

**UNIVERSIDAD NACIONAL DEL
CALLAO**
FACULTAD DE INGENIERÍA INDUSTRIAL Y DE
SISTEMAS
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS



**PREDICCIÓN DEL RENDIMIENTO ACADÉMICO MEDIANTE
REDES NEURONALES**

TESIS PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO DE SISTEMAS

Autor: BACHILLER ZEVALLOS SALAZAR, RODOLFO JOEL

Callao, Julio, 2017

PERÚ

DEDICATORIA

A mi padre Rodolfo por ser un ejemplo de todo buen hombre.

AGRADECIMIENTO

A mi familia que siempre están conmigo, a mis amigos que me dan la motivación para seguir en pie de lucha, a mi asesor el Ing, Manuel Alcántara Ramírez, por brindarme su apoyo y experiencia, y a la realidad que gracias a ella es que lucho por ese gran sueño utópico.

ÍNDICE

RESUMEN	7
ABSTRACT	8
INTRODUCCIÓN	9
I PLANTEAMIENTO DE LA INVESTIGACIÓN	11
1.1 Identificación del problema	11
1.2 Formulación del problema	12
1.2.1 General	12
1.2.2 Específicos	13
1.3 Objetivos de la investigación	13
1.3.1 General	13
1.3.2 Específicos	13
1.4 Justificación	14
1.4.1 Por su naturaleza	14
1.4.2 Según su magnitud	14
1.4.3 Por su trascendencia	14
1.5 Importancia	15
II MARCO TEÓRICO	16
2.1 Antecedentes de estudio	16
2.2 Marco conceptual	20
2.2.1 El aprendizaje	20
2.2.2 Rendimiento académico	21
2.2.3 Red neuronal biológica	22
2.2.4 La neurona artificial	24
2.2.5 Características de las redes neuronales artificiales	27
2.2.6 Entrenamiento de las redes neuronales artificiales	28
2.2.7 Perceptrón	31
2.2.8 Red Backpropagation	34
2.2.9 Resilient Backpropagation	39

ÍNDICE

III VARIABLES E HIPÓTESIS	42
3.1 Variables de la investigación	42
3.1.1 Variable dependiente	42
3.1.2 Variable independiente	42
3.2 Operacionalización de variables	43
3.3 Hipótesis de la investigación	43
3.3.1 General	43
3.3.2 Específicos	43
IV METODOLOGÍA	44
4.1 Tipo de investigación	44
4.2 Diseño de la investigación	44
4.3 Población y muestra	46
4.4 Técnicas e instrumentos de recolección de datos	46
4.4.1 Técnicas de muestreo	46
4.4.2 Recopilación de datos	47
4.4.3 Procesamiento	47
4.5 Procedimientos de recolección de datos	47
4.6 Procesamiento estadístico y análisis de datos	48
V RESULTADOS	50
5.1 Uso de redes neuronales artificiales	50
5.1.1 Selección del tipo de red neuronal artificial	51
5.1.2 Selección de la técnica de aprendizaje	51
5.1.3 Selección de la función de activación	52
5.2 Recolección de datos y procesamiento	53
5.2.1 Variables que influyen en el rendimiento académico	53
5.2.2 Selección de indicadores que influyen en el rendimiento académico	58
5.2.3 Recolección de información	60
5.2.4 Diseño de encuesta	62
5.3 Desarrollo de la red neuronal artificial	68
5.3.1 Normalización de los datos	68
5.3.2 Creación de la red neuronal artificial	75
VI DISCUSIÓN DE RESULTADOS	81
6.1 Constratación de hipótesis con los resultados	81
6.2 Contrastación de resultados con otros estudios similares	82
VII CONCLUSIONES	83
7.1 Conclusiones	83
VIII RECOMENDACIONES	85
8.1 Recomendaciones	85

ÍNDICE

REFERENCIAS	89
Anexos	90
A Matriz de consistencia	91
B Anexo para respaldo de la investigación	93
2.1 Formato de encuesta para estudiantes	93
2.1.1 Características de la escuela en relación con el estudiante	93
2.1.2 Características de los materiales de educación	93
2.1.3 Prácticas pedagógicas	94
2.1.4 Características del estudiante	94
2.1.5 Características de la salud	95
2.1.6 Características socioeconómicas	96
2.2 Formato de encuesta para profesores	96
2.2.1 Características de la escuela	96
2.2.2 Características del docente	97
2.2.3 Practicas pedagógicas	98
2.2.4 Administración del colegio	98

Índice de tablas

2.1	TIPOS DE APRENDIZAJE	28
3.1	OPERACIONALIZACIÓN DE LAS VARIABLES DE ESTUDIO	43
4.1	TIPOS DE DATOS UTILIZADOS	47
4.2	CANTIDAD DE ESTUDIANTES POR AÑO EN LA PRUEBA PILOTO	48
4.3	CANTIDAD DE ESTUDIANTES POR COLEGIO	49
4.4	CANTIDAD DE PROFESORES TUTORES POR COLEGIO	49
5.1	TIPOS DE REDES NEURONALES	51
5.2	TIPOS DE FUNCIÓN DE ACTIVACIÓN	52
5.3	DESCRIPCIÓN DE RESULTADOS	53
5.4	CARACTERÍSTICAS DEL COLEGIO	54
5.5	CARACTERÍSTICAS DE LOS MATERIALES EDUCATIVOS	55
5.6	CARACTERÍSTICAS DEL PROFESOR	55
5.7	CARACTERÍSTICAS SOBRE LAS PRÁCTICAS PEDAGÓGICAS	56
5.8	CARACTERÍSTICAS DE CONDUCCIÓN	56
5.9	CARACTERÍSTICAS DE EXPERIENCIA DEL ESTUDIANTE	57
5.10	CARACTERÍSTICAS DE SALUD	57
5.11	CARACTERÍSTICAS SOBRE LOS NIVELES SOCIOECONÓMICO	58
5.12	FACTORES QUE AFECTAN EL RENDIMIENTO ACADÉMICO	59
5.13	FACTORES QUE AFECTAN EL RENDIMIENTO ACADÉMICO	60
5.14	DATOS DE LA I.E. 5091 HIJOS DE GRAU	60
5.15	DATOS DE LA I.E.P. HÉROES DEL PACÍFICO	61
5.16	DATOS DE LA I.E. 5052 VIRGEN DE LA MERCED	61
5.17	CANTIDAD DE ESTUDIANTES ENCUESTADOS	62
5.18	CANTIDAD DE PROFESORES TUTORES COLEGIOS ENCUESTADOS	62
5.19	FACTORES DESPUÉS DE PRUEBA PILOTO	63
6.1	VALIDACIÓN DE DATOS	81

Índice de figuras

2.1	ELEMENTOS DE UNA NEURONA BIOLÓGICA	23
2.2	ESTRUCTURA DE UNA SINAPISIS	23
2.3	MODELO DE UNA NEURONA ARTIFICIAL	25
2.4	APRENDIZAJE DE HEBB[8]	30
2.5	ESTRUCTURA DEL PERCEPTRÓN[28]	32
2.6	ESTRUCTURA BÁSICA DE UNA RED NEURONAL MULTICAPA[10]	35
5.1	ENCUESTAS DE ESTUDIANTES DEL I.E. 5091 HIJOS DE GRAU	64
5.2	ENCUESTAS DE PROFESORES TUTORES DEL I.E. 5091 HIJOS DE GRAU	65
5.3	ENCUESTAS DE ESTUDIANTES DEL I.E.P. HÉROES DEL PACÍFICO	65
5.4	ENCUESTAS DE PROFESORES DEL I.E.P. HÉROES DEL PACÍFICO	66
5.5	ENCUESTAS DE ESTUDIANTES DEL I.E. 5052 VIRGEN DE LA MERCED	66
5.6	ENCUESTAS DE PROFESORES DEL I.E. 5052 VIRGEN DE LA MERCED	67
5.7	RELACIÓN DE ENCUESTAS VÁLIDAS Y NO VÁLIDAS	67
5.8	DATOS NORMALIZADOS DE LA ENTRADA 1	69
5.9	DATOS NORMALIZADOS DE LA ENTRADA 2	69
5.10	DATOS NORMALIZADOS DE LA ENTRADA 3	69
5.11	DATOS NORMALIZADOS DE LA ENTRADA 4	69
5.12	DATOS NORMALIZADOS DE LA ENTRADA 5	70
5.13	DATOS NORMALIZADOS DE LA ENTRADA 6	70
5.14	DATOS NORMALIZADOS DE LA ENTRADA 7	70
5.15	DATOS NORMALIZADOS DE LA ENTRADA 8	70
5.16	DATOS NORMALIZADOS DE LA ENTRADA 9	70
5.17	DATOS NORMALIZADOS DE LA ENTRADA 10	71
5.18	DATOS NORMALIZADOS DE LA ENTRADA 11	71
5.19	DATOS NORMALIZADOS DE LA ENTRADA 12	71
5.20	DATOS NORMALIZADOS DE LA ENTRADA 13	71
5.21	DATOS NORMALIZADOS DE LA ENTRADA 14	71
5.22	DATOS NORMALIZADOS DE LA ENTRADA 15	72
5.23	DATOS NORMALIZADOS DE LA ENTRADA 16	72
5.24	DATOS NORMALIZADOS DE LA ENTRADA 17	72
5.25	DATOS NORMALIZADOS DE LA ENTRADA 18	72

ÍNDICE DE FIGURAS

5.26 DATOS NORMALIZADOS DE LA ENTRADA 19	72
5.27 DATOS NORMALIZADOS DE LA ENTRADA 20	73
5.28 DATOS NORMALIZADOS DE LA ENTRADA 21	73
5.29 DATOS NORMALIZADOS DE LA ENTRADA 22	73
5.30 DATOS NORMALIZADOS DE LA ENTRADA 23	73
5.31 DATOS NORMALIZADOS DE LA ENTRADA 24	73
5.32 DATOS NORMALIZADOS DE LA ENTRADA 25	74
5.33 DATOS NORMALIZADOS DE LA ENTRADA 26	74
5.34 DATOS NORMALIZADOS DE LA ENTRADA 27	74
5.35 DATOS NORMALIZADOS DE LA ENTRADA 28	74
5.36 DATOS NORMALIZADOS DE LA ENTRADA 29	74
5.37 DATOS NORMALIZADOS DE LA ENTRADA 30	75
5.38 DATOS NORMALIZADOS DE LA ENTRADA 31	75
5.39 DATOS NORMALIZADOS DE LA SALIDA	75
5.40 REDUCCIÓN DEL ERROR EN EL ENTRENAMIENTO	79

RESUMEN

En la actualidad el Perú es uno de los países que se encuentra en los últimos puestos con un índice de nivel académico muy bajo según el PISA de la Organización para la Cooperación y el Desarrollo Económicos. Las instituciones educativas realizan pruebas psicológicas a los estudiantes que tienen bajo rendimiento académico de forma posteriori, es decir, luego de conocer el rendimiento que tuvo a lo largo de un periodo para tomar medidas correctivas en el estudiante.

El objetivo de la investigación es crear una red neuronal para predecir el rendimiento académico de los estudiantes del nivel primario del distrito de Ventanilla.

Los factores que influyen en el rendimiento académico de los estudiantes del nivel primario se clasifican en 2 (factores alterables y factores no alterables). Del total de factores en el rendimiento académico de los estudiantes del nivel primario solo se tomaron en cuenta 33 de un total de 47.

Se creó una arquitectura de red neuronal, utilizando el perceptrón multicapa con algoritmo de aprendizaje de resilient backpropagation y función de activación la tangente hiperbólica. La arquitectura de la red neuronal tiene 3 capas ocultas, bias para mejorar la performance de la arquitectura y como parámetro de error de aceptación hasta 2%.

Finalmente, la red neuronal artificial obtuvo resultados de un 2% de error absoluto en el entrenamiento y un grado de validez de un 84%.

Palabras claves: Red neuronal artificial, Rendimiento académico, Backpropagation, Perceptrón

ABSTRACT

Currently, Peru is one of the countries with the lowest level of academic achievement according to the PISA of the Organization for Economic Co-operation and Development. Educational institutions perform psychological tests on students who have a low academic performance afterwards, after knowing the performance they had over a period of time to take corrective action on the student.

The goal of the research is to create a neural network to predict the academic performance of students at the primary level of the district of Ventanilla.

Factors that influence the academic performance of students at the primary level are classified as 2 (alterable factors and non-alterable factors). Of the total factors in the academic performance of the students of the primary level only 33 of a total of 47 were taken into account.

A neural network architecture was created, using the multilayer perceptron with resilient back-propagation learning algorithm and hyperbolic tangent activation function. The architecture of the neural network has 3 hidden layers, bias to improve the performance of the architecture and as an acceptance error parameter of up to 2 %.

Finally, the artificial neural network obtained results of 2 % absolute error in the training and an accuracy of 84 %.

Keywords: Artificial neural network, Academic performance, Backpropagation, Perceptron

INTRODUCCIÓN

La presente investigación tiene por objetivo la predicción del rendimiento académico de los estudiantes del nivel primario mediante el uso de redes neuronales. Se consideró los estudiantes del nivel primario por ser una etapa trascendental en el desarrollo académico y personal de los estudiantes.

Los datos para el entrenamiento de la red neuronal artificial se obtuvieron de encuestas realizadas a los estudiantes del nivel primario, de primer grado hasta sexto grado, de varios colegios de Ventanilla basados en indicadores que influyen de forma directa en el rendimiento académico. El procesamiento de los datos de los estudiantes fue realizada con técnicas de normalización utilizados en "Data Science" para el entrenamiento de la red neuronal artificial.

El desarrollo de la investigación comprendió las siguientes partes:

PARTE I: Presenta el planteamiento del problema, presenta la determinación del problema, la formulación del problema, los objetivos y la justificación, con las cuales se demostrará la importancia que tiene este proyecto, considerando el impacto que tendrá en ámbitos académicos o sociales.

PARTE II: Presenta los antecedentes del tema a investigar, la situación actual del Perú en ámbitos de educación, los trabajos realizados sobre el rendimiento académico, también en el

INTRODUCCIÓN

marco conceptual. Se formula el fundamento teórico de las redes neuronales y los conceptos sobre el rendimiento académico.

PARTE III: Presenta las variables independientes y dependientes que a la vez, se mostrará un cuadro de operacionalización de ellas, teniendo en cuenta que las redes neuronales y el rendimiento académico son las variables de estudio; así mismo se presenta la hipótesis general e hipótesis específicas en función de las variables puestas anteriormente.

