

UNIVERSIDAD NACIONAL DEL SANTA
ESCUELA DE POSGRADO
PROGRAMA DE DOCTORADO EN INGENIERÍA DE SISTEMAS
E INFORMÁTICA



UNS
ESCUELA DE
POSGRADO

**“El Rendimiento Académico de los Estudiantes de la
Universidad Nacional del Santa según los Factores
Socioeconómicos determinados mediante una
Red Neuronal Supervisada”**

**Tesis para optar el grado de
Doctor en Ingeniería de Sistemas e Informática**

Autor:

Mg. Navarrete Leal, Luzbeth Karin

Asesor:

Dr. Vega Moreno, Carlos Eugenio
DNI N°. 32937583
Código ORCID: 0000-0003-2955-0674

Línea de Investigación
Sistemas Inteligentes

Nuevo Chimbote - PERÚ
2024



UNS
ESCUELA DE
POSGRADO

CONSTANCIA DE ASESORAMIENTO DE LA TESIS DOCTORAL

Yo, VEGA MORENO CARLOS EUGENIO, mediante la presente, certifico mi asesoramiento de la tesis doctoral titulada:

EL RENDIMIENTO ACADÉMICO DE LOS ESTUDIANTES DE LA UNIVERSIDAD NACIONAL DEL SANTA SEGÚN LOS FACTORES SOCIOECONÓMICOS DETERMINADOS MEDIANTE UNA RED NEURONAL SUPERVISADA, elaborado por la magister NAVARRETE LEAL, LUZBETH KARIN para obtener el grado académico de Doctor en INGENIERÍA DE SISTEMAS E INFORMÁTICA en la escuela de posgrado de la Universidad Nacional del Santa.

Nuevo Chimbote, 01 de agosto de 2024

Dr. Vega Moreno, Carlos Eugenio

ASESOR

Código ORCID: 0000-0003-2955-0674

DNI N° 32937583



UNS
ESCUELA DE
POSGRADO

CONFORMIDAD DEL JURADO EVALUADOR

EL RENDIMIENTO ACADÉMICO DE LOS ESTUDIANTES DE LA UNIVERSIDAD NACIONAL DEL SANTA SEGÚN LOS FACTORES SOCIOECONÓMICOS DETERMINADOS MEDIANTE UNA RED NEURONAL SUPERVISADA

TESIS PARA OPTAR EL GRADO ACADÉMICO DE
DOCTOR EN INGENIERÍA DE SISTEMAS E INFORMÁTICA

Revisado y aprobado por el jurado evaluador:

Dra. BRIONES PEREYRA, LIZBETH DORA

PRESIDENTE

Código ORCID: 0000-0003-0626-7227

DNI N° 32960646

Dr. PAJUELO GONZALES, LUIS ALFREDO

SECRETARIO

Código ORCID: 0000-0003-4568-3434

DNI N° 32761325

Dr. VEGA MORENO, CARLOS EUGENIO

VOCAL

Código ORCID: 0000-0003-2955-0674

DNI N° 32937583



UNS
FACULTAD DE
POSGRADO

ACTA DE EVALUACIÓN DE SUSTENTACIÓN DE TESIS

A los once días del mes de junio del año 2024, siendo las 9:00 horas, en el aula P-01 de la Escuela de Posgrado de la Universidad Nacional del Santa, se reunieron los miembros del Jurado Evaluador, designados mediante Resolución Directoral N° 155-2024-EPG-UNS de fecha 26.03.2024, conformado por los docentes: Dra. Lizbeth Dora Briones Pereyra (Presidenta), Dr. Luis Alfredo Pajuelo Gonzales (Secretario) y Dr. Carlos Eugenio Vega Moreno (Vocal); con la finalidad de evaluar la tesis titulada **"EL RENDIMIENTO ACADÉMICO DE LOS ESTUDIANTES DE LA UNIVERSIDAD NACIONAL DEL SANTA SEGÚN LOS FACTORES SOCIOECONÓMICOS DETERMINADOS MEDIANTE UNA RED NEURONAL SUPERVISADA"**; presentado por la tesista **Luzbeth Karin Navarrete Leal**, egresada del programa de **Doctorado en Ingeniería de Sistemas e Informática**.

Sustentación autorizada mediante Resolución Directoral N° 311-2024-EPG-UNS de fecha 05 de junio de 2024.

El presidente del jurado autorizó el inicio del acto académico; producido y concluido el acto de sustentación de tesis, los miembros del jurado procedieron a la evaluación respectiva, haciendo una serie de preguntas y recomendaciones al tesista, quien dio respuestas a las interrogantes y observaciones.

El jurado después de deliberar sobre aspectos relacionados con el trabajo, contenido y sustentación del mismo y con las sugerencias pertinentes, declara la sustentación como APROBADO, asignándole la calificación de 18 (Dieciocho).

Siendo las 10:40 horas del mismo día se da por finalizado el acto académico, firmando la presente acta en señal de conformidad.

Dra. Lizbeth Dora Briones Pereyra
Presidenta

Dr. Luis Alfredo Pajuelo Gonzales
Secretario

Dr. Carlos Eugenio Vega Moreno
Vocal

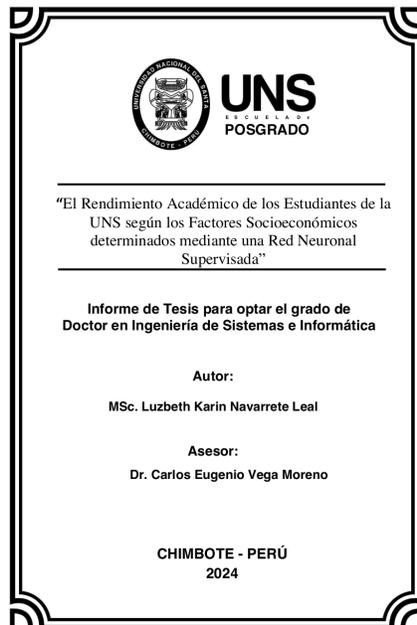


Recibo digital

Este recibo confirma que su trabajo ha sido recibido por **Turnitin**. A continuación podrá ver la información del recibo con respecto a su entrega.

La primera página de tus entregas se muestra abajo.

Autor de la entrega: Heron Morales
Título del ejercicio: Tesis Redes doctorado
Título de la entrega: INFORME TESIS DOCTORAL-24.03.2024.docx
Nombre del archivo: INFORME_TESIS_DOCTORAL-24.03.2024.docx
Tamaño del archivo: 3.47M
Total páginas: 96
Total de palabras: 16,655
Total de caracteres: 90,689
Fecha de entrega: 25-mar.-2024 01:21p. m. (UTC-0500)
Identificador de la entrega... 2330956792



INFORME TESIS DOCTORAL-24.03.2024.docx

INFORME DE ORIGINALIDAD

24%

INDICE DE SIMILITUD

23%

FUENTES DE INTERNET

5%

PUBLICACIONES

13%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	congreso.pucp.edu.pe Fuente de Internet	4%
2	personales.upv.es Fuente de Internet	3%
3	nanopdf.com Fuente de Internet	2%
4	repositorio.ucjc.edu Fuente de Internet	2%
5	repositorio.unp.edu.pe Fuente de Internet	2%
6	pdfslide.net Fuente de Internet	1%
7	Submitted to Universidad Cesar Vallejo Trabajo del estudiante	1%
8	accedacris.ulpgc.es Fuente de Internet	1%
9	www.researchgate.net Fuente de Internet	1%

DEDICATORIA

A DIOS,

Por haber dado a su hijo.

A JESUCRISTO,

Por haber entregado por mí, su vida.

AL ESPIRITU SANTO,

Porque cada día me consuela, bendice y guía.

A MI MADRE,

Por su garbo, coraje e inmenso amor.

A MI AMOR,

Por hacerme sentir especial, por su apoyo infinito, por creer y confiar en mí.

AGRADECIMIENTO

A DIOS, por estar presente en el día a día de mi vida y ser lámpara a mis pies y lumbrera en mi camino

A MI MADRE GINA BETTY LEAL REYES, agradecerte por todo el esfuerzo y apoyo que me ha brindado para completar mis estudios. Tu dedicación y sacrificio han sido fundamentales en cada paso de este camino. Por estar siempre a mi lado, por tus palabras de aliento en los momentos difíciles, por tu confianza, temple, coraje y firmeza. Has sido y eres mi pilar y mi fuente de inspiración constante. Sin tu amor y apoyo, este logro no habría sido posible.

AL AMOR DE MI VIDA, no existen palabras suficientes para expresar todo lo que significas para mí, el profundo agradecimiento que siento por tenerte en mi vida por tu apoyo incondicional, esfuerzo incansable y confianza depositada en mí. Por sacar la mejor versión de mí como mujer y persona más fuerte, valiente, compasiva, resiliente y empática. Me enseñaste a ver el mundo con otros ojos, apreciando cada momento y cada desafío como una oportunidad para crecer. Gracias por creer en mí cuando yo misma dudaba, por estar a mi lado en cada paso del camino. Tu amor y tu presencia han sido el motor que me impulsa a seguir adelante y a superarme cada día.

A mi asesor, Dr. Vega Moreno Carlos Eugenio, quien en calidad de asesor me apoya desinteresadamente en la realización de la presente investigación.

ÍNDICE

DEDICATORIA	i
AGRADECIMIENTO	ii
ÍNDICE	iii
ÍNDICE DE FIGURAS.....	v
ÍNDICE DE TABLAS.....	vii
RESUMEN.....	viii
ABSTRACT	ix
CAPÍTULO I.....	1
INTRODUCCIÓN.....	1
1.1. Planteamiento y fundamentación del problema de investigación	2
1.1.1. Realidad genérica del problema	2
1.1.2. Característica de la realidad específica	3
1.2. Antecedentes de la investigación	6
1.2.1. Antecedentes	6
1.3. Formulación del problema de investigación.....	10
1.4. Delimitación del estudio.....	10
1.5. Justificación e importancia de la investigación	11
1.6. Objetivos de la investigación	12
1.6.1. Objetivo general.....	12
1.6.2. Objetivos específicos	12
CAPÍTULO II.....	13
MARCO TEÓRICO	13
2.1. Fundamentos teóricos de la investigación.....	13
2.1.1. Rendimiento académico.....	13
2.1.2. Factores socioeconómicos.....	15
2.1.3. Redes Neuronales	19

2.1.4. Análisis de Correspondencias Múltiples (ACM)	43
2.1.5. Algoritmo de Levenberg-Marquardt	48
2.1.6. Gradiente Descendente	52
CAPÍTULO III.....	55
MARCO METODOLÓGICO.....	55
3.1. Hipótesis central de la investigación.....	55
3.2. Variables e indicadores de la investigación	55
3.3. Métodos de la investigación	56
3.4. Diseño o esquema de la investigación	56
3.5. Población y muestra	56
3.5.1. Población:	56
3.5.2. Muestra:	56
3.6. Actividades del proceso investigativo	56
3.7. Técnicas e instrumentos de la investigación	57
3.8. Procedimiento para la recolección de datos	57
3.9. Técnicas de procesamiento y análisis de los datos.....	58
CAPÍTULO IV	59
RESULTADOS Y DISCUSIÓN.....	59
4.1 Resultado del Objetivo General.....	59
4.2 Resultado del Objetivo específico nº 1	62
4.3 Resultado del Objetivo específico nº 2	62
4.4 Resultado del Objetivo específico nº 3.....	63
4.5 Resultado del Objetivo específico nº 4	68
4.6 Resultado del Objetivo específico nº 5	71
CAPÍTULO V	77
CONCLUSIONES Y RECOMENDACIONES.....	77
REFERENCIAS BIBLIOGRÁFICAS	80

