	Dato numérico:
5		¿Tienes beca en la Universidad?	1: Beca 2: media beca 3: ninguna
6	Autoconcepto	¿Qué tan responsable te consideras?	1: Muy irresponsable 2: Irresponsable 3: Indiferente 4: Responsable 5: Muy responsable
7		¿Considera que tienes las aptitudes suficientes para culminar el ciclo académico exitosamente?	1: Si 2: No
8		¿Se considera usted una persona inteligente?	1: Poco inteligente 2: Inteligente 3: Muy inteligente
9	Motivación	¿Es de su agrado la carrera profesional elegida?	1: Si 2: No
10		¿Cuántas horas al día dedica a estudiar?	Dato numérico: entre 0-24 horas
11		Si pudieras escoger entre estudiar y no estudiar. ¿Estudiarías?	1: Si 2: No
12	Socio cultural	¿Cuántos integrantes hay en su grupo familiar?	Dato numérico:
13		¿Cuántos integrantes de su grupo familiar trabajan?	Dato numérico:
14		¿Cuántos integrantes de su grupo familiar estudian?	Dato numérico:
15		¿Cuántos integrantes de su grupo familiar son pensionados?	Dato numérico:
16		¿Eres dependiente o independiente de tu padre?	1: Independiente 2: Dependiente
17		¿Eres dependiente o independiente de tu madre?	1: Independiente 2: Dependiente

18	Educación de los padres	¿Qué nivel de educación posee tu padre?	1: Primaria 2: Secundaria 3: Técnica 4: Universitaria
19		¿Qué nivel de educación posee tu madre?	1: Primaria 2: Secundaria 3: Técnica 4: Universitaria
20	Inteligencia Emocional	¿Cómo reacciona frente a un problema de su entorno social?	1: Reacciona con violencia física o verbal 2: Intenta conversar de la situación 3: Con indiferencia
21		¿De que forma influye el stress en su vida académica?	1: Muy negativamente 2: Negativamente 3: No influye 4: Positivamente 5: Muy positivamente
22		¿Qué nivel de empatía presenta hacia sus compañeros?	1: Sin empatía 2: Muy poco empático 3: Indiferente 4: Poco empático 5: Muy empático
23	Económico	¿Cuántas horas a la semana trabaja?	Dato numérico:
24		¿Cuál es el ingreso mensual aproximado en su grupo familiar?	Dato numérico:
25	Escuela de origen	¿En qué tipo de Institución Educativa completo sus estudios Primarios?	1: Público 2: Privado
26		¿En qué tipo de Institución Educativa completo sus estudios Secundarios?	1: Público 2: Privado
27	Académico	¿Cuál es tu promedio ponderado semestral?	Dato numérico:
28		¿Cuál es tu promedio ponderado acumulado?	Dato numérico:
29		Primera nota obtenida en el curso	Dato numérico:
30		Nota final (promedio) del curso pre-requisito	Dato numérico:
31		Número de veces que estuvo matriculado en el curso pre-requisito para poder aprobarlo, incluyendo la ocasión donde lo aprobó	Dato numérico:
32		Número de veces que estuvo matriculado en el curso actual para poder aprobarlo, incluyendo la ocasión donde lo aprobó	Dato numérico:
33	Variable dependiente	Estado del rendimiento académico del curso actual	1: Si aprobó 2: No aprobó
		Nota final del curso	Dato numérico:

### Anexo 3. Código fuente

#### Código Fuente

```
% Solve a Pattern Recognition Problem with a Neural
Network

% Script generated by Neural Pattern Recognition app

% Created 19-Nov-2022 12:21:44

%

% This script assumes these variables are defined:

%

% data - input data.

% data_1 - target data.

x = data;

t = data_1;

% Choose a Training Function

% For a list of all training functions type: help nntrain

% 'trainlm' is usually fastest.

% 'trainbr' takes longer but may be better for challenging
problems.

% 'trainscg' uses less memory. Suitable in low memory
situations.

trainFcn = 'trainscg'; % Scaled conjugate gradient
backpropagation.
```

```
% Create a Pattern Recognition Network

hiddenLayerSize = 5;

net = patternnet(hiddenLayerSize, trainFcn);

% Choose Input and Output Pre/Post-Processing Functions

% For a list of all processing functions type: help
nnprocess

net.input.processFcns =
{'removeconstantrows','mapminmax'};

% Setup Division of Data for Training, Validation, Testing

% For a list of all data division functions type: help
nndivision

net.divideFcn = 'dividerand'; % Divide data randomly

net.divideMode = 'sample'; % Divide up every sample

net.divideParam.trainRatio = 70/100;

net.divideParam.valRatio = 15/100;

net.divideParam.testRatio = 15/100;

% Choose a Performance Function

% For a list of all performance functions type: help
nnperformance

net.performFcn = 'crossentropy'; % Cross-Entropy
```

```

% Choose Plot Functions

% For a list of all plot functions type: help nnplot

net.plotFcns =
{'plotperform','plottrainstate','ploterrhist', ...
    'plotconfusion', 'plotroc'};

% Train the Network

[net,tr] = train(net,x,t);

% Test the Network

y = net(x);

e = gsubtract(t,y);

performance = perform(net,t,y)

tind = vec2ind(t);

yind = vec2ind(y);

percentErrors = sum(tind ~= yind)/numel(tind);

% Recalculate Training, Validation and Test Performance

trainTargets = t .* tr.trainMask{1};

valTargets = t .* tr.valMask{1};

testTargets = t .* tr.testMask{1};

trainPerformance = perform(net,trainTargets,y)

valPerformance = perform(net,valTargets,y)

testPerformance = perform(net,testTargets,y)