PARTE IV: Se define el tipo de investigación, teniendo en cuenta que es un trabajo del tipo no experimental transversal, también presenta el diseño de la investigación con la cual se propone realizarlo por etapas con el fin de facilitar el trabajo y por último presenta la población, muestra y técnicas e instrumentos de recolección de datos que presente el trabajo de investigación.

PARTE V: Presenta los resultados de la investigación.

PARTE VI: Presenta las discusiones de los resultados.

PARTE VII: Presenta las conclusiones que se generó a partir de la investigación desarrollada.

PARTE VIII: Presenta posibles recomendaciones para mejorar el rendimiento académico de los estudiantes.

Capítulo I

PLANTEAMIENTO DE LA INVESTIGACIÓN

1.1 Identificación del problema

El Perú, en las últimas pruebas realizadas del examen PISA¹ del 2012 y 2015, se encuentra entre los últimos puestos en comprensión lectora, matemáticas y ciencias. Los resultados muestran al país en el puesto 65 en las 3 materias en el 2012[3] y en los puestos 64, 63, 62 respectivamente en el 2015[4], confirmando los bajos índices de desempeño académico de los estudiantes en el país.

El rendimiento académico de los estudiantes en el Perú sigue manteniéndose en los niveles muy bajos en educación[2], se formula la siguiente pregunta ¿Cómo mejorar el desempeño académico de los estudiantes? Esta pregunta realizada es de mucha importancia para la mayoría de padres, debido al bajo rendimiento que presentan sus hijos. Pero realmente que se

¹Se basa en el análisis del rendimiento de estudiantes con el fin de determinar la valoración internacional de los estudiantes-<http://www.oecd.org/pisa/pisaenespaol.htm>

1.2. FORMULACIÓN DEL PROBLEMA

puede hacer para mejorar el desempeño académico de los estudiantes del nivel primario, que presentan distintas características en su formación académica[30], a comparación de los niveles de secundaria o superior. Y si una posible solución fuera optar por enfocarse en los distintos factores que presentan los estudiantes en su desarrollo académico y personal. Es así, que una investigación sobre los factores que afectan el rendimiento académico en la educación primaria en Latinoamérica propone una mayor atención en estos tres grupos de factores: los individuales, familiares y de establecimiento educacional[30].

En la actualidad, el sistema educativo peruano se enfoca en 10 perfiles para el desarrollo de los estudiantes[7], pero sin conocer estrictamente la situación por la que atraviesan en un ámbito personal o familiar[19]. En algunas instituciones educativas se realizan pruebas psicológicas[5] a estudiantes que tienen un bajo rendimiento académico de forma posteriori, es decir; luego de conocer el rendimiento que tuvo a lo largo de un período, recién toman interés en los factores que influyen en su bajo rendimiento.

Si las instituciones educativas pudieran conocer a priori el desempeño que tendrán los estudiantes en un trimestre, podrían intervenir para conocer qué factores están influyendo en su bajo rendimiento, con el fin de mejorar el desempeño académico que tendrán a lo largo de un período.

1.2 Formulación del problema

1.2.1 General

¿Se podrá conocer a priori el rendimiento académico que tendrán los estudiantes del nivel primario en un trimestre académico?

1.3. OBJETIVOS DE LA INVESTIGACIÓN

1.2.2 Específicos

1. ¿Cuales son los factores que más influyen en el rendimiento académico de los estudiantes del nivel primario?
2. ¿Se podrá con la red neuronal artificial predecir el rendimiento académico de los estudiantes del nivel primario?
3. ¿La red neuronal artificial tendrá un grado de predicción mayor al 75% del rendimiento académico de los estudiantes del nivel primario?

1.3 Objetivos de la investigación

1.3.1 General

Determinar que el uso de las redes neuronales artificiales predican el rendimiento académico de los estudiantes del nivel primario.

1.3.2 Específicos

1. Seleccionar los factores que más influyen en el rendimiento académico de los estudiantes del nivel primario.
2. Diseñar y crear una red neuronal artificial para la predicción del rendimiento académico de los estudiantes.
3. Validar el grado de predicción de la red neuronal artificial creada para la predicción del rendimiento académico de los estudiantes.

1.4 Justificación

El presente proyecto de investigación, se justificó basándose en los siguientes argumentos:

1.4.1 Por su naturaleza

El tema central está conectado con los siguientes subtemas:

- Control de la calidad en la educación a nivel primario, cuya importancia debe implicar no tan solo en el desarrollo académico sino también personal, ya que es una etapa trascendental en el desarrollo de los niños.
- Influencia familiar en el desarrollo académico de los estudiantes.
- Políticas de desarrollo en ámbitos de educación en niveles básicos.

1.4.2 Según su magnitud

El distrito de Ventanilla cuenta aproximadamente con 146 colegios que conforman la red de educación de Ventanilla, siendo uno de los distritos de la región callao con mayor números de colegios, por lo tanto, nos enfocamos en poder conocer el desarrollo académico que tiene y el impacto en desarrollo social, ambiental y tecnológico que tendrán los estudiantes del distrito del primer puerto del Perú.

1.4.3 Por su trascendencia

La importancia de conocer a priori el desempeño que tendrán los estudiantes en estos tiempos, donde el país sufre un déficit educacional, nos proporciona una ayuda invaluable, ya que no solo podríamos prevenir, corregir, guiar o encaminar a los estudiantes que posiblemente puedan

1.5. IMPORTANCIA

reprobar algún curso académico sino también crear nuevas políticas educacionales donde se integren a la familia y la sociedad en el desarrollo de las futuras generaciones.

1.5 Importancia

La predicción de datos tiene una gran importancia porque ayuda a tomar medidas preventivas sobre hechos que aún no han sucedido, teniendo en cuenta eso, llevarlo al campo educacional tiene una importancia vital, ya que los beneficiados son estudiantes en plena formación.

Predecir el rendimiento académico de los estudiantes ayuda a analizar a mayor profundidad los problemas familiares, sociales y educativos que presentan durante su etapa formativa.

Capítulo II

MARCO TEÓRICO

2.1 Antecedentes de estudio

En agosto de 2010 fue presentado en la Revista Electrónica de Investigación Educativa de la Universidad Nacional del Nordeste, Argentina. El artículo **Predicción del rendimiento académico de estudiantes de primer año de la FACENA (UNNE) en función de su caracterización socioeducativa** por Eduardo Adolfo Porcel, Gladys Noemí Dapazo y María Victoria López[23].

Esta investigación analizó la relación del rendimiento académico de los estudiantes ingresantes a la Facultad de Ciencias Exactas y Naturales y Agrimensura de la Universidad Nacional del Nordeste (FACENA-UNNE) en Corrientes, Argentina, durante el primer año de carrera con las características socioeducativas de los mismos. El rendimiento fue medido por la aprobación de los exámenes parciales o finales de la primera materia de Matemática que los estudiantes cursan. Se ajustó el modelo de regresión logística binaria, el cual clasificó adecuadamente el 75% de los datos. Entre las variables más apropiadas para explicar el rendimiento académico se encuentran el título secundario obtenido, la carrera elegida y el nivel educacional alcan-

2.1. ANTECEDENTES DE ESTUDIO

zados por la madre. El análisis de los resultados cuenta que los diseños curriculares del nivel medio afectan el rendimiento de los estudiantes en la universidad, en forma positiva cuando la orientación se corresponde con el perfil de la carrera elegida, y negativamente cuando esta formación previa está más alejada de los contenidos de la carrera universitaria que el estudiante decidió estudiar y con respecto a los métodos utilizados, el método de regresión logística binaria adoptado presenta un porcentaje elevado de predicción. Esta investigación ayudó a comprender el tratamiento de los datos obtenidos de los estudiantes para poder procesarlo con un método de predicción[23].

También se consultó el trabajo presentado en diciembre de 2011 en la Revista chilena de ingeniería. El artículo **Análisis de rendimiento académico estudiantil usando data warehouse y redes neuronales** por Carolina Zambrano Matamala, Darío Rojas Días, Karina Carvajal Cuello y Gonzalo Acuña Leiva[31].

Esta investigación describe una arquitectura de Data Warehouse con el fin de realizar un análisis del desempeño académico de los estudiantes. El data Warehouse es utilizado como entrada de una arquitectura de red neuronal con tal de analizar la información histórica y de tendencia en el tiempo. Los resultados presentados en esta investigación demuestran la viabilidad de utilizar Data Warehouse para el análisis de rendimientos académicos y la posibilidad de predecir el número de asignatura aprobados por los estudiantes usando solamente su propia información histórica. Esta investigación ayudó a entender que tipo de red neuronal proporciona mejores resultados en predicciones de datos de clasificación[31].

Se consultó el trabajo presentado en febrero de 2012 en University of Patras, Grecia. El artículo **Predicting students' performance using artificial neural networks** por Ioannis E. Livieris, Konstantina Drakopoulou y Panagiotis Pintelas[13].

2.1. ANTECEDENTES DE ESTUDIO

Esta investigación describe la implementación de una herramienta de software de fácil uso para predecir el rendimiento de los estudiantes en el curso de Matemáticas, la cual se basa en un clasificador de redes neuronales. Los resultados concluyen que las redes neuronales entrenadas con the modified spectral Perry (MSP) muestran un comportamiento más consistente e ilustra mejores resultados de clasificación. Esta investigación ayudó a saber que algoritmos de clasificación proporcionan mejores resultados a la hora de clasificar datos parcialmente graduados en un mismo intervalo[13].

Se consultó el trabajo presentado en noviembre de 2012 en la facultad de Ciencias Exactas y Naturales y Agrimensura. Universidad Nacional del Nordeste, Corrientes, Argentina. El artículo **Redes Neuronales para predecir el rendimiento académico de los estudiantes ingresantes a la carrera de Bioquímica de la FACENA-UNNE en función de sus conocimientos matemáticos previos** por Silvia E. Barreto, María V. López, Maria G. Ramirez Arballo, Eduardo A. Porcel y Liliana E. Mata[15].

Esta investigación tuvo por objetivo desarrollar modelos de redes neuronales artificiales para analizar la incidencia de los conocimientos matemáticos previos de los estudiantes ingresantes a la carrera de Bioquímica de la FACENA-UNNE, en su rendimiento académico en el primer cuatrimestre del primer año. Analizaron los datos del estado académico de los estudiantes y de sus conocimientos matemáticos previos, siendo obtenidos estos últimos a partir de una evaluación diagnóstica, puesta en funcionamiento en 2009, al inicio del curso de nivelación ofrecido a los ingresantes. Se diseñaron modelos de red neuronal de tipo perceptrón multicapa (PM) y función de base radial (FBR), considerando como variables independientes el número de ítems correctos en cada contenido del diagnóstico. Los resultados demuestran que el perceptrón multicapa (PM) y función de base radial (FBR) permitieron obtener porcentajes de clasificación

2.1. ANTECEDENTES DE ESTUDIO

correcta total de 81,3%, y 78,8% respectivamente, los cuales se consideran satisfactorios. Esta investigación ayudó a conocer la implementación satisfactoria de un perceptrón multicapa para la predicción de datos con variables compuestas[15].

Se consultó el trabajo presentado en octubre de 2013 publicado en *Journal of Science and Information Technology*, Nigeria. El artículo **Artificial Neural Network (ANN) Model for Predicting Students' Academic Performance** por Usman, O.L. y Adenubi, A.O.[29]

Esta investigación tuvo por objetivo utilizar redes neuronales artificiales para realizar un modelo para predecir la calificación final de un estudiante universitario antes de graduarse. Se diseñaron modelos de red neuronal de tipo perceptrón multicapa (PM) usando la función Gradient descent with momentum backpropagation (TRAINGDM), la función Levenberg-Marquardt backpropagation (TRAINLM) y la función Gradient descent with adaptive learning rate backpropagation (TRAINGDA). Los resultados demuestran que entre las tres funciones de activación utilizadas en la red neuronal artificial, la TRAINGDA presentó una clasificación correcta del 83.30%. Esta investigación ayudó a conocer que función de activación presenta mejor clasificación para este tipo de problema[29].

Se consultó el trabajo presentado en agosto de 2013 publicado en *Journal Frontline Learning Research*, Bélgica. El artículo **Predicting general academic performance and identifying the differential contribution of participating variables using artificial neural networks** por Mariel F. Musso, Eva Kyndt, Eduardo C. Cascallar, Filip Dochy[20].

La investigación explora un enfoque metodológico relativamente nuevo para el campo del aprendizaje y la educación, pero que es ampliamente utilizado en otras áreas, tales como las ciencias computacionales, la ingeniería y la economía. Este estudio utiliza medidas cognitivas

2.2. MARCO CONCEPTUAL

y no cognitivas de los estudiantes, junto con información de antecedentes, con el fin de diseñar modelos predictivos de rendimiento de los estudiantes utilizando redes neuronales artificiales (ANN). Se diseñó 3 modelos de redes neuronales usando el algoritmo de backpropagation. Los resultados demuestran que de los tres modelos de redes neuronales desarrollados, dos de los modelos (identificando el 33% superior y el 33% más bajo de los grupos, respectivamente) fueron capaces de alcanzar el 100% de identificación correcta de todos los estudiantes en cada uno de los dos grupos. El tercer modelo (que identifica los niveles de rendimiento bajo, medio y alto) alcanzó precisiones de 87% a 100% para los tres grupos. Esta investigación ayudó a conocer que el modelo de perceptrón multicapa con el algoritmo de aprendizaje backprogration tienen una alta tasa de clasificación para este tipo de problema[20].

2.2 Marco conceptual

En este capítulo se muestran los conceptos necesarios y el desarrollo de ellos para abordar el tema de investigación tratado, poniendo ejemplos de ser necesario para su mejor entendimiento.

2.2.1 El aprendizaje

Se define como un cambio relativamente permanente en el comportamiento, que refleja la adquisición de conocimientos o habilidades a través de la experiencia, y que pueden incluir el estudio, la instrucción, la observación o la práctica. Los cambios en el comportamiento son razonablemente objetivos, y, por lo tanto, pueden ser medidos. Se aprende de todo; lo bueno y lo malo. Se aprende a bailar, cantar, saltar, etc. ya sea en la casa, en el parque, en la escuela: se aprende en cualquier parte[9].

2.2.2 Rendimiento académico

El rendimiento académico es la evaluación del conocimiento adquirido en el ámbito escolar, terciario o universitario. Un estudiante con buen rendimiento académico es aquel que obtiene calificaciones positivas en los exámenes que debe rendir a lo largo de un periodo. En otras palabras, el rendimiento académico es una medida de las capacidades del estudiante, que expresa lo que este ha aprendido a lo largo del proceso formativo. También supone la capacidad del estudiante para responder a los estímulos educativos. En tal sentido, el rendimiento académico está vinculado a la aptitud[9].