ÍNDICE DE FIGURAS

Figura 1	22
<i>Modelo Simplificado de una Neurona Biológica</i>	22
Figura 2	22
<i>Prototipo de una Neurona Artificial</i>	22
Figura 3	23
<i>Función de Activación hardlim</i>	23
Figura 4	23
<i>Función de Activación hardlims</i>	23
Figura 5	24
<i>Función de Activación purelin</i>	24
Figura 6	24
<i>Función de Activación logsig y tansig</i>	24
Figura 7	25
<i>Función de Activación compet</i>	25
Figura 8	25
<i>Función de Activación satlin</i>	25
Figura 9	26
<i>Función de Activación satlins</i>	26
Figura 10	26
<i>Función de Activación Radial Basis</i>	26
Figura 11	27
<i>Red neuronal, con una Capa Feed-Forward</i>	27
Figura 12	28
<i>Red neuronal Multi-Capa Feed-Forward</i>	28
Figura 13	29
<i>Red neuronal recurrente</i>	29

Figura 14	30
<i>Diagrama de Bloques de Entrenamiento Supervisado</i>	30
Figura 15	30
<i>Diagrama de Bloques de Entrenamiento No Supervisado</i>	30
Figura 16	31
<i>Diagrama del Perceptrón Multicapa con una salida</i>	31
Figura 17	38
<i>Diagrama del Perceptrón Multicapa con una salida</i>	38
Figura 18	61
<i>Diagrama Biespacial</i>	61
Figura 19	65
<i>Diagrama de la RNA supervisada</i>	65
Figura 20	66
<i>Creando la RNA supervisada</i>	66
Figura 21	66
<i>Creando las variables de entrada y salida para la RNA supervisada</i>	66
Figura 22	67
<i>Esquema de la RNA supervisada</i>	67
Figura 23	67
<i>Creando las capas, neuronas y función de activación de la RNA supervisada</i>	67
Figura 24	68
<i>Entrenando la RNA supervisada</i>	68
Figura 25	71
<i>Evaluando la RNA supervisada en el Sistema</i>	71
Figura 26	75
<i>Frecuencia de errores de la RNA supervisada</i>	75
Figura 27	76
<i>Significancia de errores de la RNA supervisada</i>	76

ÍNDICE DE TABLAS

Tabla 1	55
<i>Operacionalización de variables</i>	55
Tabla 2	59
<i>Análisis de correspondencia múltiple, priorización y relación de las variables de los factores socioeconómicos y el rendimiento académico de los estudiantes de la UNS en el semestre 2020 I y II.</i>	59
Tabla 3	59
<i>Resumen del modelo de ACM.</i>	59
Tabla 4	60
<i>Medidas discriminantes de correlaciones del rendimiento académico de los estudiantes de la UNS en función de los factores socioeconómicos en el semestre 2020 I y II.</i>	60
Tabla 5	62
<i>Relación que Existe entre las Dimensiones Educación y las Dimensiones Económico, Vivienda y Salud, del Rendimiento Académico de los estudiantes de la UNS en función de los Factores Socioeconómicos en el semestre 2020 I y II.</i>	62
Tabla 6	64
<i>Variables de Entrada Normalizadas</i>	64
Tabla 7	74
<i>Medidas estadísticas de los errores de la red neuronal supervisada para determinar el rendimiento académico de los estudiantes de la UNS en función de los factores socioeconómicos en el semestre 2020 I y II.</i>	74
Tabla 8	75
<i>Errores según Kolmogorov</i>	75
Tabla 9	76
<i>Validando entradas y salidas de las notas.</i>	76

RESUMEN

La presente investigación es una propuesta para determinar el rendimiento académico de los estudiantes de la Universidad Nacional del Santa en el semestre 2020 I y II según los factores socioeconómicos, mediante el entrenamiento y evaluación de una red neuronal supervisada, asimismo busca predecir el cálculo del rendimiento académico de los estudiantes que no fueron considerados en el entrenamiento de los datos históricos, registrados en fichas socioeconómicas que fueron aplicados a los estudiantes como requisito antes de matricularse.

La población estuvo conformada por 6,022 estudiantes y una muestra de 2,979 estudiantes matriculados en el semestre académico 2020 – I y 2020 – II.

La investigación del tipo aplicada, efectuó un análisis estadístico e inferencial de los factores intervinientes, así como su relación y dependencia entre ellas como paso previo a la implementación en una red neuronal supervisada.

Los resultados nos permitieron obtener el número de capas, matrices de pesos y bias optimas de la red neuronal en la etapa del entrenamiento, y del análisis de los errores se concluyó como no es significativo.

Palabras claves: Rendimiento Académico, Factores Socioeconómicos, Ficha Socioeconómica, Red Neuronal Artificial, Función de Activación, Gradiente descendente, Backpropagation.

ABSTRACT

The present research is a proposal to determine the academic performance of the students of the National University of Santa in the 2020 semester I and II according to socioeconomic factors, through the training and evaluation of a supervised neural network, it also seeks to predict the calculation of performance academic performance of students who were not considered in the training of historical data, recorded in socioeconomic sheets that were applied to students as a requirement before enrolling.

The population was made up of 6,022 students and a sample of 2,979 students enrolled in the academic semester 2020 – I and 2020 – II.

The applied type of research carried out a statistical and inferential analysis of the intervening factors, as well as their relationship and dependence between them as a prior step to implementation in a supervised neural network.

The results allowed us to obtain the number of layers, weight matrices and optimal bias of the neural network in the training stage, and from the analysis of the errors it was concluded that it is not significant.

Keywords: Academic Performance, Socioeconomic Factors, Socioeconomic Record, Artificial Neural Network, Activation Function, Gradient Descent, Backpropagation.

CAPÍTULO I

INTRODUCCIÓN

El rendimiento académico de los estudiantes ha sido objeto de estudio durante décadas, dado su impacto en el desarrollo personal y profesional de los individuos, así como en el progreso social y económico de las comunidades. Diversos factores influyen en este rendimiento, entre los cuales los factores socioeconómicos juegan un papel fundamental. Estos factores incluyen variables como el nivel educativo de los padres, el acceso a recursos educativos, el entorno familiar y las condiciones socioeconómicas generales. En este contexto, la presente investigación se centra en cómo estas variables pueden predecir el rendimiento académico, utilizando herramientas avanzadas de análisis de datos, específicamente redes neuronales supervisadas.

Las redes neuronales son modelos computacionales inspirados en la estructura y funcionamiento del cerebro humano, capaces de aprender patrones complejos a partir de grandes volúmenes de datos. En el ámbito educativo, su aplicación para analizar el rendimiento académico en relación con factores socioeconómicos ofrece una perspectiva innovadora y profunda que puede aportar información valiosa a educadores y formuladores de políticas.

Este estudio se propone investigar la relación entre el rendimiento académico de los estudiantes y los factores socioeconómicos mediante el uso de redes neuronales supervisadas. A través de la recolección de datos de múltiples fuentes, se busca identificar patrones y correlaciones que puedan no ser evidentes mediante métodos estadísticos tradicionales. Al aplicar esta técnica de machine learning, se espera no solo predecir el rendimiento académico, sino también ofrecer insights sobre qué factores socioeconómicos tienen un impacto más significativo.

En resumen, esta investigación propone un enfoque innovador que combina la neurociencia artificial y la sociología educativa, con el objetivo de desentrañar la compleja interacción entre el rendimiento académico y los factores socioeconómicos, abriendo nuevas vías para la mejora del sistema educativo y el apoyo a los estudiantes.

1.1. Planteamiento y fundamentación del problema de investigación

1.1.1. Realidad genérica del problema

Actualmente, en el entorno de la educación superior el rendimiento académico es uno de los pilares principales de la eficiencia y calidad educativa que representa a la organización u institución, considerado como el hito del éxito o fracaso del estudiante.

Para comprender las consecuencias en la comunidad universitaria, sobre todo el impacto acerca de la adaptación a los nuevos métodos y procesos de enseñanza aprendizaje, en referencia al uso de plataformas virtuales, la disponibilidad de internet y equipos de cómputo. Según informe de la UNESCO, existen 290,5 millones de estudiantes a nivel mundial sin percibir clases, una cifra sin antecedentes. Por tal motivo la UNESCO está brindando a aquellos países un soporte inmediato que incluye soluciones para el aprendizaje a distancia inclusivo. De la misma forma se está realizando en el nivel universitario en nuestro país, bajo este contexto, la Superintendencia Nacional de Educación Superior Universitaria (Sunedu) publicó en el Diario Oficial El Peruano el 29 de marzo los criterios para el dictado de asignaturas mediante sistemas de educación no presencial por parte de universidades y escuelas de posgrado, frente a esta problemática la presente investigación considera a los factores socioeconómicos como elementos determinantes en el rendimiento académico, CEPAL-UNESCO (2020). La educación en tiempo de la pandemia de covid-19.

Si bien, existen datos que indican la ausencia de computadoras para seguir las clases a distancia y esto se suma la carencia de internet, una situación que amenaza con aumentar la ruptura digital, según alerta la UNESCO. Según los estudios de la Organización de la ONU para la Educación, la Ciencia y la Cultura (Unesco), en colaboración con la Unión Internacional de Telecomunicaciones (UIT), 826 millones de estudiantes no cuentan con ordenador y 706 millones menos aún acceso a internet en sus hogares. Por otra parte, están los docentes, desde el inicio de la pandemia miles de docentes universitarios de las universidades se vieron forzados a aceptar el modelo de educación virtual y a distancia, pero hoy presentan una gran dificultad. El variar de forma para desarrollar las clases, luchar contra las dificultades de los estudiantes por el acceso a internet y equipos de cómputo, lograr

llamar la atención de los jóvenes universitarios, hacer seguimiento al proceso de aprendizaje, son algunos de los temas señalados como un gran reto. Para un gran sector de los docentes, el proceso de adaptación de un modelo presencial a uno virtual o en línea es un shock. Y no porque no supiera usar plataformas digitales, sino porque el centro de estudios en el que trabaja no está preparado o adaptado a la necesidad. Arteta & Mamani (2021). Educación virtual en tiempos de pandemia.

1.1.2. Característica de la realidad específica

Hoy en día, una de las problemáticas educativas poco analizadas en la Universidad Nacional del Santa es la eficiencia del proceso de aprendizaje reflejada en el desempeño académico, el cual es evaluado periódicamente a través de los factores que influyen en el rendimiento académico tales como los factores socioeconómicos, factores culturales, factores sociales, factores personales, factores pedagógicos, factores psicológicos y factores fisiológicos. Este rendimiento académico únicamente se está dando en la Universidad Nacional del Santa a nivel de un promedio de los alumnos de acuerdo a los cursos que llevan en cada semestre y no existe una herramienta que permita predecir los rendimientos académicos a partir de las notas que tiene cada estudiante, además NO existe una relación con los factores socioeconómicos, que es relevante durante la etapa universitaria de cada uno de los estudiantes.

Limón Del Pezo, G. (2022). *Factores socioeconómicos y el desempeño académico. Caso: Estudiantes de la carrera de Gestión Social y Desarrollo de la UPSE, 2022*. [Proyecto de investigación, Universidad Estatal Península de Santa Elena]. Repositorio UEPSE.

<https://repositorio.upse.edu.ec/handle/46000/9079>

En la cual es importante manifestar que, dentro de la población estudiantil universitaria, cada uno de los estudiantes, se enfrentan a distintas realidades de desigualdad socioeconómica de su entorno cotidiano que influyen significativamente en el compromiso de su proceso de aprendizaje y por ende en los resultados de desempeño académico.

Se considera que la diferencia de los resultados en los primeros semestres se debe al limitado acceso a la tecnología, poco cumplimiento con las asignaciones, distractores del hogar, debido a la modalidad virtual, en comparación a la presencialidad, León, W. (2021)

Múltiples factores vinculados a la convivencia familiar, nivel de ingresos económicos, dinámica de movilidad social, capacidad de aprendizaje, bienestar integral, motivacional, estabilidad emocional, metodologías de enseñanza, el tipo de institución educativa, entre otros, problemas externos como el desempleo, pobreza y lugar de residencia inciden en el área educativa específicamente en el desempeño académico, en ocasiones cuando los resultados son insatisfactorios tiende a evidenciar problemáticas como rezagos, deserción y fracasos educativos.