```

```
% View the Network

view(net)

% Plots

% Uncomment these lines to enable various plots.

%figure, plotperform(tr)

%figure, plottrainstate(tr)

%figure, ploterrhist(e)

%figure, plotconfusion(t,y)

%figure, plotroc(t,y)

% Deployment

% Change the (false) values to (true) to enable the
following code blocks.

% See the help for each generation function for more
information.

if (false)

    % Generate MATLAB function for neural network for
application

    % deployment in MATLAB scripts or with MATLAB Compiler
and Builder

    % tools, or simply to examine the calculations your
trained neural

    % network performs.
```

```
    genFunction(net, 'myNeuralNetworkFunction');

    y = myNeuralNetworkFunction(x);

end

if (false)

    % Generate a matrix-only MATLAB function for neural
network code

    % generation with MATLAB Coder tools.

genFunction(net, 'myNeuralNetworkFunction', 'MatrixOnly', 'yes');

    y = myNeuralNetworkFunction(x);

end

if (false)

    % Generate a Simulink diagram for simulation or
deployment with.

    % Simulink Coder tools.

gensim(net);

end
```

## Dataset sin depurar 01.

N°	Nombre de la asignatura por la que realiza la encuesta	¿Cual es tu genero biológico?	¿Cual es tu edad?	¿En que distrito radicas?	¿A que edad ingresaste a la Facultad?	¿Tienes beca en la Universidad?	¿Que tan responsable te consideras?
1	Algebra Lineal	Masculino	34	San Juan Bautista	33	Ninguna	Muy responsable
2	Algebra Lineal	Masculino	27	Iquitos	26	Ninguna	Responsable
3	Algebra Lineal	Masculino	22	Iquitos	20	Ninguna	Irresponsable
4	Algebra Lineal	Masculino	18	San Juan Bautista	17	Ninguna	Responsable
5	Algebra Lineal	Masculino	18	San Juan Bautista	17	Ninguna	Responsable
6	Algebra Lineal	Masculino	18	San Juan Bautista	17	Ninguna	Responsable
7	Algebra Lineal	Femenino	24	San Juan Bautista	23	Ninguna	Responsable
8	Algebra Lineal	Masculino	18	Punchana	17	Ninguna	Responsable
9	Algebra Lineal	Femenino	39	San Juan Bautista	37	Ninguna	Muy responsable
10	Algebra Lineal	Femenino	19	Belen	16	Ninguna	Responsable
11	Algebra Lineal	Masculino	26	Iquitos	24	Ninguna	Responsable
12	Algebra Lineal	Masculino	19	Iquitos	17	Ninguna	Muy responsable
13	Algebra Lineal	Masculino	19	San Juan Bautista	17	Ninguna	Responsable
14	Algebra Lineal	Masculino	35	Iquitos	31	Ninguna	Responsable
15	Algebra Lineal	Masculino	20	San Juan Bautista	19	Ninguna	Responsable
16	Algebra Lineal	Masculino	23	San Juan Bautista	23	Ninguna	Responsable
17	Algebra Lineal	Masculino	19	Punchana	18	Ninguna	Responsable
18	Algebra Lineal	Masculino	18	San Juan Bautista	17	Ninguna	Indiferente
19	Algebra Lineal	Masculino	19	Iquitos	18	Ninguna	Responsable
20	Algebra Lineal	Masculino	18	Iquitos	17	Ninguna	Responsable
21	Algebra Lineal	Masculino	20	BELEN	16	Ninguna	Responsable
22	Algebra Lineal	Masculino	33	Requena	31	Ninguna	Responsable
23	Algebra Lineal	Masculino	18	Punchana	16	Ninguna	Responsable
24	Algebra Lineal	Masculino	19	San Juan Bautista	18	Ninguna	Responsable
25	Algebra Lineal	Masculino	18	Iquitos	17	Ninguna	Responsable
26	Algebra Lineal	Masculino	19	San Juan Bautista	17	Ninguna	Responsable
27	Algebra Lineal	Masculino	18	Iquitos	17	Ninguna	Indiferente
28	Algebra Lineal	Masculino	39	Iquitos	38	Ninguna	Muy responsable
29	Algebra Lineal	Masculino	23	Iquitos	22	Ninguna	Responsable
30	Algebra Lineal	Femenino	22	Iquitos	21	Ninguna	Responsable
31	Algebra Lineal	Masculino	36	Iquitos	35	Ninguna	Responsable
32	Algebra Lineal	Masculino	21	Iquitos	18	Ninguna	Indiferente
33	Algebra Lineal	Masculino	19	Iquitos	18	Ninguna	Responsable
34	Algebra Lineal	Masculino	38	Iquitos	37	Ninguna	Responsable
35	Algebra Lineal	Masculino	23	Belen	19	Ninguna	Responsable
36	Algebra Lineal	Masculino	39	Iquitos	35	Ninguna	Responsable
37	Algebra Lineal	Masculino	32	San Juan Bautista	29	Ninguna	Responsable
38	Algebra Lineal	Masculino	18	Belén	17	Ninguna	Indiferente
39	Algebra Lineal	Masculino	20	Belén	19	Ninguna	Responsable
40	Algebra Lineal	Masculino	18	Belen	16	Ninguna	Responsable