Indicadores del rendimiento académico

1. La motivación escolar: es un proceso general por el cual se inicia y dirige una conducta hacia el logro de una meta. “Este proceso involucra variables tanto cognitivas como afectivas: cognitivas, en cuanto a habilidades de pensamiento y conductas instrumentales para alcanzar las metas propuestas; afectivas, en tanto comprende elementos como la autovaloración, autoconcepto, etc.”[1], también se puede definir como un conjunto de procesos implicados en la activación, dirección y persistencia de la conducta. Por tanto, el nivel de activación, la elección entre un conjunto de posibilidades de acción y concentrar la atención, y perseverar ante una tarea o actividad son los principales indicadores motivacionales[21].
2. Las habilidades sociales: al hacer mención de la educación, necesariamente hay que referirse a la entidad educativa y a los diferentes elementos que están involucrados en el proceso de enseñanza aprendizaje como los estudiantes, la familia y el ambiente social que lo rodea. La escuela según Levinger[12], brinda al estudiante la oportunidad de adquirir técnicas, conocimientos, actitudes y hábitos que promuevan el máximo aprovechamiento de sus capacidades y contribuye a neutralizar los efectos nocivos de un ambiente

2.2. MARCO CONCEPTUAL

familiar y social desfavorables. En su estudio sobre el clima escolar: percepción del estudiante, De Giraldo y Mera[9] concluyen que si las normas son flexibles y adaptables, tienen una mayor aceptación, contribuyen a la socialización, a la autodeterminación y a la adquisición de responsabilidad por parte del estudiante, favoreciendo así la convivencia en el colegio y por tanto el desarrollo de la personalidad; por el contrario, si estas son rígidas, repercuten negativamente, generando rebeldía, inconformidad, sentimientos de inferioridad o facilitando la actuación de la persona en forma diferente a lo que quisiera expresar.

2.2.3 Red neuronal biológica

La base para poder emular el cerebro consiste en comprender el funcionamiento de las neuronas y las conexiones que tienen entre ellas. Los avances en Neurobiología permiten comprender su funcionamiento, le permite realizar tareas tan complejas. Esta sección trata de explicar el funcionamiento de la neurona biológica de una forma precisa pero no tan profunda como en Neurobiología, suficiente para entender su similitud con las neuronas artificiales.

1. La neurona: es el nombre que se da a la célula del sistema nervioso y a todas sus prolongaciones. Son células muy excitables¹, especializadas para la recepción de estímulos y la conducción del impulso nervioso². Cada una posee un cuerpo celular desde cuya superficie se proyectan una o más prolongaciones denominadas neuritas³. Las neuritas responsables de recibir información y conducirla hacia el cuerpo celular se denominan dendritas. La neurita larga única que conduce impulsos desde el cuerpo celular hacia la periferia se denomina axón[16].


¹Depende de la existencia de distintas concentraciones de iones a ambos lados de la membrana celular y de la capacidad de transporte activo a través de estas membranas

²Es una onda de descarga eléctrica que viaja a lo largo de la membrana celular modificando su distribución de carga eléctrica.

³Cualquier expansión del soma de una neurona, ya sea una dendrita o un axón.

2.2. MARCO CONCEPTUAL

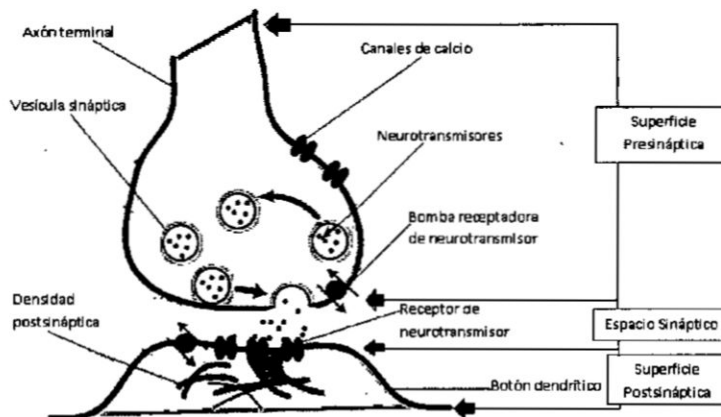
FIGURA 2.1: ELEMENTOS DE UNA NEURONA BIOLÓGICA



En la figura 2.1 se puede observar los elementos típicos de una neurona biológica que a continuación vamos a describir:

2. Sinapsis La sinapsis es la estructura de interconexión entre las neuronas o entre una célula efectora⁴ donde permite el paso del impulso nervioso.

FIGURA 2.2: ESTRUCTURA DE UNA SINAPSIS



La figura 2.2 presenta 3 elementos importantes que a continuación vamos a describir:

⁴Célula que actúa inmediatamente en la respuesta inmune frente a los antígenos, lo que da lugar a la denominada respuesta primaria, por ejemplo la célula endotelial.

2.2. MARCO CONCEPTUAL

(a) Superficie Presináptica:

Generalmente corresponde a una terminal axónica o botón axónico con la membrana presináptica libre de neurotúbulos y neurofilamentos y donde se aprecian una serie de gránulos, abundantes mitocondrias que permiten el metabolismo aeróbico a este nivel y vesículas sinápticas llenas de neurotransmisor que es sintetizado en el soma y llega a la superficie presináptica a través del flujo axónico anterógrado. Las moléculas que no se liberan vuelven al soma a través del flujo retrógrado[16].

(b) Espacio sináptico

Es el lugar donde se libera el neurotransmisor, el cual cae a la hendidura sináptica y baña la superficie del tercer componente de la sinapsis que es la superficie postsináptica. Tiene material filamentososo y se comunica con el espacio extracelular[16].

(c) Superficie Postsináptica:

Es donde el neurotransmisor abre canales iónicos para que comiencen a funcionar los segundos mensajeros, dentro del cuerpo de la segunda neurona. Desencadenando un impulso nervioso[16].

2.2.4 La neurona artificial

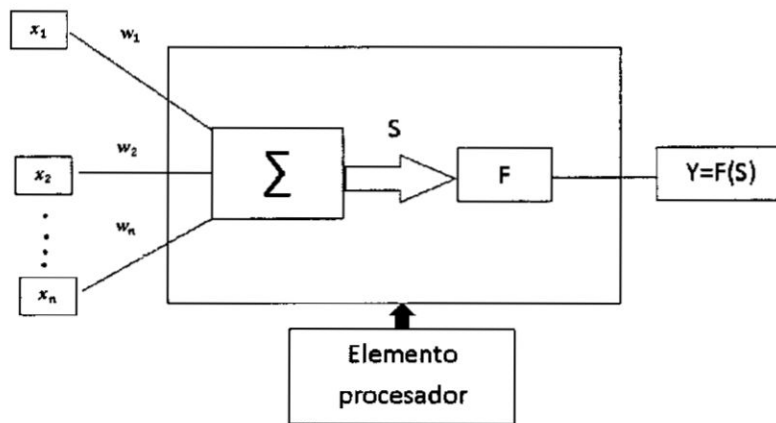
La neurona artificial es un modelo que se basa en el funcionamiento de una neurona biológica con el fin de emular las características más importantes de su funcionamiento.

El funcionamiento de una neurona artificial es similar a la de una neurona biológica, requiere un conjunto de entradas, un conjunto de pesos correspondientes a cada entrada, la cual se van a multiplicar para posteriormente poder ingresar un elemento sumador y conseguir un resultado, el resultado obtenido del elemento sumador pasara por una función de activación que conseguirá un resultado en función de un parámetro, el resultado de la función de activación es la salida de la neurona que pasara hacia otras neuronas o podrá ser la salida final[22].

2.2. MARCO CONCEPTUAL

A continuación se muestra el modelo de una neurona artificial:

FIGURA 2.3: MODELO DE UNA NEURONA ARTIFICIAL



En la figura 2.3 se puede observar los elementos que componen una neurona artificial, siendo S la sumatoria del conjunto de entradas multiplicado por un peso sináptico correspondiente a cada entrada.

$$S_k = \sum_{k=0}^N X_k * W_k \quad (2.1)$$

Siendo $S_k = (S_1, S_2, S_3 \dots S_n)$ la salida del proceso sumador, $X_k = (X_1, X_2, X_3 \dots X_n)$ vector de entrada, W_k el vector de pesos y $k = 0, 1, 2, \dots n$.

El resultado de la sumatoria S_k pasa por una función llamada "**Función de activación**".

$$Y_k = F(S_k) \quad (2.2)$$

Normalmente, la señal de salida S suele ser procesada por una función de activación F para

2.2. MARCO CONCEPTUAL

producir una señal de salida. La función F puede ser una función lineal o una función no lineal que simule con mayor exactitud las características de transferencia no lineales de las neuronas biológicas[22].

Las funciones de activación más utilizadas son las funciones Sigmoid⁵ y Tangente Hiperbólica⁶.

1. Función Sigmoide

$$F(S_k) = \frac{1}{1 + e^{-S_k}} \quad (2.3)$$

2. Función Tangente Hiperbólica

$$F(S_k) = \frac{1 - e^{-S_k}}{1 + e^{-S_k}} \quad (2.4)$$

Con similitud en las Neuronas Biológicas la Neurona Artificial presenta diversos elementos representativos:

1. Pesos sinápticos: Son los valores w_k que se muestran en la figura 2.3. Estos pesos sinápticos son los parámetros del sistema, de tal forma que el proceso de aprendizaje se reduce a obtener los valores que mejor se comportan con nuestro problema.
2. Sumador: Este elemento determina las sumas de los distintos pesos multiplicado por las diversas entradas al igual que en una neurona biológica el cuerpo o Soma acumula los neurotransmisores.
3. Función no lineal: Se aplica a la salida del sumador y, normalmente, se le conoce como función de activación y similarmente en una neurona biológica se produce en el espacio

⁵Muchos procesos naturales y curvas de aprendizaje de sistemas complejos muestran una progresión temporal desde unos niveles bajos al inicio, hasta acercarse a un clímax transcurrido un cierto tiempo; la transición se produce en una región caracterizada por una fuerte aceleración intermedia. La función sigmoide permite describir esta evolución.

⁶La tangente hiperbólica de un número real x se designa mediante \tanh_x y se define como el cociente entre el seno hiperbólico y el coseno hiperbólico del número real x .

2.2. MARCO CONCEPTUAL

sináptico, la cual si existe una excitación inhibitora los neurotransmisores pueden pasar al sector postsináptico.

Este tipo de modelo de neurona artificial ignora muchas de las características de las neuronas biológicas, entre ellas destaca la omisión de retardos y de sincronismo en la generación de la salida, no obstante, a pesar de estas limitaciones las redes construidas con este tipo de neurona artificial presentan cualidades y atributos con cierta similitud a los del sistema biológico[22].

2.2.5 Características de las redes neuronales artificiales

Las redes neuronales artificiales están inspiradas en las redes neuronales biológicas del cerebro humano. Están constituidas por elementos que se comportan de forma similar a la neurona biológica en sus funciones más comunes. Estos elementos están organizados de una forma parecida a la que presenta el cerebro humano.

Las características más importantes a tomar en cuenta en una neurona artificial son:

Aprender: adquirir el conocimiento por medio del estudio, ejercicio o experiencia. Las redes neuronales pueden cambiar su comportamiento en función del entorno, si recibe un conjunto de entradas y ellas mismas se ajustan para producir unas salidas consistentes[28].

Generalizar: extender o ampliar. Las redes neuronales artificiales generalizan automáticamente debido a su propia estructura y naturaleza. Pueden presentar respuestas correctas a entradas con variaciones debido a ruido o distorsión⁷[28].

Abstraer: aislar mentalmente o considerar por separado las cualidades de un objeto[28].

⁷Se entiende por distorsión la diferencia entre la señal que entra a un equipo o sistema y la señal que sale del mismo

2.2.6 Entrenamiento de las redes neuronales artificiales

Una de las características fundamentales de las redes neuronales artificiales es el aprendizaje, pero es necesario tener un procedimiento para conseguir los resultados deseados. El entrenamiento de una red neuronal artificial es conseguir que una aplicación determinada, para un conjunto de entradas produzca el conjunto de salidas deseadas o mínimamente consistentes.

El proceso de entrenamiento consiste en la aplicación secuencial de diferentes conjuntos o vectores de entrada para que se ajusten los pesos de las interconexiones según un procedimiento predeterminado. Durante la sesión de entrenamiento los pesos convergen⁸ gradualmente hacia los valores que hacen que cada entrada produzca el vector de salida deseado[22].

Los algoritmos de entrenamiento se pueden clasificar en dos grupos:

TABLA 2.1: TIPOS DE APRENDIZAJE

Tipo	Algoritmo
Entrenamiento supervisado	El aprendizaje supervisado es una técnica para deducir una función a partir de datos de entrenamiento. Los datos de entrenamiento consisten de pares de objetos (normalmente vectores): una componente del par son los datos de entrada y el otro, los resultados deseados. La salida de la función puede ser un valor numérico (como en los problemas de regresión) o una etiqueta de clase (como en los de clasificación). El objetivo del aprendizaje supervisado es el de crear una función capaz de predecir el valor correspondiente a cualquier objeto de entrada válida después de haber visto una serie de ejemplos, los datos de entrenamiento.
Entrenamiento no supervisado	Aprendizaje no supervisado es un método de aprendizaje automático donde un modelo es ajustado a las observaciones. Se distingue del aprendizaje supervisado por el hecho de que no hay un conocimiento a priori. En el aprendizaje no supervisado, un conjunto de datos de objetos de entrada es tratado. Así, el aprendizaje no supervisado típicamente trata los objetos de entrada como un conjunto de variables aleatorias, siendo construido un modelo de densidad para el conjunto de datos.

⁸Todos los elementos de la sucesión se aproximan tanto como queramos al valor límite.

2.2. MARCO CONCEPTUAL

La gran mayoría de modelos de aprendizaje no supervisado han surgido en función del modelo de Hebb⁹.

Aprendizaje de Hebb

La mayoría de los conocimientos y capacidades adquiridas no son innatos si no son debido a un proceso de aprendizaje que tiene lugar a lo largo de un periodo.

A continuación se muestra el concepto filosófico de Hebb que propuso en 1943 para el mecanismo de aprendizaje.