El desempeño académico de los estudiantes es una característica educativa, la cual es reconocida solo para quienes con su esfuerzo logran alcanzar los mejores resultados en el proceso de manera interna de las instituciones educativas, dejando de lado una problemática que afecta a la mayor parte de la comunidad educativa en todos los niveles formación, dichas acciones no son una garantía de aprendizaje y mucho menos del acceso a una educación de calidad, inclusiva y de equidad para todos, sin embargo gran parte de los estudiantes que no logran las mejores calificaciones debido al contexto socioeconómico del que provienen.

Mientras que en los desafíos del acontecer educativo de tercer nivel, se basa en la evaluación curricular relacionada con la enseñanza-aprendizaje y el seguimiento académico de la comunidad educativa, al cuestionar que no se están logrando los resultados esperados en los procesos de aprendizaje en los estudiantes, en el cual es importante destacar que las calificaciones no siempre definen la capacidad y el valor de los estudiantes, pero funcionan como un indicador cuantitativo para medir las deficiencias y logros obtenidos en las instituciones, durante su proceso de formación académica, además de

determinar la aprobación o reprobación de asignaturas de los estudiantes dentro de un periodo académico, como una característica calidad educativa.

Ayllon, L. (2022). *La influencia de la alta autoestima y rendimiento académico en los estudiantes de noveno ciclo de la Escuela Profesional de Administración y Sistemas de la Universidad Peruana Los Andes – Satipo, 2019*. [Proyecto de tesis, Universidad Nacional Daniel Alcides Carrión]. Repositorio UNDAC
<http://repositorio.undac.edu.pe/handle/undac/2816>

El bajo rendimiento académico se genera por una multiplicidad de situaciones, donde incluso la labor docente está presente:

“Las causas del bajo rendimiento académico son muy variadas, de las cuales se pueden enunciar: desintegración familiar, estilos de crianza, padres trabajadores, desinterés de los padres, adicciones, hijos predilectos, hijos no deseados, por citar algunas. Dichas causas pueden estar asociadas a variables pedagógicas y personales del alumno; entre las pedagógicas se consideran: maestría pedagógica-personalidad, proceso didáctico, acompañamiento pedagógico, clima de la clase y tamaño del grupo. De las variables personales del alumno se han estudiado las sociodemográficas, las familiares, motivacionales, cognoscitivas y emocionales. Específicamente las familiares requieren del trabajo de la familia con el estudiante, sus problemas y los vínculos que establece con la institución educativa.”

El docente cumple un rol muy importante en la educación su aporte y conducción para desarrollar el proceso de aprendizaje está premunido de diferentes facetas, que van desde facilitador, tutor, gestor, conductor, etc., lo que le posibilita estar preparado para asumir los nuevos retos del sistema educativo, entre los que destaca la adaptación digital, uso de herramientas diversas, conocimiento detallado de la disciplina que enseña y la formación de distintas capacidades sociales. Se prepara a los estudiantes para afrontar retos diversos en la vida y en la diversidad de relaciones sociales y culturales que enfrenta, asimismo, para desarrollar y fortalecer sus habilidades, considerando que la práctica educativa implica un aprendizaje significativo que perdure en el tiempo y le sirva de base para resolver y enfrentar cualquier situación problemática.

La educación superior en la actualidad no responde a los desafíos de la sociedad que plantea el desarrollo y progreso a nivel mundial, por la inserción de los profesionales de diversas carreras profesionales al mundo laboral.

Ruiz, R. (2020). "El bajo rendimiento académico, el excesivo tiempo invertido en el estudio de una titulación, el abandono de los estudios, son problemas comunes a todos los países de nuestro entorno cultural y económico. En Europa este tema no sólo preocupa a las autoridades educativas, sino también a los responsables políticos, que en tiempos de ajustes presupuestarios comprueban cómo el gasto público en educación no produce los resultados deseados."

1.2. Antecedentes de la investigación

1.2.1. Antecedentes

Antecedentes Internacionales

Brand, Uribe, & Valencia, (2023) en su artículo "Aplicación de redes neuronales artificiales para predecir la creación de valor de los gerentes en clubes del fútbol amateur" tiene como objetivo establecer la creación de valor de los gerentes en clubes de fútbol de amateur a través de una metodología cuantitativa mediante la aplicación de un cuestionario de 305 directivos deportivos y administrativos, obteniendo como resultado la creación de valor por medio de nuevas capacidades afecta a la organización deportiva en la medida que el talento humano pueda ser capacitado para formular procesos novedosos en servicios e interactuar en búsqueda de patrocinadores, socios y entidades con capacidades de crear valor, la investigación ha comprobado el efecto del individuo como elemento central para crear valor.

Bedoya, Guarín, & Agudelo, (2023) en su artículo "Aplicación de técnicas de inteligencia artificial para la detección de tuberculosis pulmonar en Colombia", cuyo objetivo es identificar si un paciente padece tuberculosis, proponiendo modelos basados en cuatro técnicas de aprendizaje supervisado (redes neuronales, árboles de decisión y dos métodos de ensamble) permitiendo ejecutar un diagnóstico positivo o negativo, en función de unas variables de entrada y de diagnósticos anteriormente registrados de pacientes sanos y enfermos, obteniendo como resultado al método de ensamble Extra Trees siendo el más exacto comparado con las otras técnicas de predicción alcanzando un área bajo la curva ROC de 95,63%.

Çetinkaya & Kaan, (2020) "Prediction of middle school students' programming talent using artificial neural networks", the objective of this study

focused on predicting middle school students' programming aptitude using artificial neural network (ANN) algorithms. A participant survey was developed and applied to middle school students consisting of fifth, sixth, and seventh graders from Konya Science Center, Turkey. After the completion of the survey, the participants then took the 20-level Classic Maze course (CMC) on Code.org. The participants' final scores in the CMC were calculated based on the level they completed and the lines of codes they wrote. The best results were obtained using the Bayesian regularization algorithm: Training-R = 9.72284e_1; Test-R = 9.12687e_1, and All-R = 9.597e_1.

The results show that ANN is an appropriate machine learning method that can forecast participants' skills, such as analytical thinking, problem-solving, and programming aptitude.

Romero, Aznar, Hinojo, & Gómez (2020) en la presente investigación "Uso de los Dispositivos Móviles en Educación Superior: Relación con el Rendimiento Académico y la Autorregulación del Aprendizaje" tiene como objetivo estudiar el predominio de los dispositivos móviles en el rendimiento académico y en la autorregulación del aprendizaje. Contemplando la muestra total de 420 estudiantes del Grado en Educación Primaria de la Universidad de Granada. Se aplicó el método cuantitativo basado en la aplicación de un cuestionario en línea. Teniendo como resultado proyecciones significativas del género al emplear dispositivos móviles, del mismo modo, al emplear dispositivos móviles en la autorregulación del aprendizaje. Aunque, al emplear los dispositivos móviles predominó insignificadamente en el rendimiento académico. En resumen los estudiantes confirman que el dispositivo móvil apoya en su proceso de aprendizaje, porque permite la comunicación fluida a la información. Al final, el predominio de los dispositivos móviles en la educación que lo utilizan es bastante (44.3%), mucho (15.7%), poco (33.6%) y nada (6.4%) es punto relevante en el reconocimiento de dispositivos tecnológicos que influyen de manera positiva en el aprendizaje, quedando seleccionados el ordenador portátil (80%), los Smartphones (12.9%) y las Tablets (6.4%).

Espada, Rocu, Navia, & Gómez (2020) la investigación "Rendimiento Académico y Satisfacción de los Estudiantes Universitarios hacia el método flipped classroom" tiene como objetivo estudiar el rendimiento académico, la satisfacción

y la percepción de la experiencia educativa de los estudiantes universitarios hacia el uso del método de flipped classroom. Participaron 94 estudiantes universitarios como muestra final. El artículo presenta un diseño mixto, es decir una combinación de metodologías cuantitativas y cualitativas, donde por medio de las técnicas cuantitativas se estimó el rendimiento académico de los estudiantes, y por las cualitativas se estudio la satisfacción y percepción de los estudiantes y la dirección del docente para el método de clase invertida. Obteniendo resultados favorables en los estudiantes en la clase invertida en vez del método tradicional. Los estudiantes resaltaron que la clase invertida les proporcionó incrementar su aprendizaje y distribuir su tiempo. La desventaja esta en la programación oportuna de su tiempo en la aplicación del método y trascendencia de la calidad de los bienes tecnológicos empleados. Concluyendo que el método de clase invertida es oportuna al entorno superior con un (98%), a diferencia del método tradicional con un (11%) porque incentiva al estudiante y enriquece los contenidos, para esto es necesario el uso apropiado de medios tecnológicos.

Quintana, Flores, Lazcano, & Landassuri (2018) La presente investigación “Ensamble de Clasificadores para Determinar el Perfil Académico del Estudiante usando Árboles de Decisión y Redes Neuronales” tiene como objetivo plantear un ensamble de clasificadores definiendo el perfil académico del estudiante, fundamentado en el promedio global así como en los valores vinculados a los factores educativos: actividades de estudio, formas de aprendizaje y hábitos de estudio. Se trabajó con una población estudiantil incorporada en los años 2008, 2009 y 2010 de la Universidad Autónoma del Estado de México en la diversas escuelas profesionales, determinando su categoría con su promedio global. Las categorías se precisaron: excelente, bueno y regular. Se aplicó el algoritmo C4.5 según los conjuntos de factores, originando el clasificador adecuado. Para el método de ensamble de clasificadores se aplicó una red neuronal artificial, donde los valores de entrada son la distribución fijada por los tres clasificadores, entrenadas para determinar la clase apropiada empleando una parte de los datos. Observando finalmente el cumplimiento esperado del ensamble planteado con un (80.4%) en comparación con los clasificadores independientes (65.5%).

Torres, Aldana, & Piedra (2016) en el artículo "Red Neuronal Multicapa para la Evaluación de Competencias Laborales", tiene como objetivo plantear una red neuronal artificial empleando datos de la herramienta GESPRO para estudiar, analizar y evaluar la competencia de su personal en las labores diarias durante el desarrollo de proyectos. La Universidad de las Ciencias Informáticas, contempla una red de centros de desarrollo de software organizados por proyectos, la muestra fue aplicada en una encuesta a 14 áreas de 12 de estos centros. Se desarrolló un análisis de las ARN enfocados en el tipo Perceptrón Multicapa y la evaluación de las competencias, implementando una red neuronal multicapa para la evaluación de competencias usando el lenguaje PL/R con las funciones establecidas. Obteniendo como resultado final una red neuronal entrenada facilitando la evaluación de competencias laborales en el sistema GESPRO. Confirmando que la ARN planteada incrementa la eficiencia en un (90%) a diferencia de los métodos tradicionales después de la aplicación experimental.

Antecedente Nacionales

Incio, Estela, & Capuñay, (2023) en su artículo "Modelo de red neuronal artificial para predecir resultados académicos en la asignatura Matemática II", tiene como objetivo mostrar el diseño y entrenamiento de una red neuronal artificial (RNA) para predecir resultados académicos de estudiantes de ingeniería Civil en la asignatura de matemática II, se utilizó la metodología CRISP-DM, se implementó en el software Matlab utilizando el comando nnstart y dos algoritmos de aprendizaje: Scaled Conjugate Gradiente (SCG) y Levenberg-Marquardt (LM), el rendimiento del modelo se evaluó mediante el error cuadrático medio y el coeficiente de correlación, concluyendo que el algoritmo LM logró mejor efectividad en la predicción.