**Fuente.** Elaboración propia.

## DATASET Sin Depurar 02.

¿Considera que tienes las aptitudes suficientes para culminar el ciclo académico exitosamente?	¿Se considera usted una persona inteligente?	¿Es de su agrado la carrera profesional elegida?	¿Cuántas horas al día dedica a estudiar?	Si pudieras escoger entre estudiar y no estudiar. ¿Estudiarías?	¿Cuántos integrantes hay en su grupo familiar?	¿Cuántos integrantes de su grupo familiar trabajan?	¿Cuántos integrantes de su grupo familiar estudian?	¿Cuántos integrantes de su grupo familiar son pensionados?	¿Eres dependiente o independiente de tu padre?
Si	Muy inteligente	Si	6	Si	3	20	3	0	Independiente
Si	Inteligente	Si	3	Si	5	2	2	0	Independiente
No	Poco inteligente	Si	2	Si	5	3	2	0	Dependiente
Si	Inteligente	Si	4	Si	6	3	2	1	Independiente
Si	Inteligente	Si	4	Si	6	3	2	1	Independiente
Si	Inteligente	Si	5	Si	6	3	2	1	Independiente
Si	Poco inteligente	Si	2	Si	2	1	1	0	Independiente
Si	Inteligente	Si	7	Si	3	1	2	0	Independiente
Si	Inteligente	Si	8	Si	4	2	2	0	Independiente
Si	Inteligente	Si	3	Si	4	2	3	2	Dependiente
Si	Inteligente	Si	6	Si	5	3	1	0	Independiente
Si	Inteligente	Si	10	Si	6	4	2	0	Dependiente
Si	Inteligente	Si	4	Si	7	4	3	0	Dependiente
Si	Inteligente	Si	3	Si	3	2	3	0	Independiente
Si	Inteligente	Si	2	Si	3	1	2	1	Dependiente
Si	Inteligente	Si	4	Si	1	1	1	1	Independiente
Si	Inteligente	Si	4	Si	5	2	2	1	Dependiente
Si	Inteligente	Si	4	Si	4	2	3	1	Dependiente
Si	Inteligente	Si	2	Si	6	2	3	0	Dependiente
Si	Inteligente	Si	5	Si	4	2	1	0	Independiente
Si	Inteligente	Si	2	Si	8	4	6	0	Dependiente
Si	Inteligente	Si	8	Si	1	1	1	0	Independiente
Si	Inteligente	Si	4	Si	3	2	1	0	Dependiente
Si	Inteligente	Si	9	Si	4	2	2	0	Dependiente
Si	Poco inteligente	Si	3	Si	4	2	2	0	Dependiente
Si	Inteligente	Si	4	Si	1	1	0	0	Independiente
Si	Poco inteligente	No	11	Si	5	2	2	0	Dependiente
Si	Inteligente	Si	6	Si	5	2	2	0	Independiente
Si	Inteligente	Si	4	Si	4	4	1	0	Independiente
Si	Poco inteligente	Si	4	Si	3	3	3	1	Independiente
Si	Inteligente	Si	2	Si	3	1	2	0	Independiente
Si	Inteligente	Si	5	Si	11	5	6	1	Dependiente
Si	Muy inteligente	Si	9	Si	5	2	2	1	Dependiente
Si	Inteligente	Si	2	Si	4	2	2	0	Independiente
No	Inteligente	Si	3	Si	3	2	2	0	Dependiente
Si	Inteligente	Si	2	Si	4	2	3	0	Independiente
Si	Poco inteligente	Si	4	Si	8	3	2	0	Independiente
Si	Inteligente	No	2	Si	7	3	2	1	Dependiente
Si	Muy inteligente	Si	5	Si	3	2	1	0	Dependiente
Si	Inteligente	Si	6	Si	4	2	2	0	Dependiente