1. La teoría básica de Hebb


"Cuando un axón de la célula A esta suficientemente próximo para excitar a una célula B o toma parte en su disparo de forma persistente, tiene lugar algún proceso de crecimiento o algún cambio metabólico en una de las células, o en las dos, de tal forma que la eficiencia de A, como una de las células que desencadena el disparo de B, se ve incrementada"[8].

Para ilustrar la idea básica, consideremos un ejemplo clásico de condicionamiento, empleando el conocido experimento de Pavlov¹⁰. La figura muestra tres neuronas idealizadas que toman parte del proceso.

⁹Donald O. Hebb (Chester, Nueva Escocia,1904-1985) es considerado el iniciador de la biopsicología.

¹⁰Iván Petróvich Pávlov (Riazán, 14 de septiembre de 1849 - San Petersburgo, 27 de febrero de 1936) fue un fisiólogo ruso.

FIGURA 2.4: APRENDIZAJE DE HEBB[8]



El aprendizaje Hebbiano consiste básicamente en el ajuste de los pesos de las conexiones de acuerdo con la correlación entre los valores de entrada y salida de cada neurona. Particularicemos esta regla para la neurona más sencilla, sin función de activación. De acuerdo con la regla expuesta sería[28]:

$$W_k(n + 1) = W_k(n) + \alpha * X_k * Y \quad (2.5)$$

Siendo α el coeficiente de aprendizaje (posteriormente se explicara), X_k el vector de entradas, $W_k(n + 1)$ el vector de nuevos pesos, $W_k(n)$ el vector de pesos, Y la salida del proceso. Con

$$Y = \sum_{k=0}^N X_k * W_k \quad (2.6)$$

2. Algoritmo de Hebb

- (a) Inicializar los pesos con valores pequeños
- (b) Para cada patrón obtener las salidas y si existe algún error, modificar los pesos

(c) Repetir el paso (b) hasta que los pesos se estabilicen y las salidas sean las correctas

2.2.7 Perceptrón

El Perceptrón es la red neuronal artificial más simple y la primera en aparecer ya a finales de los años cincuenta. Fue inventado por el psicólogo Frank Rosenblatt[25]¹¹. Surgió en el intento de ilustrar algunas de las propiedades fundamentales de los sistemas inteligentes¹² en general, sin entrar en demasía en ciertas condiciones especiales, y muchas veces desconocidas, que son válidas para organismos biológicos concretos[8].

El modelo de Frank Rosenblatt se basó en el modelo de Warren McCulloch y Walter Pitts en su publicación llamado "Un cálculo Lógico de las Ideas Inmanentes en la Actividad Nerviosa"[17] donde se estipula que las redes neuronales biológicas se pueden estudiar con una lógica proporcional debido que el comportamiento de las neuronas es biestable.

Características

Las principales características del Perceptrón simple son:

- El proceso de aprendizaje es iterativo.
- EL proceso de aprendizaje es supervisado.
- Reconoce patrones sencillos
- El proceso de aprendizaje es por corrección de errores
- Solo presenta una capa de procesamiento.

¹¹Estudió psicología social en la Cornell University, doctorándose en Psicopatología Experimental.


¹²Un sistema inteligente es un programa de computación que reúne características y comportamientos asimilables al de la inteligencia humana o animal.

2.2. MARCO CONCEPTUAL

- La configuración sináptica de los pesos iniciales tiene un valor pequeño.
- La función de activación puede ser linealmente separable o no.
- Limitación para realizar compuertas XOR.

A continuación se muestra el modelo del perceptrón simple.

FIGURA 2.5: ESTRUCTURA DEL PERCEPTRÓN[28]



En la Figura 2.5 se puede observar la estructura del perceptrón simple, mostrando los distintos componentes que posee; las cuales son:

- X_i : Representa las entradas(dendritas) de la neurona artificial.
- W_i : Representa los pesos(pesos sinápticos) de la neurona artificial.
- Σ : Es el operador (soma) que suma las multiplicaciones dadas por las entradas y los pesos sinápticos.
- S : Es el resultado del operador Σ
- Función activación: Es la función de activación la cual en función de S se podrá obtener como resultado un 1 o 0.
- Umbral(U): Es un valor inicial que se utiliza para comparar la salida.

2.2. MARCO CONCEPTUAL

- Señal Deseada (YD): Es el resultado correcto que se espera obtener.
- Y: Es salida del proceso de la neurona artificial.
- Error: El error es la diferencia entre la salida deseada y la salida obtenida.

Proceso de aprendizaje

El procedimiento de aprendizaje comienza por la inicialización aleatoria de los pesos, para, posteriormente, ir ajustando conforme la red se equivoca en las asignaciones de clase al vector de entrada presente en ese momento.

1. Inicialización de los pesos
2. Determinación de la salida

$$S = U + \sum_{k=0}^N W_k \cdot X_k \quad (2.7)$$

3. Aplicación de la función de activación

$$F(S) = 1, S \geq 0 \quad (2.8)$$

$$F(S) = -1, S < 0 \quad (2.9)$$

$$Y = F(S) \quad (2.10)$$

4. Comparación con la señal deseada

$$Error = YD - Y \quad (2.11)$$

2.2. MARCO CONCEPTUAL

5. Actualización de los coeficientes si existe error

$$W_k(n + 1) = W_k(n) + \alpha * Error * X_k \quad (2.12)$$

Donde α es el coeficiente de aprendizaje propuesto por Frank Rosenblatt.

$$U(n + 1) = U(n) + \alpha * Error \quad (2.13)$$

6. Volver hacer el paso del 2 al 5 si aun hay error en las salidas

2.2.8 Red Backpropagation

El perceptrón multicapa es una generalización del perceptrón simple y surgió como consecuencia de la limitación del perceptrón en la separabilidad no lineal. El perceptrón multicapa fue desarrollado por Minsky y Papert[18] en 1969 uniendo varios perceptrones simple, pero el conflicto que tuvieron fue en el aprendizaje ya que no podían modificar los pesos con el mismo aprendizaje que el perceptrón simple[22]. Este fue la base para Rumelhart, Hinton y Williams[26] en 1986 pudieran desarrollar un método para poder modificar los pesos en una red neuronal artificial llamada propagación hacia atrás (backpropagation)[10].


Arquitectura

El perceptrón multicapa se distingue por tener tres capas distintas: La capa de entradas, las capas ocultas y la capa de salida.

A continuación se muestra el modelo del perceptrón multicapa:

2.2. MARCO CONCEPTUAL

FIGURA 2.6: ESTRUCTURA BÁSICA DE UNA RED NEURONAL MULTICAPA[10]



En la figura 2.6 se puede observar las distintas capas que a continuación se explica:

En la capa de entrada se encuentran las neuronas no como elementos que procesan sino como elementos de distribución que van desde la capa de entrada hacia las neuronas de las capas ocultas.

En las capas ocultas se encuentran un conjunto de capas que contienen un número distinto o igual de neuronas procesadoras que se relacionan con otras capas ocultas como se observa en la figura 2.6.

En la capa de salida se encuentran un conjunto de neuronas procesadoras la cual, las salidas son las salidas finales de la red neuronal artificial.

Características

Las principales características del perceptrón multicapa son:

2.2. MARCO CONCEPTUAL

- Las neuronas se agrupan en capas de diferentes niveles.
- Las distintas capas se encuentran relacionadas de forma completa.
- Las funciones de transferencia deben ser derivables.
- El proceso de corrección de pesos se propaga hacia atrás.
- El proceso de la información se propaga hacia adelante.
- El valor del coeficiente de aprendizaje debe ser moderado, es decir un valor no tan pequeño y no tan grande.
- Es una estructura no lineal.
- Presenta tolerancia a fallos.
- El sistema relaciona dos conjuntos de datos.
- Se puede implementar en equipos (hardware).

Proceso de aprendizaje

El proceso de aprendizaje comienza con la inicialización aleatoria de los pesos, umbrales y también la inicialización propuesta por el diseñador de la red del α que es el coeficiente de aprendizaje.

El coeficiente de aprendizaje propuesto en el perceptrón simple por Frank Rosenblatt es un indicador de que tan rápido va a converger la red neuronal artificial, algo lógico sobre el coeficiente sería si a mayor coeficiente el sistema tendría que converger rápidamente pero se produciría, que al tratar de converger más rápido nunca encuentre la solución óptima, ya que de forma empírica se comprobó que al poner un coeficiente de aprendizaje grande tal vez no

2.2. MARCO CONCEPTUAL

converja el sistema se optó por poner un coeficiente de aprendizaje con un valor promedio y que puede variar según el diseñador con efecto a su aplicación[8].

1. Inicialización de los pesos, umbrales, coeficiente de aprendizaje y salidas deseadas.
2. Determinación de la salida: Una red neuronal de C capas y con $C - 2$ capas ocultas donde cada capa oculta contienen n^q neuronas donde $q = 1,2,3,\dots,C$. según la capa que sea. Los pesos $W^q = (w_{ij}^q)$ donde es un matriz asociada a las conexiones de la capa q hacia la capa $q + 1$ donde el peso w_{ij}^q representa el peso de la neurona i de la capa q a la neurona j de la capa $q + 1$ y sea el Umbral $U^q = u_i^q$ un vector donde i representa la neurona i y q en que capa se encuentra. Se nota a a_i^q la activación de la neurona i de la capa q .
3. Activación de las neuronas en la capa de entrada

$$a_i^1 = x_i \quad (2.14)$$

Para $i = 1,2,3,\dots,n_1$ y x presenta el valor o patrón de entrada.

4. Activación de las neuronas en la capa oculta: Las neuronas en las capas ocultas procesan la información aplicando una función de activación al producto de los pesos y la entrada.

$$a_i^q = F\left(\sum_{j=1}^{n_{q-1}} w_{ij}^{q-1} a_j^{q-1} + u_i^q\right) \quad (2.15)$$

para $i = 1,2,3,\dots,n_q$ y $q = 1,2,3,\dots,C-1$.

5. Activación de las neuronas en la capa de salida

$$Y_i = a_i^C = F\left(\sum_{j=1}^{n_{C-1}} w_{ij}^{C-1} a_j^{C-1} + u_i^C\right) \quad (2.16)$$

para $i = 1,2,3,\dots,n_C$ y donde Y_i es el vector de salida

2.2. MARCO CONCEPTUAL

La función de activación en el perceptrón multicapa más usadas son: la función sigmoïdal y la tangente hiperbólica.

A continuación se muestra la función sigmoïdal y la función tangente hiperbólica:

(a) Función sigmoïdal

$$F_x = \frac{1}{1 + e^{-x}} \quad (2.17)$$

donde $F_x = [0,1]$

(b) Función tangente hiperbólica

$$F_x = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.18)$$

donde $F_x = [-1,1]$

6. Obtención del error: Siendo E una función que evalúa la diferencia de las salidas deseada con las salidas de la red.

$$E = \frac{1}{N} \sum_{n=1}^N e(n) \quad (2.19)$$

Donde N es el numero de patrones o muestras y $e(n)$ es el error cometido por el patrón n dado por:

$$e(n) = \frac{1}{2} \sum_{i=1}^{n_c} (S_i(n) - Y_i(n))^2 \quad (2.20)$$

siendo Y_i el vector de salida de la red y S_i el vector de salida deseada para el patrón n respectivamente.

7. Modificando los pesos y umbrales para las capas de salida

(a) Pesos

$$W_{ij}^{C-1}(n) = W_{ij}^{C-1}(n-1) + \alpha \delta_i^C(n) a_j^{C-1}(n) \quad (2.21)$$

siendo α el coeficiente de aprendizaje

2.2. MARCO CONCEPTUAL

(b) Umbrales

$$U_{ij}^{C-1}(n) = W_{ij}^{C-1}(n-1) + \alpha \delta_i^C(n) \quad (2.22)$$

(c) Error

$$\delta_i^C(n) = (S_i(n) - Y_i(n))Y_i(n)(1 - Y_i(n)) \quad (2.23)$$

8. Modificando los pesos y umbrales de la entrada y las capas ocultas

(a) Pesos

$$W_{kj}^C(n) = W_{kj}^C(n-1) + \alpha \delta_j^{C+1}(n) a_j^{C-1}(n) \quad (2.24)$$

(b) Umbrales

$$U_j^{C+1}(n) = W_j^{C+1}(n-1) + \alpha \delta_j^{C+1}(n) \quad (2.25)$$

(c) Error

$$\delta_j^{C+1}(n) = a_j^C(n)(1 - a_j^C(n)) \left(\sum_{i=1}^{n_{c+1}} \delta^{C+1}_i(n) W_{ji}^C \right) \quad (2.26)$$

9. Repetir el proceso 6 al 8 hasta que el error converge o se aproxime a 0

2.2.9 Resilient Backpropagation

Es un nuevo esquema de aprendizaje eficiente que realiza una adaptación directa en la etapa de modificación de pesos basada en la información de gradiente local[24].

La diferencia que presenta con el backpropagation es el esfuerzo de adaptación por el comportamiento de la gradiente borrosa, para lograr eso, un valor de actualización individual Δ_{ij} se agrega por cada peso, este valor actualiza el proceso de aprendizaje basado en su mínimo local sobre el error[27].

2.2. MARCO CONCEPTUAL

A continuación se muestra la función de costo o función de error F :

$$\Delta_{ij}^{(t)} = \begin{cases} n^+ \times \Delta_{ij}^{(t-1)} & \text{sí } \frac{\partial F^{(t-1)}}{\partial w_{ij}} \times \frac{\partial F^{(t)}}{\partial w_{ij}} > 0 \\ n^- \times \Delta_{ij}^{(t-1)} & \text{sí } \frac{\partial F^{(t-1)}}{\partial w_{ij}} \times \frac{\partial F^{(t)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)} & \text{sino } 0 < n^- < 1 < n^+ \end{cases} \quad (2.27)$$

La adaptación trabaja de la siguiente manera: Cada tiempo la derivada parcial de la función de costo F con respecto a el peso correspondiente w_{ij} cambia su signo indica que la última actualización fue demasiado grande y el algoritmo sobrepasó un mínimo local, el valor de actualización Δ_{ij} es disminuido por el factor n^- . Si la derivada retiene su signo, el valor de la actualización es ligeramente aumentada con el fin de acelerar la convergencia en regiones. Una vez adaptado el valor de actualización por cada peso, la actualización de peso sigue una regla muy simple: si la derivada es positiva (error creciente), el peso es disminuido por su valor de actualización, y si la derivada es negativa, el valor de actualización agregado es:

$$\Delta w_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t-1)} & \text{sí } \frac{\partial F^{(t)}}{\partial w_{ij}} > 0 \\ +\Delta_{ij}^{(t-1)} & \text{sí } \frac{\partial F^{(t)}}{\partial w_{ij}} < 0 \\ \Delta w_{ij}^{(t-1)} & \text{sino } w_{ij}^{(t)} + \Delta w_{ij}^{(t)} \end{cases} \quad (2.28)$$

Sin embargo, hay una excepción, si la derivada parcial cambia el signo, es decir, el paso anterior era demasiado grande y el mínimo se ha perdido, la actualización de peso anterior se invierte:

$$\Delta w_{ij}^{(t)} = -\Delta w_{ij}^{(t-1)} \text{ sí } \frac{\partial F^{(t-1)}}{\partial w_{ij}} \times \frac{\partial F^{(t)}}{\partial w_{ij}} < 0 \quad (2.29)$$

2.2. MARCO CONCEPTUAL

Debido a ese paso de retroceso en la actualización de los pesos, la derivada cambia de signo una vez más en los siguientes pasos. Para evitar un doble valor de actualización, se debe adaptar el valor de actualización en el paso siguiente. En la practica esto puede ser realizado poniendo $(\partial F^{(t-1)} / \partial w_{(ij)}) = 0$ en la regla de adaptación sobre Δ_{ij} . Los valores y pesos actualizados están cambiando cada vez que se presenta un conjunto de patrones[27].