Gonzales & Evaristo (2021) el artículo "Rendimiento Académico y Deserción de Estudiantes Universitarios de un Curso en Modalidad Virtual y Presencial", tiene como objetivo establecer el impacto de un curso en modalidad virtual en el rendimiento académico y deserción de sector de estudiantes universitarios de cierta universidad particular. Tomando como muestra el total de la población estudiantil en un mismo curso tanto para modalidad virtual y presencial. Donde aplicó un diseño cuasiesperimental con posprueba a ambos grupos. Obteniendo diversos

resultados; a pesar de ello, al estimar el promedio final, no se contemplan divergencias estadísticas significativas; así como, no se registraron divergencias respecto de la deserción, considerándolo insignificante en ambos grupos. Coincidiendo con otros autores donde mencionan que el tipo de modalidad no es un componente concluyente sobre las variables. Ambas variables de rendimiento académico y deserción, al compararlas presentan resultados negativos que inciden en los estudiantes y que a su vez necesita de diferentes aspectos como la integración social y compromiso institucional e individual del estudiante, su capacidad intelectual, compromiso académico e identificación profesional, así como los factores socioeconómicos, educativos y demográficos.

Gallo (2021) en su investigación “Estrategias Didácticas y el Rendimiento Académico en los Estudiantes de la Escuela de Ingeniería” tiene como objetivo analizar la correspondencia entre las estrategias didácticas y el rendimiento académico en los estudiantes de la Escuela de Ingeniería Industrial en la Universidad San Pedro - filial Sullana. Considerando una muestra de 234, de una población de 600 estudiantes. Aplicando el método cuantitativo – descriptivo y de tipo correlacional, utilizando como técnica e instrumento, a la entrevista y el cuestionario. Confirmando una correspondencia relevante para las estrategias didácticas y el rendimiento académico en los estudiantes, según valores de la estadística descriptiva presentaron porcentajes elevados como (39.3% - 50.9%) y la estadística inferencial valores significativos. Por consiguiente se aprueba las hipótesis alternativas y se niegan las hipótesis nulas.

1.3. Formulación del problema de investigación

¿Cómo determinar el rendimiento académico de los estudiantes de la Universidad Nacional del Santa en función de los Factores Socioeconómicos en el semestre 2020 I y II mediante la implementación de una Red Neuronal Supervisada?

1.4. Delimitación del estudio

- El acceso a la información de las fichas socioeconómicas y las boletas de notas en las oficinas pertinentes de la UNS.

- Datos no registrados en los diferentes aspectos de la ficha de cada estudiante de la UNS.
- Disponer de una laptop o PC de baja características como capacidad rendimiento velocidad que nos impida trabajar al máximo.

1.5. Justificación e importancia de la investigación

Justificación de la Investigación sobre el Rendimiento Académico de los Estudiantes de la Universidad Nacional del Santa utilizando Redes Neuronales Supervisadas tipo Bacpropagation.

Aspecto Teórico: La aplicación de redes neuronales supervisadas mediante el algoritmo de Backpropagation en el análisis del rendimiento académico de los estudiantes es un enfoque innovador respaldado por teorías fundamentales de aprendizaje automático y psicología educativa. Este método permitió modelar de manera eficiente las complejas interacciones entre factores socioeconómicos y el rendimiento académico, brindando una comprensión más profunda de cómo estos factores influyen en el éxito del estudiante.

Aspecto Práctico: El uso de redes neuronales supervisadas con Backpropagation en esta investigación ofrece una herramienta práctica y poderosa para analizar grandes conjuntos de datos de manera eficiente y precisa. Esto permitió identificar patrones, tendencias y relaciones no lineales entre variables socioeconómicas y el rendimiento académico, facilitando la formulación de estrategias específicas de apoyo al estudiante y la toma de decisiones informadas por parte de las autoridades académicas.

Aspecto Económico: La implementación de técnicas de aprendizaje automático como Backpropagation puede resultar económicamente ventajosa al optimizar la utilización de recursos computacionales y humanos en la investigación. Además, al comprender mejor los factores que influyen en el rendimiento académico, se pueden identificar oportunidades para mejorar la eficiencia y la efectividad de los programas de apoyo estudiantil, lo que potencialmente conduce a una asignación más eficiente de recursos económicos en el ámbito educativo.

Aspecto Social: Esta investigación tiene implicaciones sociales significativas al ayudar a identificar y abordar las disparidades en el rendimiento académico que pueden estar relacionadas con factores socioeconómicos. Al comprender mejor estas relaciones a través del análisis de datos con redes neuronales supervisadas,

se pueden desarrollar intervenciones más efectivas para promover la equidad educativa y mejorar las oportunidades de éxito para todos los estudiantes, independientemente de su origen socioeconómico.

1.6. Objetivos de la investigación

1.6.1. Objetivo general

Elaborar una Red Neuronal Supervisada para el cálculo del Rendimiento Académico de los estudiantes de la UNS en función de los Factores Socioeconómicos en el semestre 2020 I y II.

1.6.2. Objetivos específicos

- 1) Recopilar información de la ficha socioeconómica y calificaciones del rendimiento académico de los estudiantes de la UNS de los semestres 2020-I y II.
- 2) Describir los factores socioeconómicos de los estudiantes de la UNS.
- 3) Diseñar la red neuronal supervisada para determinar el rendimiento académico de los estudiantes de la UNS en función de los factores Socioeconómicos.
- 4) Entrenar la red neuronal supervisada para determinar el rendimiento académico de los estudiantes de la UNS en función de los factores Socioeconómicos.
- 5) Evaluar la red neuronal supervisada para determinar el rendimiento académico de los estudiantes de la UNS en función de los factores Socioeconómicos.

CAPÍTULO II

MARCO TEÓRICO

2.1. Fundamentos teóricos de la investigación

Como el eje principal de la investigación es encontrar el rendimiento académico de los estudiantes, el cual implica hablar de los factores influyentes en dicho rendimiento académico.

2.1.1. Rendimiento académico

El rendimiento académico de los estudiantes universitarios constituye un factor imprescindible y fundamental para la valoración de la calidad educativa en la enseñanza superior.

El rendimiento académico es la suma de diferentes y complejos factores que actúan en la persona que aprende, y ha sido definido con un valor atribuido al logro del estudiante en las tareas académicas. Se mide mediante las calificaciones obtenidas, con una valoración cuantitativa, cuyos resultados muestran las materias ganadas o perdidas, la deserción y el grado de éxito académico. Pérez Luño, Ramón Jerónimo, & Sánchez Vásquez (2000). *Análisis Exploratorio de las Variables que Condicionan el Rendimiento Académico*. Universidad Pablo de Olavide.

Las notas obtenidas, como un indicador que certifica el logro alcanzado, son un indicador preciso y accesible para valorar el rendimiento académico, si se asume que las notas reflejan los logros académicos en los diferentes componentes del aprendizaje, que incluyen aspectos personales, académicos y sociales Rodríguez, Fita, & Torrado (2004). *El Rendimiento Académico en la Transición Secundaria-Universidad*.

Cada universidad determina criterios evaluativos propios, para obtener un promedio ponderado (valoración) de las materias que cursa el estudiante, donde se toman en cuenta elementos como la cantidad de materias, el número de créditos y el valor obtenido en cada una de ellas, que generalmente se denomina “nota de aprovechamiento”. En las calificaciones como medida de los resultados de

enseñanza hay que tomar en cuenta que son producto de condicionantes tanto de tipo personal del estudiante, como didácticas del docente, contextuales e institucionales, y que todos estos factores median el resultado académico final.

Por sus características, hay consenso en la comunidad de especialistas de lo difícil que resulta identificar el rendimiento académico en la educación superior, debido a que es problemático y confuso identificar el rendimiento académico con las notas. Advierte al respecto que se debe diferenciar entre el rendimiento académico inmediato refiriéndose a las notas, y el mediato refiriéndose a los logros personales y profesionales.

Rodríguez, Fita, & Torrado (2004). *El Rendimiento Académico en la Transición Secundaria-Universidad.*, hace una valoración más amplia del rendimiento académico, pues lo evalúa en relación con el éxito, retraso y abandono, y en un sentido más estricto por medio de las notas. La valoración del rendimiento académico no conduce a otra cosa que a la relación entre lo que se aprende y lo que se logra desde el punto de vista del aprendizaje, y se valora con una nota, cuyo resultado se desprende de la sumatoria de la nota de aprovechamiento del estudiante en las diferentes actividades académicas, a las que se sometió en un ciclo académico determinado.

Las observaciones sobre la influencia de los sistemas educativos en el rendimiento académico suelen ser arriesgadas. Se critica por la falta de adecuación contextual de los diferentes estudios, argumentando que el rendimiento no solo tiene efectos diferenciales según un contexto determinado, sino que hay que tomar en cuenta los criterios de evaluación con que se presentan los estudios, ya que su metodología condiciona los resultados. De ahí la dificultad de realizar generalizaciones en torno a un tema tan complejo en contextos disímiles.

Estudios llevados a cabo por Vélez Van & Roa (2005). *Factors Associated with Academic Perfomance in Medical Students.*, con estudiantes universitarios en Colombia; Carrión Pérez (2007). *Validación de Características al Ingreso como Predictores del Rendimiento Académico en la Carrera de Medicina*; Valle Arias, González Cabanach, Núñez Pérez, & Martínez Rodríguez (1999). *Un Modelo Causal sobre los Determinantes cognitivo - Motivacionales del Rendimiento Académico*, en la Universidad de Coruña, en España y Montero, Villalobos, en la Universidad de Costa Rica, se ha abordado el tema del rendimiento académico a

partir de variables cognitivas, emocionales y socioeconómicas, entre las que se incluyen resultados de la educación secundaria, pruebas del Estado, el examen de ingreso a la universidad, las pruebas de aptitudes intelectuales, factores psicosociales (consumo de alcohol y otro tipo de sustancias), rasgos de personalidad y factores relacionados con el estado emocional hacia el estudio, calificaciones obtenidas, composición familiar, el interés vocacional, los hábitos de estudio y el nivel académico de los padres.

Conocer los diferentes factores que inciden en el rendimiento académico en el campo de la educación superior de una manera más integral, permite obtener resultados tanto cualitativos como cuantitativos para propiciar un enfoque más completo en la toma de decisiones para mejorar los niveles de pertinencia, equidad y calidad educativa. La determinación de indicadores de índole cuantitativa y cualitativa no implica que los factores asociados al rendimiento académico que se tomen en cuenta son exclusivos del campo universitario. Por su complejidad, algunos de ellos son fácilmente adaptables a otras realidades, lo que muestra su capacidad explicativa y analítica en relación con el éxito académico en cualquier sector educativo, independientemente de si se trata de instituciones públicas o privadas.

2.1.2. Factores socioeconómicos

El rendimiento académico, por ser multicausal, envuelve una enorme capacidad explicativa de los distintos factores y espacios temporales que intervienen en el proceso de aprendizaje. Existen diferentes aspectos que se asocian al rendimiento académico, entre los que intervienen componentes tanto internos como externos al individuo. Pueden ser de orden social, cognitivo y emocional, que se clasifican en tres categorías: determinantes personales, determinantes sociales y determinantes institucionales, que presentan subcategorías o indicadores.

Para que los estudios de rendimiento académico sean útiles, es importante identificar el tipo de influencia de los factores asociados al éxito o al fracaso del estudiantado; es decir, de los niveles de influencia entre las variables por considerar para determinar factores causales y mediaciones que determinan las relaciones entre las distintas categorías de variables personales, sociales e institucionales. Estas variables, además de ofrecer información de carácter estructural y objetivo, toman en cuenta la percepción del estudiante respecto de factores asociados al rendimiento académico y a su posible impacto en los resultados académicos. La

mayoría de estudios sobre rendimiento académico se basan en una aproximación metodológica de tipo predictivo, donde se utilizan modelos de regresión múltiple, pocas veces complementados con modelos explicativos que favorecen un análisis más integral de los factores asociados al rendimiento académico, por lo que es útil describir las características de los determinantes mencionados Castejón & Pérez (1998). *Un Modelo Causal - Explicativo de las variables Psicosociales en el Rendimiento Académico*.