**Fuente.** Elaboración propia.

## DATASET Sin Depurar 03.

¿Eres dependiente o independiente de tu madre?	¿Qué nivel de educación posee tu padre?	¿Qué nivel de educación posee tu madre?	¿Cómo reacciona frente a un problema de su entorno social?	¿De que forma influye el estrés en su vida académica?	¿Qué nivel de empatía presenta hacia sus compañeros?	¿Cuántas horas a la semana trabaja?	¿Cuál es el ingreso mensual aproximado en su grupo familiar?	¿En qué tipo de Institución Educativa completo sus estudios Primarios?
Independiente	Tecnica	Universitaria	conversar de la s	No influye	Muy empático	8	1200	Público
Independiente	Tecnica	Secundaria	conversar de la s	No influye	Empático	11	1200	Público
Dependiente	Secundaria	Secundaria	conversar de la s	Negativamente	Empático	24	150	Público
Dependiente	Universitaria	Tecnica	conversar de la s	Positivamente	Empático	0	5000	Público
Dependiente	Universitaria	Tecnica	conversar de la s	Positivamente	Empático	7	5000	Público
Dependiente	Universitaria	Tecnica	conversar de la s	Positivamente	Empático	7	5000	Público
Dependiente	Universitaria	Tecnica	conversar de la s	No influye	Muy poco empático	12	600	Público
Dependiente	Universitaria	Secundaria	conversar de la s	Negativamente	Empático	18	1000	Público
Independiente	Tecnica	Tecnica	conversar de la s	Negativamente	Empático	40	2500	Público
Dependiente	Universitaria	Universitaria	conversar de la s	Positivamente	Muy empático	0	500	Público
Independiente	Secundaria	Secundaria	conversar de la s	Negativamente	Empático	48	4500	Público
Dependiente	Universitaria	Tecnica	Con indiferencia	Negativamente	Indiferente	0	3000	Privado
Dependiente	Universitaria	Universitaria	conversar de la s	Negativamente	Empático	30	3000	Público
Independiente	Secundaria	Secundaria	conversar de la s	Negativamente	Empático	72	4500	Público
Dependiente	Universitaria	Secundaria	conversar de la s	No influye	Empático	0	1000	Público
Independiente	Secundaria	Secundaria	conversar de la s	No influye	Empático	0	800	Privado
Independiente	Tecnica	Tecnica	conversar de la s	Positivamente	Empático	6	2000	Público
Dependiente	Tecnica	Tecnica	conversar de la s	No influye	Empático	5	4000	Privado
Dependiente	Secundaria	Secundaria	Con indiferencia	No influye	Muy poco empático	4	1000	Público
Dependiente	Tecnica	Tecnica	conversar de la s	Negativamente	Empático	0	1600	Público
Dependiente	Tecnica	Secundaria	conversar de la s	No influye	Indiferente	9	2000	Público
Independiente	Secundaria	Secundaria	conversar de la s	Negativamente	Empático	20	500	Público
Dependiente	Primaria	Tecnica	conversar de la s	No influye	Empático	0	350	Público
Dependiente	Universitaria	Secundaria	conversar de la s	Negativamente	Empático	0	2300	Público
Dependiente	Universitaria	Secundaria	conversar de la s	Negativamente	Empático	8	1500	Público
Dependiente	Universitaria	Universitaria	Con indiferencia	Negativamente	Empático	0	3500	Privado
Independiente	Universitaria	Tecnica	Con indiferencia	Negativamente	Empático	0	5000	Privado
Independiente	Universitaria	Universitaria	conversar de la s	No influye	Empático	30	3500	Público
Independiente	Secundaria	Secundaria	conversar de la s	Negativamente	Empático	54	1200	Público
Independiente	Tecnica	Tecnica	conversar de la s	Negativamente	Empático	6	3000	Público
Independiente	Primaria	Primaria	conversar de la s	Negativamente	Empático	8	1500	Público
Dependiente	Secundaria	Tecnica	conversar de la s	Negativamente	Empático	48	1000	Público
Dependiente	Universitaria	Universitaria	conversar de la s	No influye	Empático	8	3500	Privado
Independiente	Tecnica	Secundaria	conversar de la s	No influye	Empático	50	5000	Público
Independiente	Tecnica	Tecnica	conversar de la s	Negativamente	Empático	0	3000	Público
Independiente	Secundaria	Primaria	conversar de la s	Negativamente	Empático	60	2000	Público
Independiente	Primaria	Secundaria	conversar de la s	Positivamente	Muy poco empático	48	900	Público
Dependiente	Tecnica	Secundaria	conversar de la s	Negativamente	Empático	0	00	Privado
Dependiente	Tecnica	Secundaria	conversar de la s	Negativamente	Empático	10	2000	Público
Dependiente	Secundaria	Secundaria	conversar de la s	Negativamente	Empático	0	1500	Privado