Capítulo III

VARIABLES E HIPÓTESIS

3.1 Variables de la investigación

3.1.1 Variable dependiente

La variable dependiente es el rendimiento académico de un estudiante.

3.1.2 Variable independiente

La variable independiente refiere a la aplicación de una red neuronal.

3.2 Operacionalización de variables

TABLA 3.1: OPERACIONALIZACIÓN DE LAS VARIABLES DE ESTUDIO

Variables	Dimensiones	Indicadores
VI: Aplicación de las redes neuronales artificiales	Procesamiento en paralelo. Procesamiento no lineal. Aprendizaje. Eficiencia.	Gradiente descendiente adaptativa. Función de regresión multivariable. Función de costos.
VD: Predecir el rendimiento académico de los estudiantes del nivel primario.	Características de la escuela. Material educativo. Características del profesor. Prácticas pedagógicas. Experiencia de los estudiantes. Estados de salud. Estructura socioeconómica	Relación con el profesor Turno de estudio Acceso a material de estudios Uso de material intuitivo Frecuencia de tareas Frecuencia de evaluaciones

3.3 Hipótesis de la investigación

3.3.1 General

El uso de las redes neuronales predecirá el rendimiento académico de los estudiantes del nivel primario en los colegios del distrito de Ventanilla.

3.3.2 Específicos

No aplica para esta investigación.

Capítulo IV

METODOLOGÍA

4.1 Tipo de investigación

El tipo de investigación es no experimental transversal, debido a que las inferencias sobre las relaciones entre variables se realizan sin influencia directa y dichas relaciones se observan tal y como se han dado en su contexto.

4.2 Diseño de la investigación

Para el desarrollo de este proyecto se realizó las siguientes etapas:

1. Estudio y evaluación

- (a) Estudio y evaluación de los diferentes tipos de redes neuronales con el objetivo de seleccionar una red neuronal que se adapte al problema planteado.
- (b) Estudio y evaluación de los factores que afectan el rendimiento académico de los estudiantes del nivel primario con el objetivo de seleccionar un conjunto de indicadores, para poder utilizarlos como entradas en el diseño de la red neuronal.

4.2. DISEÑO DE LA INVESTIGACIÓN

2. Recolección de datos y procesamiento

- (a) Búsqueda en las bases de datos de la región Callao de los diferentes colegios, nacionales o privadas, del distrito de Ventanilla que tengan el nivel primario, con el objetivo de seleccionar mediante un análisis estadístico¹ una muestra representativa de los estudiantes del nivel primario a encuestar en los distintos colegios del distrito de Ventanilla.
- (b) Diseño de un tipo de encuesta donde se plasme preguntas que estén directamente relacionadas con los factores individuales, familiares y del establecimiento educacional, con el objetivo de tener un vector de entradas para poder entrenar la red neuronal.
- (c) Encuestar a los estudiantes del nivel primario de los distintos colegios del distrito de Ventanilla de acuerdo con la muestra establecida anteriormente. Los datos obtenidos de la encuesta son los vectores de entrada para poder entrenar la red neuronal, con el fin que pueda posteriormente predecir el rendimiento académico de los estudiantes.

3. Desarrolló de la red neuronal

- (a) Diseño y desarrollo de una red neuronal utilizando como lenguaje de programación java y la librería encog como modelo para procesar la información.

4. Validación del modelo

- (a) Prueba del grado de confianza que tiene la red neuronal en la predicción del rendimiento académico, para probar la calidad del modelo resultante después de haber entrenado la red neuronal. Si los resultados procesados confirman los resultados obtenidos por los estudiantes, entonces el modelo utilizado tendrá una tasa alta de

¹Estudia el uso y los análisis provenientes de una muestra representativa de datos

4.3. POBLACIÓN Y MUESTRA

confiabilidad. También una forma de analizar la calidad del modelo es haciendo un análisis de sensibilidad a las entradas de la red neuronal, mediante el error obtenido entre los resultados deseados y los resultados obtenidos del proceso.[14].

4.3 Población y muestra

La población lo conforma todos los estudiantes del nivel primario del "I.E 5091 Hijos De Grau", "I.E.P Héroes Del Pacífico" y "I.E. 5052 Virgen de la Merced" del distrito de Ventanilla, así mismo los profesores tutores de cada aula por año. Con el fin de trabajar una muestra representativa de la población, se consideró a todos los estudiantes del nivel primario de los colegios más representativos del distrito de Ventanilla.

La ubicación espacio temporal de las muestras se encuentra en la región Callao, provincia constitucional del Callao, distrito de Ventanilla.

4.4 Técnicas e instrumentos de recolección de datos

Se utilizó un cuestionario adaptado para el propósito de la investigación, cuya finalidad fue obtener información de manera sistemática y ordenada de acuerdo con las dimensiones planteadas para cuantificar las variables en todo el proceso de investigación.

4.4.1 Técnicas de muestreo

- Estadística

4.5. PROCEDIMIENTOS DE RECOLECCIÓN DE DATOS

4.4.2 Recopilación de datos

- Encuestas por cuestionarios

4.4.3 Procesamiento

- La escala de Likert
- Estadística descriptiva
- Estadística inferencial

4.5 Procedimientos de recolección de datos

Las encuestas se realizarán en 3 colegios de Ventanilla con el fin de obtener la información para poder entrenar la red neuronal que va a predecir los rendimientos académicos de los estudiantes del nivel primario.

El total de encuestas se fraccionará en 2 partes, como se muestra a continuación:

TABLA 4.1: TIPOS DE DATOS UTILIZADOS

Tipo de proceso	Porcentaje
Datos de entrenamiento	90%
Datos de validación	10%

El 90% de las encuestas serán designadas al entrenamiento de la red neuronal artificial para que pueda predecir el rendimiento académico de los estudiantes del nivel primario, y el 10% se utilizará para validar la arquitectura de red neuronal diseñada para la predicción del rendimiento académico.

4.6. PROCESAMIENTO ESTADÍSTICO Y ANÁLISIS DE DATOS

Las encuestas permitirán conocer las diversas características que presentan los estudiantes durante su desarrollo académico con el fin que la red neuronal artificial pueda procesar esa información para poder predecir los rendimientos académicos de los estudiantes.

4.6 Procesamiento estadístico y análisis de datos

Se procederán las encuestas para obtener los indicadores que presentan los estudiantes durante su desarrollo académico.

Para la elaboración de las preguntas de la encuesta se tomó como referencia los factores que influyen en los rendimientos académicos de los estudiantes del nivel primario[30].

La encuesta se realizó en dos etapas:

Prueba piloto

La prueba piloto se realizó en el "I.E. 8170 César Vallejo" del distrito de Comas, a 50 estudiantes de todos los niveles de primaria (1ro a 6to) el 15 de abril del 2017 y tuvo un tiempo de duración de 1 día.

TABLA 4.2: CANTIDAD DE ESTUDIANTES POR AÑO EN LA PRUEBA PILOTO

Año	Cantidad
1	10
2	10
3	10
4	10
5	5
6	5

La prueba ayudó a saber el grado de validez de la encuesta, así mismo se pudo observar que

4.6. PROCESAMIENTO ESTADÍSTICO Y ANÁLISIS DE DATOS

existen preguntas que los estudiantes no respondieron debido a no tener conocimiento sobre tal, ayudando a mejorar la encuesta.

Encuesta a colegios

La encuesta rediseñada fue validada por un experto de la Universidad Nacional del Callao. La encuesta se realizó a 3 colegios de ventanilla siendo estos: "I.E 5091 Hijos De Grau", "I.E.P Héroes Del Pacífico" y "I.E. 5052 Virgen de la Merced".

La cantidad de estudiantes por colegio se muestra a continuación:

TABLA 4.3: CANTIDAD DE ESTUDIANTES POR COLEGIO

Colegio	Cantidad de estudiante
I.E 5091 Hijos De Grau	155
I.E.P Héroes Del Pacífico	525
I.E. 5052 Virgen de la Merced	393

Del total de 1073 estudiantes encuestados, solo 1000 fueron encuestas válidas para el objetivo de esta investigación.

Los profesores tutores también fueron encuestados debido a que presentan factores que influyen en el rendimiento académico de los estudiantes.

La cantidad de profesores tutores por colegio se muestra a continuación:

TABLA 4.4: CANTIDAD DE PROFESORES TUTORES POR COLEGIO

Colegio	Cantidad de profesores
I.E 5091 Hijos De Grau	9
I.E.P Héroes Del Pacífico	17
I.E. 5052 Virgen de la Merced	14

Capítulo V

RESULTADOS

En el presente capítulo vamos a presentar la solución propuesta para predecir el rendimiento académico de los estudiantes del nivel primario mediante el uso de las redes neuronales artificiales. Se utiliza información real, obtenida de los estudiantes y profesores tutores de del "I.E 5091 Hijos De Grau", "I.E.P Héroes Del Pacífico" y "I.E. 5052 Virgen de la Merced" del distrito de Ventanilla.

5.1 Uso de redes neuronales artificiales

Para comenzar mostraremos los modelos actuales de redes neuronales existentes para resolver el problema de la predicción de rendimientos académicos, luego el algoritmo de aprendizaje con la cual la red neuronal va a aprender en base a los datos para poder predecir los rendimientos académicos de los estudiantes del nivel primario y finalmente la función de activación que procesa los datos en cada neuronal de la arquitectura.

5.1.1 Selección del tipo de red neuronal artificial

En este apartado se comparó los distintos tipos de redes neuronales que pueden aplicarse para este tipo de problema.

En la siguiente tabla se muestra las características que se necesitan para resolver el problema y los distintos tipos de redes neuronales que aplicarían de una mejor forma.

TABLA 5.1: TIPOS DE REDES NEURONALES

Características / Tipo de red	Perceptrón	Adaline	Madaline	Perceptrón Multicapa
Compresión de datos			X	X
Aprendizaje supervisado	X			X
Aprendizaje no supervisado		X	X	
Función derivable			X	X
Tolerancia a fallos			X	X
Velocidad de convergencia				X
Asociación de patrones		X	X	X

Se pudo observar en la tabla 5.1 que después de hacer un análisis en cuanto a las características en cuatro tipos de redes neuronales, la que mayor aceptación presenta para el propósito de esta investigación es el perceptrón multicapa debido que cumple con la mayor cantidad de características y además cumple el criterio de ser un modelo de red neuronal que se adapta muy bien para el aprendizaje supervisado, la cual usamos en esta investigación.

5.1.2 Selección de la técnica de aprendizaje

Luego de haber seleccionado el tipo de red neuronal a trabajar, se realizó otro análisis, para escoger la técnica de aprendizaje a utilizar para el entrenamiento de la red neuronal.

Entre las técnicas de entrenamiento mencionadas para la predicción del rendimiento académico

5.1. USO DE REDES NEURONALES ARTIFICIALES

de los estudiantes del nivel primario la que mejor rendimiento tiene es la resilient backpropagation debido que mejora el algoritmo de actualización de pesos sin la necesidad de definir un learning rate para el entrenamiento, debido a eso, la convergencia es mucho más rápido que las técnicas mencionadas anteriormente como lo menciona Lalit Mohan Saini[27].

5.1.3 Selección de la función de activación

La función de activación es la encargada de calcular el estado de activación de una neurona, transformando la entrada global en un valor (estado) de activación cuyo rango va normalmente entre (0 a 1) o (-1 a 1).

A continuación se muestran diferentes funciones de activación:

TABLA 5.2: TIPOS DE FUNCIÓN DE ACTIVACIÓN

	Función	Rango
Identidad	$y = x$	$[-\infty, +\infty]$
Escalón	$y = \text{sign}(x)$	$\{-1, +1\}$
Lineal a tramos	$y = \begin{cases} -1 & \text{si } x < -1 \\ x & \text{si } -1 < x < 1 \\ 1 & \text{si } x > 1 \end{cases}$	$[-1, +1]$
Sigmoidea	$y = \frac{1}{1+e^{-x}}$	$[-1, +1]$
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$
Sinusoidal	$y = A\text{sen}(\omega x + \phi)$	$[-1, +1]$
Tangente Hiperbólica	$y = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$[-1, +1]$

En la figura 5.2 se muestran los distintos tipos de función de activación que se puede utilizar para una red neuronal artificial, para el problema que resolvemos en esta investigación se seleccionó la función tangente hiperbólica por presentar mejores resultados en problemas del tipo de clasificación[11].

5.2 Recolección de datos y procesamiento

5.2.1 Variables que influyen en el rendimiento académico

Para el entrenamiento de una red neuronal artificial necesitamos un conjunto de entradas que posteriormente serán procesadas y darán un resultado. El resultado en esta investigación es conocer el rendimiento académico de los estudiantes. El rendimiento académico de los se medirá a través de los cursos desaprobados o aprobados en un periodo de tiempo (bimestre o trimestre), por la tanto medimos el rendimiento académico del estudiante sabiendo lo siguiente:

TABLA 5.3: DESCRIPCIÓN DE RESULTADOS

Resultado	Descripción
0	Desaprobó uno o más cursos
1	Aprobó los cursos

En la tabla 5.3 el valor de 0 muestra posiblemente que el estudiante desaprobó 1 o más curso, por lo tanto, presenta un bajo rendimiento académico y se debe tomar en cuenta, por otro lado, el valor de 1 muestra que el estudiante tiene un rendimiento académico bueno.