Durón & Oropeza (1999). *Análisis Predictivo a partir de la Interacción Familiar y Escolar de Estudiantes de Nivel Superior*, mencionan la presencia de algunos factores:

- 1. Factores económicos:** Se identifican dos tipos de factores, los aspectos económicos sociales y privados, entre los primeros se encuentra la capacidad inversora de la sociedad en educación superior y la inversión social en instituciones educativas (gasto público en educación); entre los aspectos privados se mencionan los costos que debe asumir el individuo para acceder a la educación superior, como los costes de matrícula, los libros, los costos de mantenimiento y el costo de oportunidad el cual dependerá de la situación del mercado laboral.
- 2. Factor sociales y familiares:** Son aquellos que influyen en las características familiares y socioeconómicas de los estudiantes, entre ellos se destacan el nivel de educación de los padres, el tipo de profesión de los mismos y el número de hermanos, estos aspectos generan a través de la transmisión de valores a los hijos y de la existencia de un mayor o menor ambiente cultural lo que contribuye a la demanda de la educación, por otro lado, desde el ámbito social se considera el nivel educativo del entorno, origen rural o urbano, la religión, el idioma familiar entre otros.
- 3. Factores pedagógicos:** Son aquellos aspectos que se relacionan con la calidad de la enseñanza. Entre ellos están el número de alumnos por maestro, los métodos y materiales didácticos utilizados, la motivación de los estudiantes y el tiempo dedicado por los profesores a la preparación de sus clases.

4. Factores psicológicos: Entre estos se cuentan algunos desórdenes en las funciones psicológicas básicas, como son la percepción, la memoria y la conceptualización, los cuales dificultan el aprendizaje.

FICHA SOCIOECONÓMICA, sirve para acreditar ciertas situaciones de cada estudiante considerando los diferentes aspectos como: aspecto personal, aspecto familiar, aspecto económico, aspecto vivienda, aspecto académico, aspecto conectividad, aspecto salud y aspecto emergencia, con la finalidad de que contenga la información necesaria para poder evaluar la realidad del caso que influye en el rendimiento académico de cada uno de los estudiantes.

Aspectos en la ficha socioeconómica:

1) Aspecto Personal, ficha que consigna datos personales del estudiante.

Los datos consignados son:

DNI, Fecha de nacimiento, Lugar de nacimiento, Sexo, Estado civil, Teléfono fijo, Teléfono móvil, Correo electrónico, Grupo sanguíneo, Lugar de residencia.

2) Aspecto Familiar, ficha que consigna los datos familiares del estudiante de pregrado.

Los datos consignados son:

Apellidos y nombres, Fecha de nacimiento, Estado civil, Grado de instrucción, Parentesco ocupación.

3) Aspecto Económico, ficha que consigna los datos económicos referente al responsable de la familia y del ingreso familiar del estudiante.

Los datos consignados son:

De quien dependes económicamente, Condición del trabajo del responsable de familia, Nombre del centro de trabajo, Ocupación del responsable, Trabaja usted, Condición del trabajo del estudiante, Centro del trabajo del estudiante, Ocupación del estudiante, Ingreso familiar.

4) Aspecto Vivienda, ficha que consigna los datos, condición y ubicación de la vivienda del estudiante.

Los datos consignados son:

¿Con quién vivirás durante tus estudios?, Ubicación de la vivienda, Zona de la vivienda, Nombre de la zona de la vivienda, Tipo de vivienda, Tenencia de la vivienda, Material con el que está fabricada la vivienda, Condición de la vivienda, Numero de divisiones, Servicios con que cuenta la vivienda, Bienes con que cuenta la vivienda.

5) Aspecto Académico, ficha que consigna los datos referentes al estado académico del estudiante.

Los datos consignados son:

Idioma que conoces, Colegio en que terminaste, Año en que terminaste estudios, Número de veces que postulaste, Porque decidiste estudiar en la UNS, Porque elegiste la carrera que estudias, Tipo de estudios realizados interrumpiste tus estudios universitarios, Porque razón interrumpiste tus estudios universitarios, Tiempo de interrupción de estudios, Recursos de apoyo, Técnica de estudio.

6) Aspecto Conectividad, ficha socioeconómica que consigna los datos referentes al equipo electrónico e internet.

Los datos consignados son:

Dispositivo en el cual te conectas con mayor frecuencia a internet, Tiempo al día que te conectas a internet, Horario del día en el que utilizas internet con más frecuencia, Desde que lugar te conectas con mayor frecuencia a internet.

7) Aspecto Salud, ficha que consigna los datos referentes de los hábitos alimenticios y estados de salud del estudiante.

Los datos consignados son:

¿Dónde almuerzas habitualmente?, Nombre de la enfermedad aguda que padece, Nombre de la discapacidad que padece, ¿Cuenta Ud. con algún tipo de seguro?, Nombre del seguro, Frecuencia de consumo de carne roja, pescado, fruta y verdura, Frecuencia de realización de ejercicio físico, Selecciona los deportes que practica, Selecciona actividades que desarrollas, ¿Qué religión profesa?

8) Aspecto Emergencia, ficha que consigna los datos para situaciones de emergencia del estudiante de pregrado.

Los datos consignados son:

Apellidos y nombres, Parentesco, Dirección, Teléfono fijo/ móvil, Especifique el tipo de problema que afronta.

2.1.3. Redes Neuronales

2.1.3.1. Principios Esenciales de Redes Neuronales

Emersión de Redes Neuronales

Las Redes Neuronales Artificiales (RNA) emergen como una carencia de emular con máquinas capaces de educarse y evocar, tal como la inteligencia humana. Es decir, imitar el funcionamiento del cerebro humano, ya que este adquiere un procesamiento altamente paralelo y con capacidad de solucionar problemas complejos.

Redes Neuronales Artificiales

Basogain Olabe (1998), mencionó:

Que por ahora se había alcanzado métodos capaces de sobrepasar al cerebro humano en cálculos que se consideraban muy difíciles para él, pero en cambio no se podían realizar tareas que el cerebro ejecuta de forma simple a todas horas, como por ejemplo reconocer a una persona o identificar si una persona se ha quebrado una pierna en base al resultado de una exploración o de una prueba.

Las propiedades más resaltantes del funcionamiento del cerebro como sistema computacional son las siguientes:

- a) Es robusto
- b) Es flexible, se adapta al entorno
- c) Puede tratar información ambigua o incompleta
- d) Es pequeño, compacto y consume poca potencia

Definiendo la red neuronal artificial como una implementación, en hardware o software, de un sistema de procesamiento de datos que intenta imitar las funciones computacionales principales de la red nerviosa del cerebro humano. Su particularidad fundamental es la implementación del nuevo paradigma computacional muy útil en problemas que no se adecuan bien a las estructuras convencionales de cálculo. Mediante esta técnica las redes neuronales separan información estructural de masas de datos complicados

o imprecisos, que sinteticen una descripción del fenómeno que ha generado estos datos. (p.13)

Viñuela & León (2004), explicaron:

Las RNA pretenden emular el esqueleto y funcionamiento del cerebro humano con el fin de solucionar problemas prácticos mediante la construcción de sistemas de procesamiento de la información paralelos (sobre diferentes sectores a la vez), distribuidos (de modo que si una zona se pierde no cae toda la red) y adaptativos (aprenden de la experiencia pudiendo generalizar conceptos a partir de casos particulares) que puedan representar un cierto comportamiento inteligente.

Elementos

Todas las redes neuronales artificiales tienen unos elementos en común que son los siguientes:

Neuronas y los elementos que la forman: valor, señal de salida, peso de la sinapsis (factor asignado a cada sinapsis), entrada total, función de salida, función de activación y reglas de aprendizaje (permiten modificar los pesos de la sinapsis).

Capa o nivel: conjunto de neuronas cuya capa tiene su origen en la misma fuente y cuyas salidas van al mismo destino.

Tipos de capas: entrada (reciben estímulos externos), ocultas (representación interna de la información) y salida.

Conexión entre neuronas: propagación hacia delante (ninguna salida de las neuronas es entrada del mismo nivel o niveles superiores) y propagación hacia detrás (la salida de las neuronas pueden ser entradas del mismo nivel o niveles anteriores y también de ellas mismas).

Dinámica: asincrónica (evalúan su estado continuamente, según les llega información), sincronía (cambios a la vez en todas las neuronas).

Tipos

Existen diversos tipos de redes neuronales, estos son:

Redes neuronales supervisadas: pueden emplearse como clasificadores de patrones, estimadores de funciones multivariadas o memorias asociativas.

Redes no supervisadas: en su entrenamiento no presentan las salidas objetivo que se desean asociar a cada patrón de entrada, será la red la que proporcione cierto resultado. La principal aplicación es la realización de agrupamiento de patrones (clustering), visualización de datos y representación de densidades de probabilidad, es, por tanto, la más utilizada en el campo de la documentación.

Redes neuronales realimentadas: son más complicadas que las dos anteriores. En este caso la información se propaga tanto hacia delante como hacia atrás, comportándose como un sistema dinámico, de difícil análisis y en el que deberá garantizarse la estabilidad de su respuesta.

Características

Sin embargo, todas ellas tienen unas características en común. Son las siguientes:

Clasificación: puede identificar datos y clasificarlos en clases. A diferencia de las técnicas tradicionales puede generar para un problema concreto estructuras específicas de identificación de características.

Asociación: la red funciona como un proceso de recuperación de un dato a partir de una entrada relacionada con el dato almacenado.

Agrupamiento: cuando no se produce una clasificación de los datos de entrada, es la red la que genera esta clasificación a medida que se va produciendo la señal.

Generalización: las redes pueden detectar las relaciones subyacentes entre diferentes elementos, y, por tanto, pueden extrapolar las relaciones numéricas presentes en los datos disponibles en situaciones similares.

Optimización: cuando es necesario elegir la opción óptima entre diferentes alternativas, las redes proporcionan un procedimiento relativamente rápido para generar una solución subóptima que es suficientemente satisfactoria.

Predicción y control: la flexibilidad de las redes neuronales las hace adecuadas para la predicción ya que el sistema va aprendiendo y puede seguir de manera versátil estos cambios.

Vemuri (1990), indicó que esto se logra gracias a las RNA:

Los principios de funcionamiento de las RNA a tener en cuenta son:

Aprendizaje adaptativo

Auto organización o generalización

Tolerancia a fallos

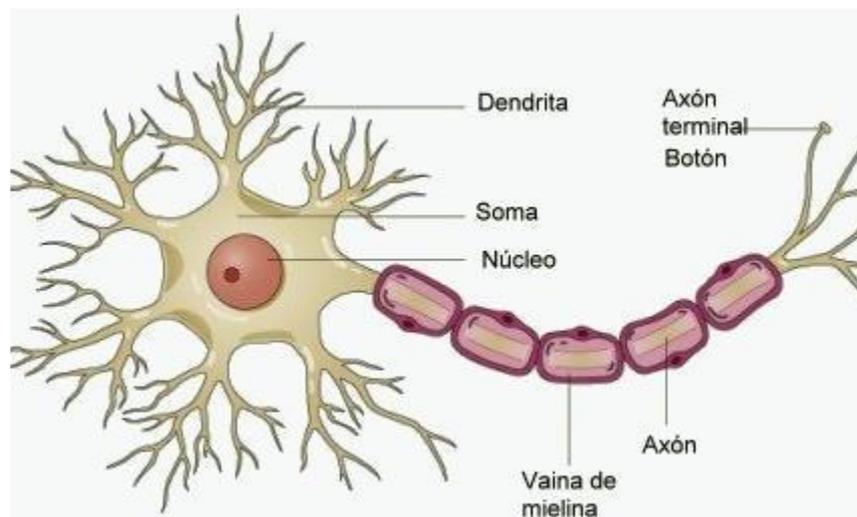
Operación en tiempo real

Fácil inserción en la tecnología existente

A continuación, en las figuras 1 y 2 se observan los prototipos de una neurona biológica y una neurona artificial.