**Fuente.** Elaboración propia.

## DATASET Sin Depurar 04.

¿En qué tipo de Institución Educativa completo sus estudios Secundarios?	¿Cuál es tu promedio ponderado semestral?	¿Cuál es tu promedio ponderado acumulado?	Primera nota obtenida en el curso	Nota final (promedio) del curso pre-requisito	Numero de veces que estuvo matriculado en el curso pre-requisito para poder aprobarlo,	Numero de veces que estuvo matriculado en el curso actual para	Estado del rendimiento académico del curso actual	¿En qué semestre académico siguió esta asignatura?	Nota final del curso
Privado	13.5	14	14	14	1	1	Si aprobo	2022-1	14
Privado	13	14	13	12	2	2	Si aprobo	2022-1	12
Público	15	15	0	0	1	1	No aprobo	2022-1	0
Público	14	14	12	12	2	2	Si aprobo	2021-1	15
Público	15	14	12	13	1	2	Si aprobo	2021-1	14
Público	14	14	14	15	2	2	Si aprobo	2021-1	15
Privado	13	13	9	12	1	2	No aprobo	2021-2	0
Público	16,136	16,136	15	16	1	1	Si aprobo	2021-2	15
Público	13.4	14.50	14	14	1	1	Si aprobo	2021-2	14
Público	12	13	12	14	2	1	No aprobo	2021-2	0
Público	14	14	11	13	0	0	Si aprobo	2022-1	13
Privado	14.4	14.6	15	15	1	1	Si aprobo	2022-1	13
Privado	14	14	0	11	2	1	No aprobo	2022-1	0
Privado	13	13	11	14	1	2	No aprobo	2022-1	7
Público	14	14	07	0	1	1	No aprobo	2022-1	0
Público	13.75	14	00	00	00	00	No aprobo	2022-1	00
Público	14	15	12	15	1	2	No aprobo	2021-1	00
Privado	14	14	16	12	1	1	No aprobo	2021-1	0
Público	13	13	13	12	2	2	No aprobo	2021-2	10
Público	15,526	15,486	0	0	1	1	No aprobo	2022-1	0
Público	13	11	07	13	2	2	Si aprobo	2021-2	14
Público	15,111	15,867	05	16	2	1	Si aprobo	2021-2	12
Público	15.2	15.6	13	15	1	1	Si aprobo	2021-2	13
Público	16	16	15	17	1	1	Si aprobo	2021-2	18
Público	13	13	13	13	0	1	Si aprobo	2022-1	13
Privado	15	15	8	0	0	0	No aprobo	2021-1	0
Privado	15	15	10	0	0	0	No aprobo	2022-1	0
Privado	16	16	11	15	1	1	Si aprobo	2021-2	15
Público	15	15	15	15	1	1	Si aprobo	2021-2	15
Público	12	13	10	10	2	2	No aprobo	2021-2	10
Público	00	00	00	00	2	2	No aprobo	2022-1	00
Público	11	11	12	0	1	2	No aprobo	2022-1	0
Privado	15	15	0	0	1	1	No aprobo	2022-1	0
Público	14	14	0	14	1	1	No aprobo	2022-1	0
Público	12	12	11	6	3	3	No aprobo	2022-1	6
Público	14	13	0	0	1	1	No aprobo	2022-1	0
Público	13.5	13	0	0	0	0	Si aprobo	2022-1	0
Privado	14	15	0	0	0	1	Si aprobo	2022-1	0
Público	15.5	15.45	11	14	1	1	Si aprobo	2021-2	16
Público	14,565	14,978	12	12	1	1	No aprobo	2021-2	0

Fuente. Elaboración propia.