Los resultados solo pueden ser 0 o 1, 0 si tiene un mal rendimiento o 1 si tiene un buen rendimiento académico.

El conjunto de entradas para entrenar la red neuronal artificial se seleccionó en función del trabajo "Factores que Afectan el Rendimiento académico en la Educación Primaria"[30]. Los factores presentados que tienen mayor influencia en el rendimiento académico de los estudiantes fueron escogidos como parámetros de entrada en la arquitectura de red neuronal artificial para predecir el rendimiento académico de los estudiantes del nivel primario.

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

El trabajo presentado por Eduardo Velez, Ernesto Schiefelbein y Jorge Valenzuela a estudiantes de América Latina muestran 2 tipos de variables (alterables y no alterables). En la variable alterable se encuentran las características de la escuela y del profesor, los cuales están sujetos a políticas de intervención. En la variable no alterable se encuentran las características socioeconómicas del estudiante las cuales son oxígenos al medio escolar[30].

A continuación se muestran los indicadores alterables y no alterables por cada característica presentada y el impacto que tienen en el rendimiento académico de los estudiantes:

Indicadores alterables

TABLA 5.4: CARACTERÍSTICAS DEL COLEGIO

indicadores	Positiva	No relación	Negativa
Estudiante/clase		X	
Rel.Maestro/estudiante			X
Tamaño/escuela	X		
Publica/Privada	X		
Urbana/Rural		X	
Jornada completa		X	
Colegio con secu.			X
Mixta/No mixta			X
Maestro varón		X	
Maestra mujer		X	
Turno mañana	X		

Se escogieron los indicadores que presentan una relación positiva o negativa debido que son los que si afectan en el rendimiento académico de los estudiantes. En esta característica se tomaron: relación con el profesor, tamaño de la escuela, colegio con secundaria, mixta y no mixta, y turno de estudio.

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

TABLA 5.5: CARACTERÍSTICAS DE LOS MATERIALES EDUCATIVOS

indicadores	Positiva	No relación	Negativa
Acceso a libros de texto	X		
Otros materiales didácticos	X		
Infraestructura		X	

En la tabla 5.5 de las características de los materiales educativos solo se escoge el indicador de acceso a libro de texto debido a que presenta relación positiva con el rendimiento académico.

TABLA 5.6: CARACTERÍSTICAS DEL PROFESOR

indicadores	Positiva	No relación	Negativa
Años de formación	X		
Años de experiencia	X		
Capacitación en servicios	X		
Incentivos económicos		X	
Nivel económico social	X		
Lugar de residencia	X		
Especialidad		X	
Expectativa sobre el desempeño del estudiante		X	
Tiempo de preparación		X	
Sexo		X	
Satisfacción		X	
Experiencia con el material	X		
Experiencia en el aula		X	
Trabajo adicional		X	
Experiencia enseñando en 1.er grado		X	
Tiempo de dedicación		X	
Diseños de experimentos propios		X	

De la tabla 5.6 sobre las características del profesor los indicadores escogidos son: años de formación, años de experiencia, capacitación en servicios, nivel socioeconómico, lugar de residencia, especialidad, expectativas sobre el desempeño del estudiante y experiencia con el material.

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

TABLA 5.7: CARACTERÍSTICAS SOBRE LAS PRÁCTICAS PEDAGÓGICAS

indicadores	Positiva	No relación	Negativa
Tarea al hogar	X		
Evaluación/seguimiento			X
Horas de currículo		X	
Ausentismo del profesor		X	
Programas/recuperación		X	
Grupo de pares		X	
Énfasis en matemáticas y lenguas	X		
Cobertura de currículo		X	
Porcentaje de maestro en ciencias		X	
Porcentaje de profesores realizando investigación	X		
Utilización de nuevas estrategias			X
Activa/Pasiva		X	
Multigrado/Grado	X		

La tabla 5.7 solo muestra 4 indicadores a tomar en cuenta: tarea de hogar, énfasis en matemática y lenguas, profesores realizando investigación y multigrado / grado.

TABLA 5.8: CARACTERÍSTICAS DE CONDUCCIÓN

indicadores	Positiva	No relación	Negativa
Años de formación del director		X	
Años de experiencia del director			X
Experiencia como director de colegio		X	
Número de visitas de supervisor		X	
Número de servicios ofrecidos		X	
Actividades extracurriculares			X

Como se puede observar en la tabla 5.8 solo 2 factores influyen en el rendimiento de los estudiantes, las cuales son: años de experiencia del director y actividades extracurriculares.

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

TABLA 5.9: CARACTERÍSTICAS DE EXPERIENCIA DEL ESTUDIANTE

Indicadores	Positiva	No relación	Negativa
Preescolar	X		
Repitencia			X
Número de escuelas a la que asistió		X	
Actitud hacia el estudio	X		
Rendimiento cognitivo previo	X		
Grado	X		
Los padres ayudan con las tareas		X	
Distancia a la escuela			X
Opinión sobre el profesor		X	
Opinión sobre el colegio		X	
Comprende el material	X		
Autoestima	X		
Actitud hacia los padres		X	
Actitud hacia el material	X		
Dificultad del material		X	
Horas/lectura por semana	X		
Tareas del hogar/trabajo	X		

En las características sobre la experiencia del estudiante se observa una mayor cantidad de indicadores que afectan en el rendimiento académico de los estudiantes, siendo 11 los indicadores que afectan de forma positiva o negativa en el rendimiento académico.

TABLA 5.10: CARACTERÍSTICAS DE SALUD

indicadores	Positiva	No relación	Negativa
Altura según edad	x		
Peso según altura	x		
Problemas visuales y auditivas	x		

La tabla 5.10 muestra que todos los indicadores propuestos afectan en el rendimiento académico de los estudiantes.

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

Indicadores no alterables

TABLA 5.11: CARACTERÍSTICAS SOBRE LOS NIVELES SOCIOECONÓMICO

indicadores	Positiva	No relación	Negativa
Nivel económico	X		
Sexo	X		
Edad del estudiante			X
Tipo de familia	X		
Ingreso familiar	X		
Tamaño de la familia			X
Ingreso medio del barrio		X	
Cantidad de libros en el hogar	X		
Tv en el hogar	X		
Horas de radio en el hogar		X	
Experiencia	X		
Condiciones de estudio en el hogar	X		
Edad de los padres	X		
Cantidad de habitaciones en casa	X		
Porcentaje de los padres propietarios		X	
Lengua materna	X		
IQ/habilidad	X		

En la tabla 5.11 se muestra que 14 de los indicadores afectan de forma positiva o negativa en el rendimiento académico de los estudiantes.

5.2.2 Selección de indicadores que influyen en el rendimiento académico

Como se observó en los cuadros presentados en la sección anterior sobre los indicadores que afectan el rendimiento académico de los estudiantes, se seleccionó los indicadores que afectan de forma positiva o negativa.

Los indicadores seleccionados se muestran a continuación:

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

TABLA 5.12: FACTORES QUE AFECTAN EL RENDIMIENTO ACADÉMICO

Característica	Indicador
Del colegio	Tamaño del colegio
	Relación maestro estudiante
	Colegio con secundaria
	Publico o privado
	Mixto o no mixto
	Turno de enseñanza
Del material educativo	Acceso a libros o material de lectura
	Acceso a juegos educativos
Del profesor	Años de estudios del profesor
	Años de experiencia como docente
	Capacitación en servicios
	Estatus socioeconómicos
	Distancia del colegio a su casa
	Experiencia usando material didáctico
Practicas pedagógicas	Frecuencia de tareas
	Frecuencia de evaluaciones
	Énfasis en matemática y lenguas
	Realiza investigaciones
	Utiliza de estrategias de docencia
	Grado o multigrado
De la conducción	Experiencia del director en su cargo
	Enseñanza de cursos extracurriculares
Del Estudiante	Estudios pre escolares
	Repitencia de año
	Estudios previos antes de clase
	Año escolar
	Distancia del colegio
	Comprensión lectora
	Autoestima
	Gusta de la lectura
	Horas de lectura por semana
	Tareas del hogar / trabajo
Salud del estudiante	Altura según edad
	Peso según altura
	Problemas de visión y/o auditivos

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

TABLA 5.13: FACTORES QUE AFECTAN EL RENDIMIENTO ACADÉMICO

Característica	Indicador
Socio-económicos del estudiante	Sexo
	Edad del estudiante
	Tipo de familia
	Ingresos familiares
	Cantidad de personas con las que vive
	Cantidad de libros en casa
	Horas de televisión al día
	Experiencia
	Condiciones de estudio en el hogar
	Tamaño de la casa
	Lengua materna
	IQ/Habilidad

Los indicadores mostrados en las tablas 5.12 y 5.13 serán utilizados como parámetros en la arquitectura de la red neuronal para la predicción del rendimiento académico de los estudiantes.

5.2.3 Recolección de información

En esta etapa se obtuvo los datos de los colegios como se muestra a continuación en el cuadro:

TABLA 5.14: DATOS DE LA I.E. 5091 HIJOS DE GRAU

Características	
Nombre IE	I.E 5091 Hijos De Grau
Nivel	Primaria
Dirección	Hijos de Grau Mz "O"
Centro Poblado	Callao
Distrito	Ventanilla
Provincia	Callao
Región	Callao
Área	Urbana
Categoría	Escolarizado
Genero	Mixto
Turno	Tarde y Mañana
Tipo	Publica

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

TABLA 5.15: DATOS DE LA I.E.P. HÉROES DEL PACÍFICO

Características	
Nombre IE	I.E.P Héros Del Pacífico
Nivel	Primaria-Secundaria
Dirección	Av. la playa s/n Mz. "I" Lote. 1 Etapa 4
Centro Poblado	Callao
Distrito	Ventanilla
Provincia	Callao
Región	Callao
Área	Urbana
Categoría	Escolarizado
Genero	Mixto
Turno	Tarde y Mañana
Tipo	Privado

TABLA 5.16: DATOS DE LA I.E. 5052 VIRGEN DE LA MERCED

Características	
Nombre IE	I.E. 5052 Virgen de la Merced
Nivel	Primaria-Secundaria
Dirección	Av. los geranios s/n Ciudad Satélite
Centro Poblado	Callao
Distrito	Ventanilla
Provincia	Callao
Región	Callao
Área	Urbana
Categoría	Escolarizado
Genero	Mixto
Turno	Tarde y Mañana
Tipo	Publica

A continuación se muestran la cantidad de estudiantes por cada año del nivel primario de los 3 colegios seleccionados:

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

TABLA 5.17: CANTIDAD DE ESTUDIANTES ENCUESTADOS

Año	Hijos De Grau	Héroes Del Pacífico	Virgen de la Merced	Total
Primero	15	75	48	138
Segundo	15	90	55	160
Tercero	30	60	52	142
Cuarto	35	110	55	200
Quinto	35	95	98	228
Sexto	25	95	82	202

A continuación se muestra la cantidad de profesores tutores por cada año del nivel primario de los 3 colegios seleccionados:

TABLA 5.18: CANTIDAD DE PROFESORES TUTORES COLEGIOS ENCUESTADOS

Año	Hijos De Grau	Héroes Del Pacífico	Virgen de la Merced	Total
Primero	1	3	2	6
Segundo	1	3	2	6
Tercero	2	2	2	6
Cuarto	2	4	2	8
Quinto	2	3	3	8
Sexto	1	3	3	7

Los colegios mencionados cuentan con un total de 1070 estudiantes en el nivel primario y 41 profesores tutores a quienes se les realizaron las encuestas.

5.2.4 Diseño de encuesta

La encuesta fue diseñado en función de los indicadores que afectan el rendimiento académico de los estudiantes del nivel primario ya propuesto anteriormente, es así que al realizar una prueba piloto se mostró que algunas preguntas no presentaban respuesta debido a que los estudiantes no lo marcaban por no comprender o no conocer. La encuesta se rediseño en base a los indicadores que si fueron marcados durante la prueba piloto.

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

A continuación se presentan los nuevos indicadores para la creación de la encuesta:

TABLA 5.19: FACTORES DESPUÉS DE PRUEBA PILOTO

Característica	Indicador
Del colegio	Tamaño del colegio
	Relación maestro estudiante
	Colegio con secundaria
	Turno de enseñanza
Del material educativo	Acceso a libros o material de lectura
	Acceso a juegos educativos
Del profesor	Años de estudios del profesor
	Años de experiencia como docente
	Estatus socio-económicos
	Distancia del colegio a su casa
	Experiencia usando material didáctico
Prácticas pedagógicas	Frecuencia de tareas
	Frecuencia de evaluaciones
	Realiza investigaciones
	Utiliza de estrategias de docencia
De la conducción	Experiencia del director en su cargo
	Enseñanza de cursos extracurriculares
Del Estudiante	Estudios pre escolares
	Repitencia de año
	Estudios previos antes de clase
	Año escolar
	Distancia del colegio
	Comprensión lectora
	Gusta de la lectura
Salud del estudiante	Problemas de visión y/o auditivos
Socio-económicos del estudiante	Sexo
	Edad del estudiante
	Tipo de familia
	Ingresos familiares
	Cantidad de libros en casa
	Tamaño de la casa

En base a la tabla 5.19 se realizó una nueva encuesta con los indicadores que afectan de forma positiva y negativa el rendimiento académico.

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO


Se debe tener en cuenta que una encuesta para este objeto de investigación es valido si los estudiantes y profesor completan todas las preguntas, es decir, si alguno de los encuestados no respondiera una pregunta, se tomará como invalida.

El formato de la encuesta se adjuntara en los anexos de la investigación.

Se encuestó el día 1 de mayo del 2017 a los estudiantes y profesores tutores del "I.E. 5091 Hijo de Grau".

A continuación se muestra la cantidad de encuestas válidas:


FIGURA 5.1: ENCUESTAS DE ESTUDIANTES DEL I.E. 5091 HIJOS DE GRAU



En la figura 5.1 se observa una cantidad de 17 encuestas inválidas debido a que no presentan información completa.

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

FIGURA 5.2: ENCUESTAS DE PROFESORES TUTORES DEL I.E. 5091 HIJOS DE GRAU




En la figura 5.2 se observa que no presentan encuestas inválidas.

Se encuestó el día 8 de mayo del 2017 a los estudiantes y profesores tutores del "I.E.P Héroes Del Pacífico".

A continuación se muestra la cantidad de encuestas válidas:

FIGURA 5.3: ENCUESTAS DE ESTUDIANTES DEL I.E.P. HÉROES DEL PACÍFICO




En la figura 5.3 se observa una cantidad de 45 encuestas inválidas debido a que no presentan

5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

información completa.