Figura 1

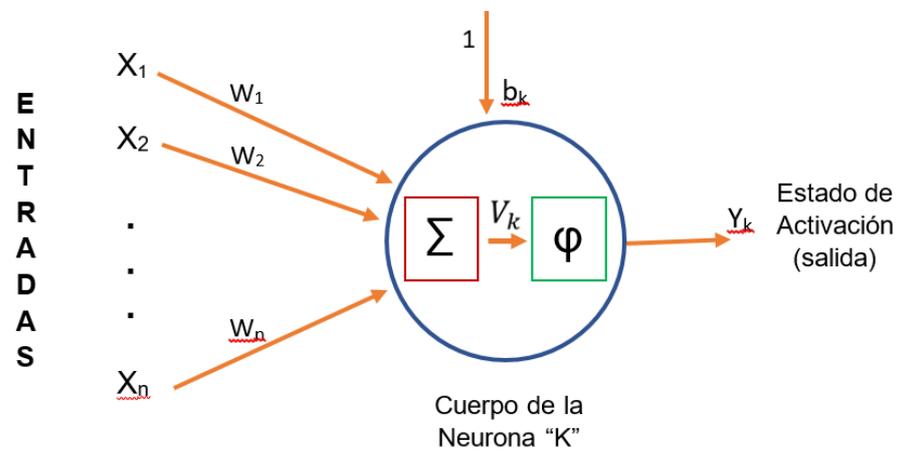
Modelo Simplificado de una Neurona Biológica



Fuente: Santiago Ramón y Cajal

Figura 2

Prototipo de una Neurona Artificial



Fuente: Propia

Cabe mencionar que el cuerpo de la neurona biológica es aquel en donde se encuentra el núcleo y por lo tanto es donde se realiza el procesamiento de la información recibida (impulsos eléctricos), inhibiendo o activando la neurona. En cuanto que la synapses vienen a ser los puntos de unión entre una neurona pre-sináptica y otra post-sináptica.

Donde $w_1, w_2, \dots, w_n, b_k, x_1, x_2, \dots, x_n$, e y_k , se representan como contenido de los vectores:

$$W = [w_1 \ w_2 \ \dots \ w_n] \ 1 \times n$$

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_n \end{bmatrix} \ n \times 1$$

$$B = [b_k] \ 1 \times 1$$

$$Y = [y_k] \ 1 \times 1$$

Definiéndose como:

$$V_k = \sum_{i=1}^n w_i * x_i + b_k$$

$$V_k = w_1 * x_1 + w_2 * x_2 + \dots + w_n * x_n + b_k$$

$$Y_k = \varphi (V_k)$$

y, en notación matricial, como:

$$V_k = W * X + B$$

$$Y = \varphi (V_k)$$

Dónde:

$\Phi (.)$: representa a la Función de Activación, sobre la variable “ V_k ”

K : hace referencia a la k -ésima neurona de la red neuronal.

Cuando se cuenta con redes neuronales de múltiples capas y múltiples neuronas por capas, los pesos sinápticos y las vías son representados a través de matrices.

Funciones de Activación

Existen diversos tipos de funciones de activación. Por ejemplo: Función de activación Escalón, Lineal, No Lineal (tangencial o sigmoideal), entre otros.

Función de Activación Escalón

Se caracteriza porque el vector de entrada a la función de activación es real, en cuanto que la salida está limitada a un vector con sólo dos valores. Si se desea que la salida tome los valores 0 o 1, entonces se hace uso de la función o comando "hardlim". Y, si se desea que la salida tome los valores -1 o 1, se utiliza la función "hardlims". En las figuras 3 y 4, se muestran los casos de ambas funciones de activación. Se utiliza en la red Perceptrón para decisiones de clasificación.

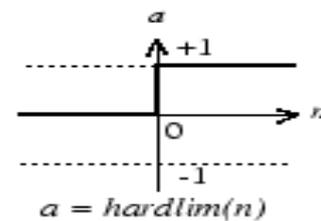
```
>> V = -8:0.2:8;
>> Y = hardlim( V );
>> subplot(1,2,1), plot( V , Y )
>> Y = hardlims( V );
>> subplot(1,2,2), plot( V , Y )
```

$$\text{hard lim}(n) = \begin{cases} 1, & n \geq 0 \\ 0, & n < 0 \end{cases}$$

$$\text{hard lim } s(n) = \begin{cases} 1, & n \geq 0 \\ -1, & n < 0 \end{cases}$$

Figura 3

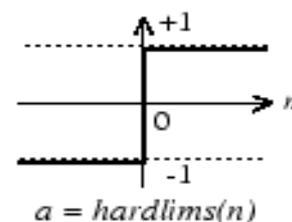
Función de Activación *hardlim*



Fuente: Propia

Figura 4

Función de Activación *hardlims*



Fuente: Propia

Función de Activación Lineal

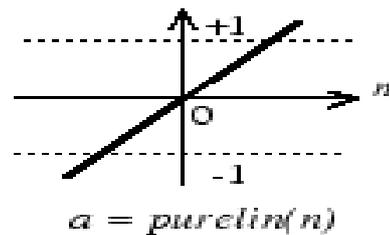
Se caracteriza por que la entrada y la salida de la función son de tipo real. El comando o función que realiza dicha operación se denomina “purelin”. Es utilizada por las redes lineales y en ocasiones en la última capa de una red Multicapa. En la figura 5 se muestra dicha función.

```
>> V = -8:0.2:8;
>> Y = purelin( V );
>> plot( V , Y )

purelin(n) = n
```

Figura 5

Función de Activación purelin



Función de Activación No Lineal

Se caracteriza porque la entrada a la función es real, en cuanto que la salida también lo es, pero limitado a un rango. Puede ser el tipo “sigmiod logarítmico” o “sigmoid tangente hiperbólico”. Ver figura 6. Esta función es utilizada por la red Multicapa con regla de aprendizaje Backpropagation.

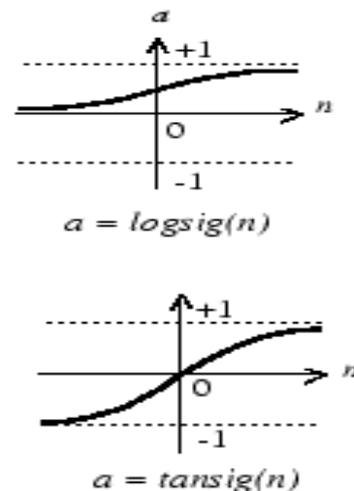
```
>> V = -8:0.2:8;
>> Y = logsig( V );
>> subplot(1,2,1), plot( V , Y )
>> Y = tansig( V );
>> subplot(1,2,2), plot( V , Y )
```

$$\log sig(n) = \frac{1}{1 + e^{-n}}$$

$$\tan sig(n) = \frac{2}{1 + e^{-2n}} - 1$$

Figura 6

Función de Activación logsig y tansig



Fuente: Propia

Función de Activación Competitiva

Se caracteriza porque la entrada a la función de activación es real, y la salida será igual a 1 sólo para el caso máximo, y será 0 para los demás casos. A continuación, la figura 7, muestra un ejemplo. Esta función es utilizada por las redes competitivas.

compet. Asigna el valor de 1 al mayor valor de entrada.

```
>> n=[2;1;4;3]
```

```
>> a=compet(n)
```

```
>> subplot(2,1,1)
```

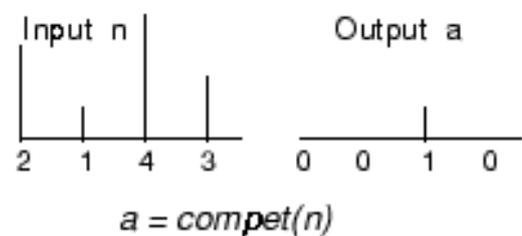
```
>> stem(n)
```

```
>> subplot(2,1,2)
```

```
>> stem(a)
```

Figura 7

Función de Activación compet



Fuente: Propia

Función de Activación de Saturación

Se caracteriza porque la entrada a la función de activación es del tipo real, y la salida es real y lineal pero limitada al intervalo de 0 a 1 o de -1 a 1. Es decir, se satura cualquier valor por encima o debajo de los límites. Es utilizada por la red Hopfield. Ver figura 8 y 9.

```
>> V = -8:0.2:8;
```

```
>> Y = satlin( V );
```

```
>> subplot(1,2,1), plot( V , Y )
```

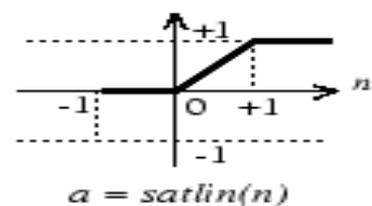
```
>> Y = satlins( V );
```

```
>> subplot(1,2,2), plot( V , Y )
```

$$\text{satlin}(n) = \begin{cases} 1, & n > 1 \\ n, & 0 \leq n \leq 1 \\ 0, & n < 0 \end{cases}$$

Figura 8

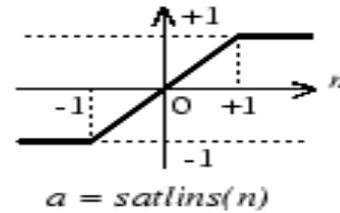
Función de Activación satlin



Fuente: Propia

Figura 9*Función de Activación satlins*

$$satlins(n) = \begin{cases} 1, & n > 1 \\ n, & -1 \leq n \leq 1 \\ -1, & n < -1 \end{cases}$$



Fuente: Propia

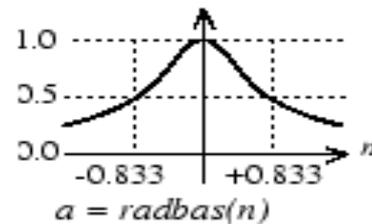
Función de Activación Radial Basis

Se caracteriza porque la entrada a la función de activación es real, y la salida está limitada a un intervalo de 0 a 1 formando una curva gaussiana. Ver la figura N°10. Es utilizada por la red Function Radial Basis.

Figura 10*Función de Activación Radial Basis*

```
>> V = -8:0.2:8;
>> Y = radbas( V );
>> plot( V , Y )
```

$$radbas(n) = e^{-n^2}$$



Fuente: Propia

Características Principales

Entre las principales características de toda red neuronal artificial, se tiene:

- Aprendizaje: porque aprende de la experiencia.
- Asociación: debido a que asocia padrones diferentes.
- Generalización: generaliza de ejemplos anteriores.
- Robustez: la pérdida de algunas neuronas, no deteriora el buen funcionamiento de la red neuronal.
- Búsqueda Paralela: basado en la búsqueda por contenido y no en forma paralela.

Arquitecturas más Comunes

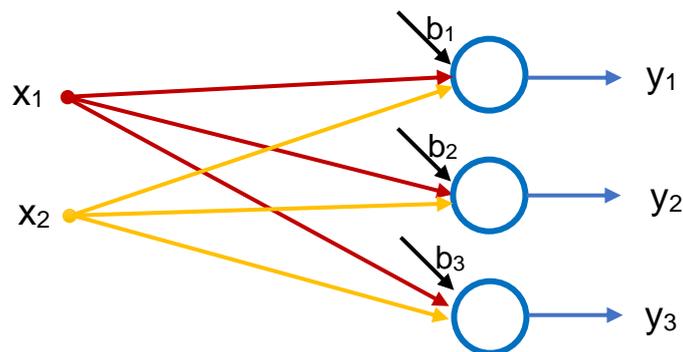
Seguidamente se muestran tres tipos principales de arquitecturas, de las cuales se derivan otras más. La elección del tipo de arquitectura a utilizar, se basa en el tipo de aplicación que se desea realizar.