## Anexo 5. Datos para entrenar la red.

### Datos de INPUT 01

0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00576271	0.00457627	0.00305085	0.00305085	0.00305085	0.00305085	0.00661017	0.00440678	0.00322034	0.0059322	0.00322034	0.00338983	0.00559322	0.00305085	0.00322034	0.00067797
0.00067797	0.00016949	0.00067797	0.00067797	0.00067797	0.00067797	0.00033898	0.00067797	0.00016949	0.00016949	0.00016949	0.00050847	0.00016949	0.00033898	0.00067797	0.00067797
0.00559322	0.00440678	0.00288136	0.00288136	0.00288136	0.00288136	0.00627119	0.0040678	0.00288136	0.00525424	0.00305085	0.00271186	0.00525424	0.00271186	0.00305085	0.00067797
0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847
0.00084746	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00084746	0.00067797	0.00084746	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00101695	0.00050847	0.00067797	0.00067797	0.00084746	0.00118644	0.00135593	0.00101695	0.00169492	0.00050847	0.00033898	0.00033898	0.00135593	0.00067797	0.00152542	0.00067797
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00050847	0.00084746	0.00101695	0.00101695	0.00101695	0.00050847	0.00067797	0.00084746	0.00101695	0.00050847	0.00101695	0.00135593	0.00016949	0.00050847	0.00067797	0.00067797
0.00033898	0.00033898	0.00050847	0.00050847	0.00050847	0.00016949	0.00033898	0.00050847	0.00067797	0.00033898	0.00033898	0.00067797	0.00016949	0.00033898	0.00033898	0.00033898
0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00016949	0.00033898	0.00050847	0.00050847	0.00101695	0.00016949	0.00016949	0.00033898	0.00033898
0	0	0.00016949	0.00016949	0.00016949	0	0	0	0	0	0	0	0	0	0	0
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00033898	0.00033898	0.00016949	0.00033898	0.00033898	0.00033898
0.00016949	0.00016949	0.00033898	0.00033898	0.00033898	0.00033898	0.00016949	0.00016949	0.00033898	0.00016949	0.00033898	0.00033898	0.00016949	0.00033898	0.00033898	0.00033898
0.00050847	0.00050847	0.00067797	0.00067797	0.00067797	0.00067797	0.00050847	0.00033898	0.00067797	0.00033898	0.00033898	0.00050847	0.00033898	0.00016949	0.00067797	0.00067797
0.00067797	0.00033898	0.00050847	0.00050847	0.00050847	0.00033898	0.00050847	0.00033898	0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00050847	0.00033898	0.00033898
0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00050847	0.00033898	0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898
0.00050847	0.00050847	0.00067797	0.00067797	0.00067797	0.00033898	0.00033898	0.00033898	0.00016949	0.00033898	0.00050847	0.00050847	0.00033898	0.00050847	0.00033898	0.00033898
0.00084746	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00050847	0.00067797	0.00033898	0.00050847	0.00067797	0.00067797	0.00067797	0.00067797
0.00135593	0.00186441	0	0.00118644	0.00118644	0.00305085	0.00677966	0.00813559	0	0.01220339	0.00067797	0.00152542	0.00338983	0	0	0
0.20338983	0.20338983	0.84745763	0.84745763	0.84745763	0.16949153	0.42372881	0.76271186	0.50847458	0.76271186	0.16949153	0.33898305	0.08474576	0.05932203	0.38983051	0.38983051
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00033898	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00228814	0.00220339	0.00237288	0.00254237	0.00237288	0.00273559	0.00227119	0.00237288	0.00244068	0.00220339	0.00220339	0.00220339	0.00256102	0.00257627	0.00271186	0.00271186
0.00237288	0.00237288	0.00237288	0.00237288	0.00237288	0.00273559	0.00245763	0.00237288	0.00247458	0.00220339	0.00220339	0.00186441	0.00268983	0.00264407	0.00271186	0.00271186
0.00237288	0.00220339	0.0020339	0.0020339	0.00237288	0.00254237	0.00237288	0.00186441	0.00254237	0.00186441	0.00220339	0.00186441	0.00084746	0.00220339	0.00254237	0.00254237
0.00237288	0.0020339	0.0020339	0.00220339	0.00254237	0.00271186	0.00237288	0.00220339	0.00254237	0.00237288	0.0020339	0.00220339	0.00271186	0.00254237	0.00288136	0.00288136
0.00016949	0.00033898	0.00033898	0.00016949	0.00033898	0.00016949	0.00016949	0	0.00016949	0.00016949	0.00033898	0.00033898	0.00033898	0.00016949	0.00016949	0.00016949
0.00016949	0.00033898	0.00033898	0.00033898	0.00033898	0.00016949	0.00016949	0	0.00016949	0.00033898	0.00033898	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949

Fuente. Elaboración propia.