FIGURA 5.4: ENCUESTAS DE PROFESORES DEL I.E.P. HÉROES DEL PACÍFICO




En la figura 5.4 se observa que no presentan encuestas inválidas.

Se encuestó el día 15 de mayo del 2017 a los estudiantes y profesores tutores del "I.E. 5052 Virgen de la Merced".

A continuación se muestra la cantidad de encuestas válidas:


FIGURA 5.5: ENCUESTAS DE ESTUDIANTES DEL I.E. 5052 VIRGEN DE LA MERCED



5.2. RECOLECCIÓN DE DATOS Y PROCESAMIENTO

En la figura 5.5 se observa una cantidad de 13 encuestas inválidas debido a que no presentan información completa.


FIGURA 5.6: ENCUESTAS DE PROFESORES DEL I.E. 5052 VIRGEN DE LA MERCED



En la figura 5.6 se observa que no presentan encuestas inválidas.

A continuación se muestra la cantidad de datos validos a utilizar para el propósito de esta investigación.

FIGURA 5.7: RELACIÓN DE ENCUESTAS VÁLIDAS Y NO VÁLIDAS



5.3 Desarrollo de la red neuronal artificial

5.3.1 Normalización de los datos

Los datos obtenidos de las encuestas realizadas a los 3 colegios deben ser normalizadas para que puedan ser utilizadas por la red neuronal artificial, para ello se realiza el proceso de normalización de datos para las entradas de una red neuronal artificial.

Existen muchos tipos de normalización de datos, lo óptimo y por lo tanto lo que se pretende, es que tanto las entradas como las salidas se concentren en un rango de longitudes aceptables y estén dispersos dentro de ese rango para un tratamiento de los datos más sencillo.

A continuación, la función de normalización más común:

$$F(x) = \frac{(x - d_L)(n_H - n_L)}{(d_H - d_L) + n_L} \quad (5.1)$$

Donde:

x : Valor a normalizar.

d_L : El menor valor de conjunto de datos del parámetro.

d_H : El mayor valor de conjunto de datos del parámetro.

n_L : El menor valor de rango al que se desea normalizar.

n_H : El mayor valor de rango al que se desea normalizar.

Los valores n_L y n_H son (0 a 1) respectivamente debido a que el valor del rendimiento académico lo medidos con un valor binario, es decir, 0 para los que van a jalar uno o más cursos o 1 para los que van a aprobar, por tal motivo se asigna ese rango para la normalización.

5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

A continuación se muestran los gráficos de los datos normalizados:

FIGURA 5.8: DATOS NORMALIZADOS DE LA ENTRADA 1
relacionProfesor




FIGURA 5.9: DATOS NORMALIZADOS DE LA ENTRADA 2
turnoEstudios




FIGURA 5.10: DATOS NORMALIZADOS DE LA ENTRADA 3
accesoLibros





FIGURA 5.11: DATOS NORMALIZADOS DE LA ENTRADA 4
utilizacionJuegosDidacticos



5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

FIGURA 5.12: DATOS NORMALIZADOS DE LA ENTRADA 5

tareasCasa




FIGURA 5.13: DATOS NORMALIZADOS DE LA ENTRADA 6

frecuenciaEvaluacion




FIGURA 5.14: DATOS NORMALIZADOS DE LA ENTRADA 7

estudioJardin




FIGURA 5.15: DATOS NORMALIZADOS DE LA ENTRADA 8

repetencia





FIGURA 5.16: DATOS NORMALIZADOS DE LA ENTRADA 9

estudiosPrevios



5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

FIGURA 5.17: DATOS NORMALIZADOS DE LA ENTRADA 10
distanciaColegio




FIGURA 5.18: DATOS NORMALIZADOS DE LA ENTRADA 11
comprensionLectora




FIGURA 5.19: DATOS NORMALIZADOS DE LA ENTRADA 12
gustoLectura




FIGURA 5.20: DATOS NORMALIZADOS DE LA ENTRADA 13
edadEstudiante





FIGURA 5.21: DATOS NORMALIZADOS DE LA ENTRADA 14
sexo



5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

FIGURA 5.22: DATOS NORMALIZADOS DE LA ENTRADA 15
problemasSalud




FIGURA 5.23: DATOS NORMALIZADOS DE LA ENTRADA 16
ingresoEconomico




FIGURA 5.24: DATOS NORMALIZADOS DE LA ENTRADA 17
vivoPadres




FIGURA 5.25: DATOS NORMALIZADOS DE LA ENTRADA 18
librosCasa




FIGURA 5.26: DATOS NORMALIZADOS DE LA ENTRADA 19
tamanoCasa



5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

FIGURA 5.27: DATOS NORMALIZADOS DE LA ENTRADA 20
tamanoColegio




FIGURA 5.28: DATOS NORMALIZADOS DE LA ENTRADA 21
secundaria




FIGURA 5.29: DATOS NORMALIZADOS DE LA ENTRADA 22
estudiosDocente




FIGURA 5.30: DATOS NORMALIZADOS DE LA ENTRADA 23
experienciaDocente





FIGURA 5.31: DATOS NORMALIZADOS DE LA ENTRADA 24
ingresoEconomicoDocente



5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

FIGURA 5.32: DATOS NORMALIZADOS DE LA ENTRADA 25




FIGURA 5.33: DATOS NORMALIZADOS DE LA ENTRADA 26




FIGURA 5.34: DATOS NORMALIZADOS DE LA ENTRADA 27




FIGURA 5.35: DATOS NORMALIZADOS DE LA ENTRADA 28





FIGURA 5.36: DATOS NORMALIZADOS DE LA ENTRADA 29



5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

FIGURA 5.37: DATOS NORMALIZADOS DE LA ENTRADA 30
experienciaDirector




FIGURA 5.38: DATOS NORMALIZADOS DE LA ENTRADA 31
cursosExtracurriculares





FIGURA 5.39: DATOS NORMALIZADOS DE LA SALIDA
rendimientoAcademico



Ahora pasamos a escoger de forma aleatoria un conjunto de datos con el objetivo de obtener una muestra suficientemente dispersa. El 90% de los datos lo utilizaremos para el entrenamiento de la red neuronal artificial, y el 10% restante para verificar el grado de fiabilidad de la red neuronal artificial pidiéndole que obtenga esos resultados con los cuales no ha sido entrenada y comparándolos luego con los valores almacenados del 10% restantes.

5.3.2 Creación de la red neuronal artificial

La red neuronal artificial consta de 3 capas ocultas; 30 neuronas en la primera capa oculta, 15 neuronas en la segunda capa oculta y 10 en la última capa oculta. Los datos de entrada a la capa

5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

oculta, que son los datos de entrada de la red, se trataron con la función tangente hiperbólica (tanh). Los de salida también se trataron con la función tangente hiperbólica de acuerdo en lo mencionado en la primera sección de este capítulo.

El algoritmo de aprendizaje utilizado es resilient backpropagation. Este algoritmo es ofrecido por la librería "Encog" en Java, el cual es muy potente y rápido. Fue elegido por las mejoras que presenta en la actualización de los pesos.

A continuación se muestra el código de la red neuronal artificial realizado en Java:

```
1
2 // Arquitectura de la red neuronal usando tanh y resilient backpropagation
3 network = new BasicNetwork();
4 network.addLayer(new BasicLayer(null, true, 33));
5 network.addLayer(new BasicLayer(new ActivationTANH(), true, 30));
6 network.addLayer(new BasicLayer(new ActivationTANH(), true, 15));
7 network.addLayer(new BasicLayer(new ActivationTANH(), true, 10));
8 network.addLayer(new BasicLayer(new ActivationTANH(), true, 1));
9 network.getStructure().finalizeStructure();
10 network.reset();
11
12 MLDataSet trainingSet = new BasicMLDataSet(inputs, outputs);
13
14 // Uso del algoritmo de entrenamiento resilient backpropagation
15 final ResilientPropagation train = new ResilientPropagation(network,
    trainingSet);
```

Donde el siguiente código crea la red neuronal del tipo Perceptrón multicapa.

```
1 network = new BasicNetwork();
```

5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

Luego se agregan la cantidad de capas que va a tener la red neuronal pasando como parámetros (la función de activación o en caso de que no tuviera se coloca nulo, el valor true si la capa se crea con bias, la cantidad de neuronas por capa). Como se observa se creó 4 capas; 1 de entrada, 3 ocultas y 1 de salida. Solo la capa de entrada no presenta función de activación debido a que es la capa de recepción de datos. La capa de salida solo tiene 1 neurona ya que es la responsable de dar el valor binario del rendimiento académico (0 o 1).

```
1 network.addLayer(new BasicLayer(null, true, 33));
2 network.addLayer(new BasicLayer(new ActivationTANH(), true, 30));
3 network.addLayer(new BasicLayer(new ActivationTANH(), true, 15));
4 network.addLayer(new BasicLayer(new ActivationTANH(), true, 10));
5 network.addLayer(new BasicLayer(new ActivationTANH(), true, 1));
```

Se crea la dataset a utilizar para el entrenamiento de la red neuronal pasando como parámetros (los valores de entrada, el valor de salida)

```
1 MLDataSet trainingSet = new BasicMLDataSet(inputs, outputs);
```

La creación el algoritmo de entrenamiento tiene como parámetros (la red neuronal creada, la dataset creada). Como se puede observar se usa el algoritmo resilient backpropagation.

```
1 final ResilientPropagation train = new ResilientPropagation(network,
    trainingSet);
```

Para poder entrenar la red neuronal tenemos que tener en cuenta que el grado de fiabilidad se verifica con el accuracy o el porcentaje de predicción de la red neuronal, en cambio, para el entrenamiento se calcula con el error absoluto del entrenamiento, por tal motivo hemos especificado hasta un error del 2%.

Se realiza una operación repetitiva hasta que el error generado por el entrenamiento sea menor o igual a 2% o 0.02, y es entonces cuando la red neuronal esta entrenada.

5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

```
1 do {
2   train.iteration();
3   System.out.println("Epoch #" + epoch + " Error:" + formatter.format(
4     train.getError()));
5   epoch++;
6 } while (train.getError() > error);
```

El número de conexiones, es la suma total de las multiplicaciones de una capa con la capa siguiente es decir:

$$\sum_{n=0}^{t-1} (cNodos_x * cNodos_{x+1}) \quad (5.2)$$

Donde:

t: Es el total de capas en la arquitectura de la red neuronal.


x: Es el índice de la capa.

cNodos: Es el número de nodos por capa.

A continuación, entrenamos la red neuronal y se muestra una gráfica donde se ve como va reduciendo el error con cada iteración:

5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

FIGURA 5.40: REDUCCIÓN DEL ERROR EN EL ENTRENAMIENTO



La imagen muestra que la red neuronal se entrenó luego de 885 épocas de entrenamiento en una duración de 4,75 segundos.

A continuación, vamos a validar (accuracy) de la red neuronal creada mostrando el código para la validación.

```
1 MLDataSet trainingTest = new BasicMLDataSet(input, null);
2
3 for (MLDataPair pair : trainingTest) {
4
5     final MLData output = network.compute(pair.getInput());
6     System.out.println("Salida 1: " + output.getData(0) + " / " + Math.round(
7         output.getData(0)) + " / " + (Math.round(output.getData(0)) <= 0 ? 0 :
8         1));
9 }
```

Donde a continuación explicamos cada fragmento de código:

5.3. DESARROLLO DE LA RED NEURONAL ARTIFICIAL

Necesitamos predecir los rendimientos académicos de los estudiantes y para ellos se necesita nueva información para predecir, el 10% de la dataset nos ayudará en ese trabajo para posteriormente comparar las predicciones realizadas por la red neuronal artificial con los datos reales del 10% de la dataset.

Se crea una nueva dataset con el 10% de datos totales de las encuestas usando como parámetros solo los inputs y no se coloca el output debido a que la red neuronal tiene que predecir esa información, por tal motivo colocamos null en el parámetro de salida.

```
1 MLDataSet trainingTest = new BasicMLDataSet(input, null);
```

Realizamos un bucle hasta que la red neuronal pueda predecir el rendimiento del total de datos ingresados, por cada repetición se obtiene el resultado de cada predicción.

```
1 for (MLDataPair pair : trainingTest) {  
2  
3     final MLData output = network.compute(pair.getInput());  
4     System.out.println("Salida 1: " + output.getData(0) + " / " + Math.round(  
        output.getData(0)) + " / " + (Math.round(output.getData(0)) <= 0 ? 0 :  
        1));  
5 }
```

Capítulo VI

DISCUSIÓN DE RESULTADOS

En este capítulo se discute y analiza los resultados obtenidos por la red neuronal entrenada. Los resultados son evaluados en función al grado de predicción de la red neuronal.

6.1 Constratación de hipótesis con los resultados

Para la validación de la predicción de la red neuronal se usó el 10% de las encuestas válidas, con la cual se ejecutó la red neuronal con todos los parámetros iguales al entrenamiento realizado.

A continuación se muestra la tabla de resultados:

TABLA 6.1: VALIDACIÓN DE DATOS

clasificación	Rendimiento malo	Rendimiento Bueno	Total	Porcentaje
Malo	6	10	16	16%
Bueno	9	75	84	84%
Total	15	85	100	100%

En la tabla 6.1 se puede mostrar que el grado de validez de la red neuronal es de un 84%, quiere decir que hay una probabilidad del 84% que la red neuronal pueda predecir el

6.2. CONTRASTACIÓN DE RESULTADOS CON OTROS ESTUDIOS SIMILARES

rendimiento académico de los estudiantes de forma correcta.

El nivel de predicción es de $PRED(0,16) = 0.84$. Sabiendo que para que un modelo predictivo sea aceptable un PRED debe ser mayor a 0.75[6].

La arquitectura de red neuronal para predecir el rendimiento académico de los estudiantes del nivel primario tiene un error absoluto de entrenamiento del 2% y un grado de validez del 84%.

6.2 Contrastación de resultados con otros estudios similares

Los resultados obtenidos con una muestra del 10% de las encuestas validas dan como resultado un 84% de predicción utilizando un perceptrón multicapa, tangente hiperbólica como función de activación y resilient backproagation como algoritmo de aprendizaje y los resultados mostrados por Eduardo Adolfo Porcel y otros en el artículo **Predicción del rendimiento académico de estudiantes de primer año de la FACENA (UNNE) en función de su caracterización socioeducativa** obtuvieron un 75% de predicción utilizando un modelo de regresión logística binaria, también Eduardo Adolfo Porcel y otros en el artículo **Redes Neuronales para predecir el rendimiento académico de los estudiantes ingresantes a la carrera de Bioquímica de la FACENA (UNNE) en función de sus conocimientos matemáticos previos** obtuvieron un 81.3% de predicción utilizando un perceptrón multicapa, función de base radial como función de activación y backpropagation como algoritmo de aprendizaje.