❖ Una Capa Feed-Forward

Es una arquitectura conformada por una sola capa de neuronas, donde el flujo de datos viaja por la red de izquierda a derecha. Esto significa que se dirige desde el vector de entrada hacia la salida de toda la red. A continuación, en la figura 11, se muestra el caso particular de una red neuronal de una capa, con 3 neuronas y dos elementos por cada vector de entrada.

Figura 11

Red neuronal, con una Capa Feed-Forward



Fuente: Propia

De esta manera, en forma matricial se interpretaría como:

$$Y = \varphi (W * X + B)$$

$$X = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}_{2 \times 1}$$

$$W = \begin{bmatrix} W_{11} & W_{12} \\ W_{21} & W_{22} \\ W_{31} & W_{32} \end{bmatrix}_{3 \times 2}$$

$$B = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}_{3 \times 1}$$

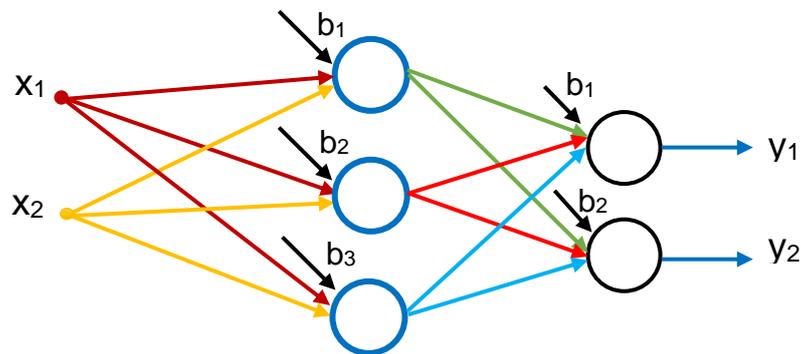
$$Y = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix}_{3 \times 1}$$

❖ Multi Capa Feed/Forward

Es una arquitectura conformada por múltiples capas de neuronas, donde el flujo de datos viaja de capa en capa desde la primera capa hacia la última capa de la red neuronal. A continuación, en la figura 12, se muestra el caso particular de una red neuronal con dos capas, de 3 y 2 neuronas, y dos elementos por cada vector de entrada.

Figura 12

Red neuronal Multi-Capa Feed-Forward



Fuente: Propia

En este caso, como existen dos capas de neuronas, se acostumbra a utilizar una notación matricial particular para referenciar a la matriz de pesos y de vías de la primera y segunda capa.

$$Y^{1C} = \varphi (W^{1C} * X + B^{1C})$$

$$Y^{2C} = \varphi (W^{2C} * Y^{1C} + B^{2C})$$

Dónde:

$$X = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}_{2 \times 1} \quad W^{1C} = \begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \\ w_{31} & w_{32} \end{bmatrix}_{3 \times 2}$$

$$B^{1C} = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}_{3 \times 1} \quad Y^{1C} = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix}_{3 \times 1}$$

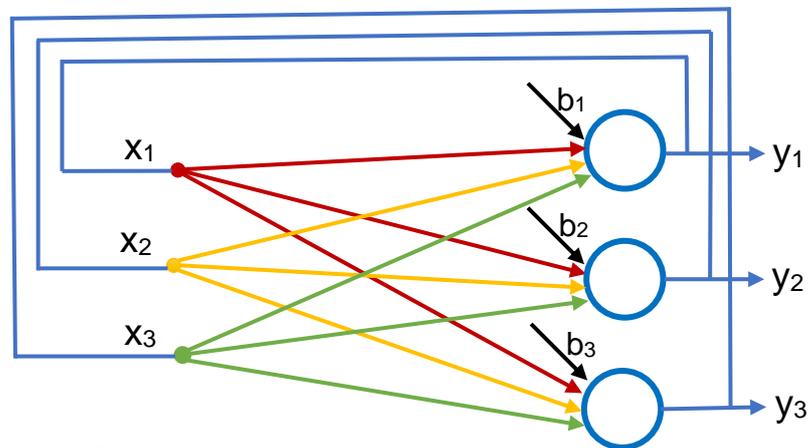
$$W^{2C} = \begin{bmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \end{bmatrix}_{2 \times 3}$$

$$B^{2C} = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix}_{2 \times 1} \qquad Y^{2C} = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}_{2 \times 1}$$

❖ Red Recurrente

Es una arquitectura conformada por una o varias capas de neuronas, donde existe una realimentación de la salida total hacia la entrada principal de la red neuronal. A continuación, en la figura 13, se muestra el caso particular de una red recurrente de una capa, tres neuronas y tres elementos por cada vector de entrada.

Figura 13
Red neuronal recurrente



Fuente: Propia

En forma matricial se tendría:

$$Y = \varphi (W * X + B)$$

$$X = Y$$

Donde "X = Y", indica que los nuevos cálculos se obtienen con el nuevo vector de entrada.

Aprendizaje en Redes Neuronales

El aprendizaje de una red neuronal se refiere al proceso de como los pesos y vías cambian o se utilizan debido a la experiencia. Así tenemos:

a. Sin Entrenamiento

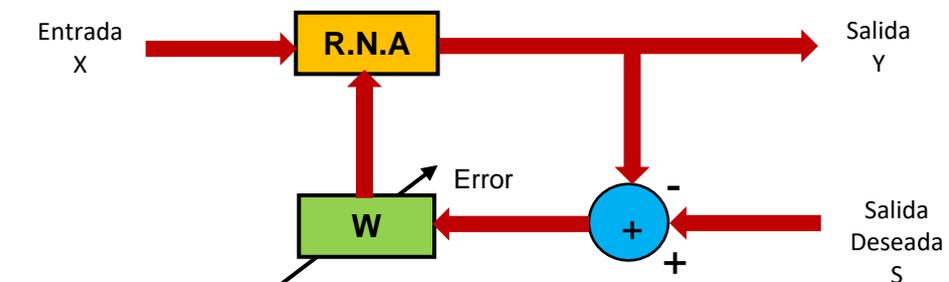
Es un caso donde los pesos de la red neuronal no se entrenan sino se calculan. Un ejemplo de ello lo podemos encontrar en la red neuronal recurrente Hopfield.

b. Entrenamiento Supervisado

Es cuando existe una comparación entre el vector de salida total y un vector de salida deseada. Un ejemplo de ello lo podemos encontrar en la red neuronal Perceptrón. Ver la figura 14.

Figura 14

Diagrama de Bloques de Entrenamiento Supervisado



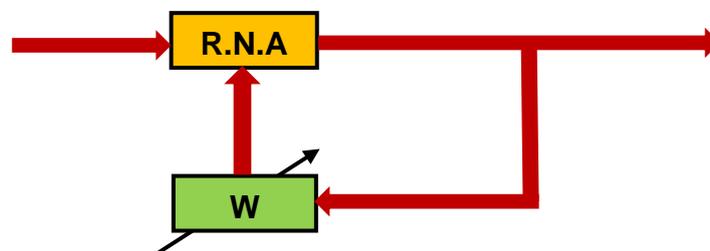
Fuente: Propia

c. Entrenamiento No Supervisado

Es cuando no se hace necesaria la presencia de un tutor para la supervisión. Un ejemplo de ello lo encontramos en las redes neuronales Competitivas. Ver la figura 15.

Figura 15

Diagrama de Bloques de Entrenamiento No Supervisado

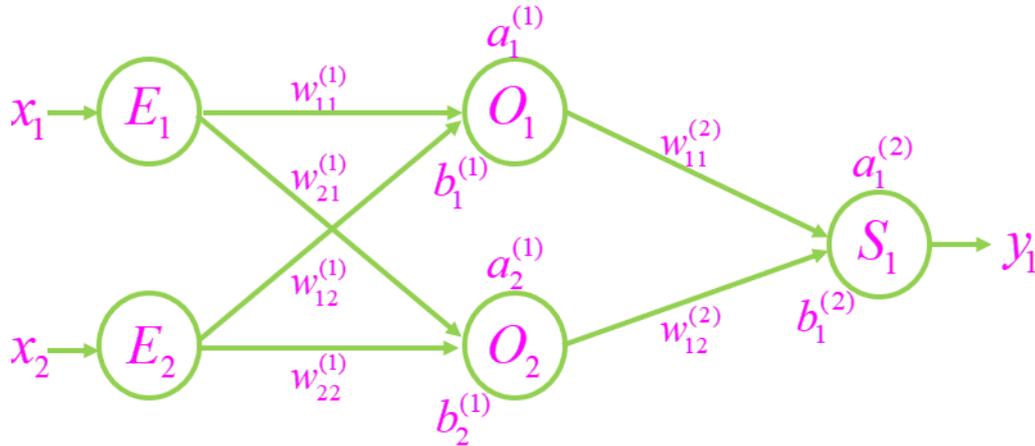


Fuente: Propia

Modelo de Perceptr3n Multicapa con una salida

Figura 16

Diagrama del Perceptr3n Multicapa con una salida



Fuente: Propia

$$X = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}_{2 \times 1} ; W_1 = \begin{bmatrix} w_{1,1}^{(1)} & w_{1,2}^{(1)} \\ w_{2,1}^{(1)} & w_{2,2}^{(1)} \end{bmatrix}_{2 \times 2} ; b_1 = \begin{bmatrix} b_1^{(1)} \\ b_2^{(1)} \end{bmatrix}_{2 \times 1} ; a_1 = \begin{bmatrix} a_1^{(1)} \\ a_2^{(1)} \end{bmatrix}_{2 \times 1}$$

$$W_2 = \begin{bmatrix} w_{1,1}^{(2)} & w_{1,2}^{(2)} \end{bmatrix}_{1 \times 2} ; b_2 = \begin{bmatrix} b_1^{(2)} \end{bmatrix}_{1 \times 1} ; a_2 = \begin{bmatrix} a_1^{(2)} \end{bmatrix}_{1 \times 1}$$

Propagaci3n hacia adelante :

$$v_1 = \begin{bmatrix} v_1^{(1)} \\ v_2^{(1)} \end{bmatrix} = W_1 * X + b_1 ; a_1 = \varphi(v_1) \text{ salida}$$

$$v_2 = \begin{bmatrix} v_1^{(2)} \end{bmatrix} = W_2 * a_1 + b_2 ; a_2 = \varphi(v_2) \text{ salida}$$

Funci3n de activaci3n

$$\varphi(x) = \frac{1}{1 + e^{(-x)}} ; \varphi'(x) = \varphi(x)(1 - \varphi(x))$$

$$a_1^{(1)} = \varphi(w_{11}^{(1)} x_1 + w_{12}^{(1)} x_2 + b_1^{(1)}) ; a_2^{(1)} = \varphi(w_{21}^{(1)} x_1 + w_{22}^{(1)} x_2 + b_2^{(1)})$$

$$a_1^{(2)} = \varphi(w_{11}^{(2)} \cdot a_1^{(1)} + w_{12}^{(2)} \cdot a_2^{(1)} + b_1^{(2)})$$

$$y_1 = a_1^{(2)} = \varphi(w_{11}^{(2)} \cdot \varphi(w_{11}^{(1)} x_1 + w_{12}^{(1)} x_2 + b_1^{(1)}) + w_{12}^{(2)} \cdot \varphi(w_{21}^{(1)} x_1 + w_{22}^{(1)} x_2 + b_2^{(1)}) + b_1^{(2)})$$