### Datos de INPUT 02 continuación

0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00305085	0.00661017	0.00389831	0.00372881	0.00389831	0.00338983	0.00305085	0.00338983	0.00288136	0.00322034	0.00322034	0.00305085	0.00389831	0.00322034	0.00322034
0.00016949	0.00016949	0.00016949	0.00016949	0.00050847	0.00016949	0.00016949	0.00067797	0.00067797	0.00016949	0.00016949	0.00016949	0.00016949	0.00067797	0.00067797
0.00288136	0.00644068	0.00372881	0.00355932	0.00322034	0.00322034	0.00271186	0.00305085	0.00271186	0.00305085	0.00288136	0.00288136	0.00372881	0.00288136	0.00305085
0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00016949	0.00050847
0.00067797	0.00084746	0.00067797	0.00067797	0.00067797	0.00067797	0.00050847	0.00084746	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00050847	0.00067797
0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00016949	0.00033898	0.00033898	0.00016949	0.00033898	0.00050847	0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00016949
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00050847	0.00101695	0.00067797	0.00067797	0.00050847	0.00084746	0.00050847	0.00084746	0.00067797	0.00067797	0.00084746	0.00050847	0.00084746	0.00033898	0.00084746
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00067797	0.00084746	0.00067797	0.00050847	0.00050847	0.00050847	0.00118644	0.00067797	0.00135593	0.00118644	0.00067797	0.00067797	0.00067797	0.00101695	0.00050847
0.00033898	0.00033898	0.00067797	0.00050847	0.00033898	0.00033898	0.00067797	0.00016949	0.00033898	0.00084746	0.00033898	0.00016949	0.00067797	0.00033898	0.00016949
0.00033898	0.00033898	0.00016949	0.00050847	0.00033898	0.00016949	0.00033898	0.00033898	0.00067797	0.00050847	0.00050847	0.00033898	0.00016949	0.00050847	0.00050847
0	0	0	0.00016949	0	0	0.00016949	0	0	0	0.00033898	0	0	0.00016949	0
0.00033898	0.00016949	0.00016949	0.00016949	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00016949	0.00016949	0.00033898
0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00016949	0.00033898	0.00033898
0.00067797	0.00067797	0.00033898	0.00050847	0.00050847	0.00050847	0.00050847	0.00016949	0.00050847	0.00033898	0.00050847	0.00033898	0.00033898	0.00033898	0.00050847
0.00033898	0.00067797	0.00033898	0.00050847	0.00050847	0.00033898	0.00033898	0.00016949	0.00067797	0.00033898	0.00050847	0.00067797	0.00033898	0.00033898	0.00016949
0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00050847	0.00033898
0.00033898	0.00050847	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00033898	0.00033898	0.00033898	0.00050847	0.00016949	0.00016949
0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00084746	0.00067797	0.00067797	0.00067797	0.00067797	0.00084746	0.00067797	0.00067797
0.00135593	0.00508475	0.00915254	0.00101695	0	0.00169492	0.00813559	0	0	0.00169492	0	0	0.00152542	0	0.00050847
0.25423729	0.59322034	0.20338983	0.50847458	0.50847458	0.33898305	1	0.05084746	0.84745763	0.50847458	0.59322034	0.16949153	0.20338983	0.15254237	0.05084746
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949
0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949
0.00220339	0.00271186	0.00254237	0.0020339	0.0020339	0.00262712	0.00079492	0.00260169	0.00263559	0.00268983	0.00271186	0.00245424	0.00264576	0.00254237	0.00237288
0.00220339	0.00271186	0.00254237	0.00220339	0.0020339	0.00261864	0.00087797	0.00266271	0.00263559	0.00268983	0.00271186	0.00253729	0.0026322	0.00254237	0.0020339
0.00220339	0.00186441	0.00254237	0.00169492	0.00186441	0.00186441	0.00186441	0.00237288	0.00254237	0.00237288	0.00322034	0.00084746	0.00254237	0.0020339	0.0020339
0.00220339	0.00254237	0.00254237	0.00169492	0.00101695	0.00237288	0.00254237	0.00237288	0.00254237	0.00254237	0.00322034	0.00254237	0.00254237	0.0020339	0.0020339
0	0.00016949	0.00016949	0.00033898	0.00050847	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00016949	0.00016949	0.00016949	0.00033898	0.00050847	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949