El trabajo presentado por Usma O.L en el artículo **Artificial Neural Network Model for Predicting Student's Academic Performance** obtuvo un 83.3% de predicción utilizando un perceptrón multicapa, tangente hiperbólica como función de activación y gradient descent with momentum backpropagation (TRAININGDA) como algoritmo de aprendizaje.

Capítulo VII

CONCLUSIONES

7.1 Conclusiones

1. El primer objetivo de este trabajo de investigación se logró a través de la construcción de una arquitectura de red neuronal la cual nos ayudará a predecir los rendimientos académicos de los estudiantes del nivel primario.
2. La cantidad de factores que influyen en el rendimiento académico de los estudiantes del nivel primario son afectados para esta investigación de acuerdo con el conocimiento de los estudiantes, por tal motivo no se pueden tomar todos los factores como parámetros de entrada.
3. El algoritmo de aprendizaje resilient backpropagation nos proporciona mejores resultados en la modificación de los pesos sinápticos, ayudando a reducir el tiempo de entrenamiento.
4. La red neuronal creada para la predicción del rendimiento académico de los estudiantes del nivel primario llegó alcanzar un valor porcentual del 84% en predicción.

7.1. CONCLUSIONES

5. Al tener un modelo matemático capaz de poder predecir variables complejas con un grado de validez muy alto es posible predecir el rendimiento académico de los estudiantes del nivel primario.

Capítulo VIII

RECOMENDACIONES

8.1 Recomendaciones

1. Es posible aplicar redes neuronales artificiales para la predicción del rendimiento académico de los estudiantes del nivel primario en cualquier institución educativa, debido a que los factores están determinados para latinoamerica, aunque es posible ajustar los factores para determinadas realidades.
2. Es posible crear un sistema de evaluación educativa donde se pueda predecir el rendimiento académico de los estudiantes del nivel primario.
3. Es posible utilizar esta investigación como partida a futuras investigaciones en mejora de la educación básica.
4. Es posible utilizar la predicción de rendimientos académicos para tomar medidas preventivas en los estudiantes.

REFERENCIAS

- [1] ALCALAY, L., AND ANTONIJEVIC, N. Variables afectivas. *Revista de Educación - México* (1987).
- [2] ALUMNOS, P. P. L. E. I. D. L. Programa internacional para la evaluación de estudiantes(programme for international student assesment o pisa). *Organización para la Cooperación y el Desarrollo Económico* (2012).
- [3] ALUMNOS, P. P. L. E. I. D. L. Resultados de pisa 2012 en foco. *Organización para la Cooperación y el Desarrollo Económico* (2014).
- [4] ALUMNOS, P. P. L. E. I. D. L. Pisa 2015 resultados clave. *Organización para la Cooperación y el Desarrollo Económico* (2016).
- [5] BAZALAR, L. A. C., AND ZEVALLOS, J. Z. Q. *Baremos de Pruebas Psicológicas: Niños y Adolescentes*. Biblioteca Nacional del Perú, 2013.
- [6] DUNSMORE, H. E., CONTE, S. D., AND SHEN, V. Software engineering metrics and models. *Menlo Park* (1986).
- [7] EDUCACIÓN, M. D. Currículo nacional de la educación básica. *Ministerio de Educación - Perú* (2017).

REFERENCIAS

- [8] FREEMAN, J. A., AND SKAPURA, D. M. Redes neuronales: Algoritmos, aplicaciones y técnicas de programación. *æ* 132 (1993), 47.
- [9] GIRALDO, L. D., AND MERA, R. Clima social escolar: percepción del estudiante. *Colombia Médica* 31, 1 (2000).
- [10] ISASI, P., AND GALVÁN, I. Redes de neuronas artificiales. un enfoque práctico. *Madrid [etc.]: Prentice Hall* (2004).
- [11] LECUN, Y. A., BOTTOU, L., ORR, G. B., AND MÜLLER, K.-R. Efficient backprop. In *Neural networks: Tricks of the trade*. Springer, 2012, pp. 9–48.
- [12] LEVINGER, B. School feeding programmes: myth and potential. *Prospects* 14, 3 (1984), 369–376.
- [13] LIVIERIS, L. E., DRAKOPOULOU, K., AND PINTELAS, P. Predicting students' performance using artificial neural networks. In *8th PanHellenic Conference with International Participation Information and Communication Technologies in Education* (2012), pp. 321–328.
- [14] LÓPEZ, M. V., RAMÍREZ ARBALLO, M., PORCEL, E., MATA, L. E., AND BARRETO, S. E. Redes neuronales para predecir el rendimiento académico de los alumnos ingresantes a la carrera de bioquímica de la facena-unne en función de sus conocimientos matemáticos previos. In *XVIII Congreso Argentino de Ciencias de la Computación* (2012).
- [15] LÓPEZ, M. V., RAMÍREZ ARBALLO, M., PORCEL, E., MATA, L. E., AND BARRETO, S. E. Redes neuronales para predecir el rendimiento académico de los alumnos ingresantes a la carrera de bioquímica de la facena-unne en función de sus conocien-

REFERENCIAS

- tos matemáticos previos. In *XVIII Congreso Argentino de Ciencias de la Computación* (2012).
- [16] MATAMALA, F. Neurohistología. *Universidad de la Frontera* (2011).
- [17] MCCULLOCH, W. S., AND PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics* 5, 4 (1943), 115–133.
- [18] MINSKY, M., AND PAPERT, S. *Perceptrons: an introduction to computational geometry*. MIT Press, 1969.
- [19] MIRANDA, L. Factores asociados al rendimiento escolar y sus implicancias para la política educativa del Perú. *Grupo de Análisis para el Desarrollo - GRADE* (2008).
- [20] MUSSO, M. F., KYNDT, E., CASCALLAR, E. C., AND DOCHY, F. Predicting general academic performance and identifying the differential contribution of participating variables using artificial neural networks. *Frontline Learning Research* 1, 1 (2013), 42–71.
- [21] NÚÑEZ, J. C. Motivación, aprendizaje y rendimiento académico. In *Trabajo presentado en el X Congreso Internacional Galego-Português de Psicopedagogia. Braga, Portugal* (2009).
- [22] OLABE, X. B. *Redes Neuronales Artificiales y sus Aplicaciones*, 2008.
- [23] PORCEL, E. A., DAPOZO, G. N., AND LÓPEZ, M. V. Predicción del rendimiento académico de alumnos de primer año de la facena (unne) en función de su caracterización socioeducativa. *Revista Electrónica de Investigación Educativa* 12, 2 (2010), 1–21.
- [24] RIEDMILLER, M., AND BRAUN, H. *A direct adaptive method for faster backpropagation learning: the RPROP algorithm*. Proceedings of the IEEE International Conference on Neural Networks, 1993.

REFERENCIAS

- [25] ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological review* 65, 6 (1958), 386.
- [26] RUMELHART, H. W. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. MIT, Cambridge, 1986.
- [27] SAINI, L. M. Peak load forecasting using bayesian regularization, resilient and adaptive backpropagation learning based artificial neural networks. *Electric Power Systems Research* 78, 7 (2008), 1302–1310.
- [28] SERRANO, A. J., SORIA, E., AND MARTIN, J. D. Redes neuronales artificiales. *Universidad de Valencia (Escuela Técnica Superior Ingeniería, Departamento de Ingeniería Electrónica): Valencia, España (2009)*.
- [29] USMAN, O. L., AND ADENUBI, A. O. Artificial neural network (ann) model for predicting students' academic performance. *Journal of Science and Information Technology October 13*, 2 (2013), 61–71.
- [30] VÉLEZ, E., SCHIEFELBEIN, E., AND VALENZUELA, J. Factores que afectan el rendimiento académico en la educación primaria: Revisión de la literatura de américa latina y el caribe. *OEA, Ministerio de Cultura y Educación de Argentina (1994)*.
- [31] ZAMBRANO MATALA, C., ROJAS DÍAZ, D., CARVAJAL CUELLO, K., AND ACUÑA LEIVA, G. Análisis de rendimiento académico estudiantil usando data warehouse y redes neuronales. *Ingeniare. Revista chilena de ingeniería* 19, 3 (2011), 369–381.

Anexos

Anexos A

Matriz de consistencia

Problema general	Objetivos	Hipótesis	Metodología	Población
Si las instituciones educativas pudieran conocer a priori los desempeños que tendrán los estudiantes en un trimestre, podrían intervenir para conocer qué factores están influyendo en su bajo rendimiento, con el fin de mejorar el desempeño académico que tendrán a lo largo de un período.	<p>Objetivo general:</p> <p>Determinar que el uso de las redes neuronales artificiales predican el rendimiento académico de los estudiantes del nivel primario.</p>	<p>General:</p> <p>El uso de las redes neuronales predecirá el rendimiento académico de los estudiantes del nivel primario en los colegios del distrito de Ventanilla.</p>	<p>Tipo de investigación:</p> <p>El tipo de investigación es no experimental transversal, debido a que las inferencias sobre las relaciones entre variables se realizan sin influencia directa y dichas relaciones se observan tal y como se han dado en su contexto.</p>	<p>Población:</p> <p>La población lo conforma todos los estudiantes del nivel primario del colegio "I.E 5091 Hijos De Grau", "I.E.P Héroes Del Pacífico" y "I.E. 5052 Virgen de la Merced" del distrito de Ventanilla, así mismo los profesores tutores de cada aula por año.</p>

<p>¿Se podrá conocer a priori el rendimiento académico que tendrán los estudiantes del nivel primario en un trimestre académico?</p>	<p>Objetivos específicos:</p> <p>Seleccionar los factores que más influyen en el rendimiento académico de los estudiantes del nivel primario.</p> <p>Diseñar y crear una red neuronal artificial para la predicción del rendimiento académico de los estudiantes.</p> <p>Validar el grado de predicción de la red neuronal artificial creada para la predicción del rendimiento académico de los estudiantes.</p>		<p>Diseño de la investigación:</p> <p>Para el desarrollo de este proyecto se deben realizar las siguientes etapas:</p> <p>-Estudio y evaluación</p> <p>-Recolección de datos y procesamiento</p> <p>-Desarrolló de una red neuronal</p> <p>-Validación del modelo</p>	<p>Muestra:</p> <p>Con el fin de trabajar una muestra representativa de la población, se ha considerado a todos los estudiantes del nivel primario de los colegios "I.E 5091 Hijos De Grau", "I.E.P Héroes Del Pacífico" y "I.E. 5052 Virgen de la Merced".</p>
--	--	--	--	--

Anexos B

Anexo para respaldo de la investigación

2.1 Formato de encuesta para estudiantes

2.1.1 Características de la escuela en relación con el estudiante

¿Cómo, es la relación que tienes con tu profesor?

Muy mala	Mala	Regular	Buena	Muy buena

¿En qué turno estudias?

Mañana	Tarde	Noche

2.1.2 Características de los materiales de educación

¿Cuentas con acceso a libros de texto y/o material de lectura?

Si	No

2.1. FORMATO DE ENCUESTA PARA ESTUDIANTES

¿En la clase utilizan juegos educativos u otros materiales que te ayuden a entender el tema de estudio?

Si	No

¿En tu salón tienen estantes para guardar los materiales de clase?

Si	No

2.1.3 Prácticas pedagógicas

¿Qué tan frecuente tu profesor te deja tareas para la casa?

Todos los días	Inter diario	Una vez por semana	Nunca

¿Qué tan frecuente tu profesor realiza evaluaciones?

Todos los días	Inter diario	Una vez por semana	Nunca

2.1.4 Características del estudiante

¿Estudiaste en jardín (inicial) antes de entrar a la escuela?

Si	No

¿Alguna vez repetiste un grado?

Si	No

2.1. FORMATO DE ENCUESTA PARA ESTUDIANTES

¿Estudias un tema antes de que el profesor te enseñe?

Siempre	Algunas veces	Nunca

¿Qué tan lejos está tu casa al colegio?

Muy lejos	Lejos	Normal	Cerca	Muy cerca

¿Cuándo lees un libro lo entiendes?

Muy poco	Poco	Regular	Mucho	Totalmente

¿Te gustan los libros u otros materiales de estudio (físico o virtual)?

Si	No

2.1.5 Características de la salud

¿Cuántos años tienes? _____

¿Eres hombre o mujer?

Hombre	Mujer

¿Tienes problemas de visión y/o auditivos?

Ninguno	Visión	Auditivos	Ambos

2.2. FORMATO DE ENCUESTA PARA PROFESORES

2.1.6 Características socioeconómicas

¿Los ingresos económicos de tu familia son?

Muy Altos	Altos	Medianos	Bajos	Muy bajos

¿Vives con ambos padres o solo con alguno de ellos?

Mamá	Papá	Ambos	Ninguno

¿Cuántos libros tienen en casa?

Muchos	Algunos	Ninguno

¿Qué tan grande es tu casa?

Grande	Mediana	Pequeña

¿En tu libreta de este año has tenido algún curso desaprobado?

Si	No

2.2 Formato de encuesta para profesores

2.2.1 Características de la escuela

El colegio tiene un tamaño:

Muy grande	Grande	Regular	Pequeño	Muy pequeño

2.2. FORMATO DE ENCUESTA PARA PROFESORES

¿La escuela cuenta con secundaria?

Si	No

¿Es una escuela de enseñanza mixta?

Si	No

2.2.2 Características del docente

¿Cuántos años tiene de estudios? _____

¿Cuánto años de experiencia como docente tiene? _____

¿Cuál es su estatus socioeconómicos?

A	B	C	D	E

¿Qué tan lejos vive esta su casa al colegio?

Muy lejos	Lejos	Normal	Cerca	Muy cerca

¿Qué tanta experiencia considera usted que tiene con el material que les presenta a los alumnos en clase?

Muy mala	Mala	Regular	Buena	Muy buena

2.2. FORMATO DE ENCUESTA PARA PROFESORES

2.2.3 Practicas pedagógicas

¿Realiza investigaciones?

Si	No

¿Utiliza estrategias nuevas en su docencia?

Si	No

2.2.4 Administración del colegio

¿Cree usted que el director tiene experiencia como director?

Si	No

¿El colegio brinda cursos extracurriculares?

Si	No