**Fuente.** Elaboración propia.

### Datos de INPUT 03 continuación

0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949
0.00322034	0.00305085	0.00322034	0.00322034	0.00372881	0.00644068	0.00661017	0.00322034	0.00322034	0.00661017	0.00305085	0.00322034	0.00305085	0.00338983	0.00305085	0.00322034	0.00389831	0.00322034
0.00016949	0.00067797	0.00033898	0.00033898	0.00033898	0.00016949	0.00067797	0.00067797	0.00050847	0.00016949	0.00016949	0.00033898	0.00016949	0.00067797	0.00067797	0.00033898	0.00016949	0.00067797
0.00271186	0.00288136	0.00305085	0.00305085	0.00355932	0.00576271	0.00627119	0.00288136	0.00305085	0.00644068	0.00271186	0.00288136	0.00288136	0.00288136	0.00288136	0.00305085	0.00338983	0.00305085
0.00016949	0.00050847	0.00050847	0.00050847	0.00016949	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00050847	0.00016949	0.00050847	0.00050847	0.00050847	0.00050847
0.00067797	0.00067797	0.00067797	0.00050847	0.00067797	0.00067797	0.00084746	0.00084746	0.00067797	0.00067797	0.00050847	0.00067797	0.00067797	0.00050847	0.00067797	0.00084746	0.00067797	0.00050847
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00033898	0.00033898
0.00033898	0.00033898	0.00033898	0.00050847	0.00033898	0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00033898	0.00033898
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00033898	0.00135593	0.00067797	0.00016949	0.00118644	0.00084746	0.00135593	0.00084746	0.00050847	0.00084746	0.00050847	0.00067797	0.00033898	0.00016949	0.00067797	0.00050847	0.00135593	0.00101695
0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00084746	0.00050847	0.00084746	0.00135593	0.00067797	0.00067797	0.00067797	0.00033898	0.00084746	0.00084746	0.00050847	0.00101695	0.00084746	0.00118644	0.00067797	0.00067797	0.00101695	0.00067797
0.00033898	0.00050847	0.00033898	0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00050847	0.00050847	0.00050847	0.00067797	0.00050847
0.00033898	0.00016949	0.00016949	0.00084746	0.00016949	0.00033898	0.00033898	0.00016949	0.00033898	0.00050847	0.00016949	0.00067797	0.00050847	0.00067797	0.00033898	0.00033898	0.00050847	0.00016949
0	0	0.00016949	0.00016949	0	0	0	0	0	0	0	0	0	0.00016949	0	0	0	0
0.00033898	0.00033898	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00016949	0.00033898
0.00033898	0.00033898	0.00033898	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898
0.00033898	0.00033898	0.00033898	0.00016949	0.00033898	0.00033898	0.00050847	0.00372881	0.00033898	0.00050847	0.00033898	0.00050847	0.00067797	0.00050847	0.00067797	0.00050847	0.00033898	0.00033898
0.00033898	0.00050847	0.00033898	0.00033898	0.00016949	0.00033898	0.00050847	0.00033898	0.00050847	0.00067797	0.00050847	0.00067797	0.00067797	0.00050847	0.00050847	0.00050847	0.00033898	0.00033898
0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898
0.00033898	0.00033898	0.00050847	0.00033898	0.00050847	0.00050847	0.00033898	0.00067797	0.00050847	0.00033898	0.00033898	0.00033898	0.00033898	0.00033898	0.00016949	0.00033898	0.00050847	0.00050847
0.00067797	0.00067797	0.00067797	0.00050847	0.00016949	0.00067797	0.00067797	0.00084746	0.00067797	0.00067797	0.00084746	0.00067797	0.00067797	0.00067797	0.00067797	0.00067797	0.00084746	0.00067797
0	0.00135593	0	0.01186441	0.00067797	0.00762712	0.00677966	0.00067797	0.00271186	0.00508475	0.00016949	0.00084746	0	0.00016949	0	0.00118644	0	0
0.33898305	0.50847458	0.33898305	0.42372881	0.16440678	0.25423729	0.42372881	0.10169492	0.06779661	0.61016949	0.08474576	0.6779661	0.50847458	0.6779661	0.16949153	0.25423729	0.08474576	0.16949153
0.00016949	0.00033898	0.00016949	0.00016949	0.00033898	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00016949	0.00033898	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00016949	0.00033898	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949
0.00210847	0.00254237	0.00237288	0.00220339	0.0024678	0.00237288	0.00232203	0.00237288	0.00254237	0.00254237	0.00271186	0.00257458	0.00247627	0.00220339	0.00254237	0.00237288	0.0020339	0.00237288
0.00228814	0.00254237	0.00237288	0.0020339	0.00250508	0.00220339	0.00228814	0.00237288	0.00254237	0.00254237	0.00271186	0.00257458	0.00253051	0.0020339	0.00254237	0.00237288	0.00220339	0.00220339
0.00067797	0.00220339	0.00169492	0.0020339	0.00254237	0.00237288	0.0020339	0.0020339	0.00186441	0.00169492	0.00067797	0.00169492	0.00169492	0.00135593	0.00254237	0.00101695	0.00237288	0.00033898
0.0020339	0.00220339	0.00084746	0.0020339	0.00237288	0.0020339	0.00237288	0.0020339	0.00186441	0.00254237	0.00237288	0.00254237	0.00254237	0.00135593	0.00254237	0.00288136	0.00237288	0.00254237
0.00033898	0.00016949	0.00033898	0.00033898	0	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00033898	0.00016949	0.00016949	0.00033898	0.00016949
0.00033898	0.00016949	0.00033898	0.00033898	0	0.00033898	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0.00016949	0	0.00016949	0.00016949

Fuente. Elaboración propia.