Derivadas Parciales de la salida respecto a los pesos y bías

$$\frac{\partial y_1}{\partial w_{11}^{(1)}} = \frac{\partial \varphi(v_1^{(2)})}{\partial v_1^{(2)}} \cdot \frac{\partial v_1^{(2)}}{\partial a_1^{(1)}} \cdot \frac{\partial a_1^{(1)}}{\partial v_1^{(1)}} \cdot \frac{\partial v_1^{(1)}}{\partial w_{11}^{(1)}} ; \quad \frac{\partial y_1}{\partial w_{12}^{(1)}} = \frac{\partial \varphi(v_1^{(2)})}{\partial v_1^{(2)}} \cdot \frac{\partial v_1^{(2)}}{\partial a_1^{(1)}} \cdot \frac{\partial a_1^{(1)}}{\partial v_1^{(1)}} \cdot \frac{\partial v_1^{(1)}}{\partial w_{12}^{(1)}}$$

$$\frac{\partial y_1}{\partial w_{21}^{(1)}} = \frac{\partial \varphi(v_1^{(2)})}{\partial v_1^{(2)}} \cdot \frac{\partial v_1^{(2)}}{\partial a_2^{(1)}} \cdot \frac{\partial a_2^{(1)}}{\partial v_2^{(1)}} \cdot \frac{\partial v_2^{(1)}}{\partial w_{21}^{(1)}} ; \quad \frac{\partial y_1}{\partial w_{22}^{(1)}} = \frac{\partial \varphi(v_1^{(2)})}{\partial v_1^{(2)}} \cdot \frac{\partial v_1^{(2)}}{\partial a_2^{(1)}} \cdot \frac{\partial a_2^{(1)}}{\partial v_2^{(1)}} \cdot \frac{\partial v_2^{(1)}}{\partial w_{22}^{(1)}}$$

$$\frac{\partial y_1}{\partial b_1^{(1)}} = \frac{\partial \varphi(v_1^{(2)})}{\partial v_1^{(2)}} \cdot \frac{\partial v_1^{(2)}}{\partial a_1^{(1)}} \cdot \frac{\partial a_1^{(1)}}{\partial v_1^{(1)}} \cdot (1) \quad ; \quad \frac{\partial y_1}{\partial b_2^{(1)}} = \frac{\partial \varphi(v_1^{(2)})}{\partial v_1^{(2)}} \cdot \frac{\partial v_1^{(2)}}{\partial a_2^{(1)}} \cdot \frac{\partial a_2^{(1)}}{\partial v_2^{(1)}} \cdot (1)$$

$$\frac{\partial y_1}{\partial w_{11}^{(2)}} = \frac{\partial \varphi(v_1^{(2)})}{\partial v_1^{(2)}} \cdot \frac{\partial v_1^{(2)}}{\partial w_{11}^{(2)}} ; \quad \frac{\partial y_1}{\partial w_{12}^{(2)}} = \frac{\partial \varphi(v_1^{(2)})}{\partial v_1^{(2)}} \cdot \frac{\partial v_1^{(2)}}{\partial w_{12}^{(2)}} ; \quad \frac{\partial y_1}{\partial b_1^{(2)}} = \frac{\partial \varphi(v_1^{(2)})}{\partial v_1^{(2)}} \cdot (1)$$

Reemplazando las Derivadas Parciales con la función de Transferencia

$$\frac{\partial y_1}{\partial w_{11}^{(1)}} = y_1(1-y_1)w_{11}^{(2)}a_1^{(1)}(1-a_1^{(1)})x_1 ; \quad \frac{\partial y_1}{\partial w_{12}^{(1)}} = y_1(1-y_1)w_{11}^{(2)}a_1^{(1)}(1-a_1^{(1)})x_2$$

$$\frac{\partial y_1}{\partial w_{21}^{(1)}} = y_1(1-y_1)w_{12}^{(2)}a_2^{(1)}(1-a_2^{(1)})x_1 ; \quad \frac{\partial y_1}{\partial w_{22}^{(1)}} = y_1(1-y_1)w_{12}^{(2)}a_2^{(1)}(1-a_2^{(1)})x_2$$

$$\frac{\partial y_1}{\partial b_1^{(1)}} = y_1(1-y_1)w_{11}^{(2)}a_1^{(1)}(1-a_1^{(1)}) \quad ; \quad \frac{\partial y_1}{\partial b_2^{(1)}} = y_1(1-y_1)w_{12}^{(2)}a_2^{(1)}(1-a_2^{(1)})$$

$$\frac{\partial y_1}{\partial w_{11}^{(2)}} = y_1(1-y_1) \cdot a_1^{(1)} \quad ; \quad \frac{\partial y_1}{\partial w_{12}^{(2)}} = y_1(1-y_1) \cdot a_2^{(1)} \quad ; \quad \frac{\partial y_1}{\partial b_1^{(2)}} = y_1(1-y_1)$$

Representación matricial de las Derivadas Parciales

$$\frac{\partial y_1}{\partial W_1} = \begin{bmatrix} \frac{\partial y_1}{\partial w_{11}^{(1)}} & \frac{\partial y_1}{\partial w_{12}^{(1)}} \\ \frac{\partial y_1}{\partial w_{21}^{(1)}} & \frac{\partial y_1}{\partial w_{22}^{(1)}} \end{bmatrix}_{2 \times 2}$$

$$\frac{\partial y_1}{\partial W_1} = \begin{bmatrix} y_1(1-y_1) \cdot w_{11}^{(2)} \cdot a_1^{(1)}(1-a_1^{(1)}) \cdot x_1 & y_1(1-y_1) \cdot w_{11}^{(2)} \cdot a_1^{(1)}(1-a_1^{(1)}) \cdot x_2 \\ y_1(1-y_1) \cdot w_{12}^{(2)} \cdot a_2^{(1)}(1-a_2^{(1)}) \cdot x_1 & y_1(1-y_1) \cdot w_{12}^{(2)} \cdot a_2^{(1)}(1-a_2^{(1)}) \cdot x_2 \end{bmatrix}_{2 \times 2}$$

$$\frac{\partial y_1}{\partial W_1} = y_1(1-y_1) \cdot \begin{bmatrix} w_{11}^{(2)} \\ w_{12}^{(2)} \end{bmatrix} \cdot \begin{bmatrix} a_1^{(1)}(1-a_1^{(1)}) \\ a_2^{(1)}(1-a_2^{(1)}) \end{bmatrix} * [x_1 \ x_2]_{1 \times 2}$$

$$\frac{\partial y_1}{\partial W_1} = (y_1(1-y_1) \cdot W_2^T \cdot a_1(1-a_1)) * x^T \quad \dots\dots\dots (1)$$

$$\frac{\partial y_1}{\partial b_1} = \begin{bmatrix} \frac{\partial y_1}{\partial b_1^{(1)}} \\ \frac{\partial y_1}{\partial b_2^{(1)}} \end{bmatrix} = \begin{bmatrix} y_1(1-y_1) \cdot w_{11}^{(2)} \cdot a_1^{(1)}(1-a_1^{(1)}) \\ y_1(1-y_1) \cdot w_{12}^{(2)} \cdot a_2^{(1)}(1-a_2^{(1)}) \end{bmatrix}_{2 \times 1}$$

$$\frac{\partial y_1}{\partial b_1} = y_1(1-y_1) \begin{bmatrix} w_{11}^{(2)} \\ w_{12}^{(2)} \end{bmatrix}_{2 \times 1} \cdot \begin{bmatrix} a_1^{(1)}(1-a_1^{(1)}) \\ a_2^{(1)}(1-a_2^{(1)}) \end{bmatrix}_{2 \times 1}$$

$$\frac{\partial y_1}{\partial b_1} = y_1(1-y_1) \cdot W_2^T \cdot a_1(1-a_1) \quad \dots\dots\dots (2)$$

$$\frac{\partial y_1}{\partial W_2} = \begin{bmatrix} \frac{\partial y_1}{\partial w_{11}^{(2)}} & \frac{\partial y_1}{\partial w_{12}^{(2)}} \end{bmatrix} = \begin{bmatrix} y_1(1-y_1) \cdot a_1^{(1)} & y_1(1-y_1) \cdot a_2^{(1)} \end{bmatrix} = y_1(1-y_1) \begin{bmatrix} a_1^{(1)} & a_2^{(1)} \end{bmatrix}$$

$$\frac{\partial y_1}{\partial W_2} = y_1(1-y_1) * a_1^T \quad \dots\dots\dots (3)$$

$$\frac{\partial y_1}{\partial b_2} = \begin{bmatrix} \frac{\partial y_1}{\partial b_1^{(2)}} \end{bmatrix} = [y_1(1-y_1)] \quad \dots\dots\dots (4)$$

Gradiente de la función error respecto a los pesos y bias

$E = \frac{1}{2}(s_1 - y_1)^2$ *función error* ; $e_1 = s_1 - y_1$ *error relativo*

$$\frac{\partial(E)}{\partial W_1} = \begin{bmatrix} \frac{\partial(E)}{\partial w_{11}^{(1)}} & \frac{\partial(E)}{\partial w_{12}^{(1)}} \\ \frac{\partial(E)}{\partial w_{21}^{(1)}} & \frac{\partial(E)}{\partial w_{22}^{(1)}} \end{bmatrix} = \begin{bmatrix} -(s_1 - y_1) \frac{\partial y}{\partial w_{11}^{(1)}} & -(s_1 - y_1) \frac{\partial y}{\partial w_{12}^{(1)}} \\ -(s_1 - y_1) \frac{\partial y}{\partial w_{21}^{(1)}} & -(s_1 - y_1) \frac{\partial y}{\partial w_{22}^{(1)}} \end{bmatrix}$$

$$\frac{\partial(E)}{\partial W_1} = -(s_1 - y_1) \cdot \begin{bmatrix} \frac{\partial y_1}{\partial w_{11}^{(1)}} & \frac{\partial y_1}{\partial w_{12}^{(1)}} \\ \frac{\partial y_1}{\partial w_{21}^{(1)}} & \frac{\partial y_1}{\partial w_{22}^{(1)}} \end{bmatrix} = -e_1 \cdot \frac{\partial y_1}{\partial W_1} \quad \dots\dots\dots (5)$$

$$\frac{\partial(E)}{\partial b_1} = \begin{bmatrix} \frac{\partial(E)}{\partial b_1^{(1)}} \\ \frac{\partial(E)}{\partial b_2^{(1)}} \end{bmatrix} = \begin{bmatrix} -(s_1 - y_1) \cdot \frac{\partial y_1}{\partial b_1^{(1)}} \\ -(s_1 - y_1) \cdot \frac{\partial y_1}{\partial b_2^{(1)}} \end{bmatrix} = -e_1 \cdot \frac{\partial y_1}{\partial b_1} \quad \dots\dots\dots (6)$$

$$\frac{\partial E}{\partial W_2} = \begin{bmatrix} \frac{\partial E}{\partial w_{11}^{(2)}} & \frac{\partial E}{\partial w_{12}^{(2)}} \end{bmatrix} = \begin{bmatrix} -(s_1 - y_1) \frac{\partial y_1}{\partial w_{11}^{(2)}} & -(s_1 - y_1) \frac{\partial y_1}{\partial w_{12}^{(2)}} \end{bmatrix}$$

$$\frac{\partial E}{\partial W_2} = -(s_1 - y_1) \begin{bmatrix} \frac{\partial y_1}{\partial w_{11}^{(2)}} & \frac{\partial y_1}{\partial w_{12}^{(2)}} \end{bmatrix} = -(s_1 - y_1) \cdot \frac{\partial y_1}{\partial W_2}$$

$$\frac{\partial E}{\partial W_2} = -e_1 \cdot y_1 (1 - y_1) * a_1^T \quad \dots\dots\dots (7)$$

$$\frac{\partial(E)}{\partial b_2} = \begin{bmatrix} \frac{\partial(E)}{\partial b_1^{(2)}} \end{bmatrix} = \begin{bmatrix} -(s_1 - y_1) \cdot \frac{\partial y_1}{\partial b_1^{(2)}} \end{bmatrix} = -(s_1 - y_1) \cdot \frac{\partial y_1}{\partial b_1^{(2)}}$$

$$\frac{\partial(E)}{\partial b_2} = -e_1 \cdot [y_1 (1 - y_1)] \quad \dots\dots\dots (8)$$

Propagación hacia atrás en los pesos y bias

$$W_1 = W_1 + \alpha \cdot e_1 \cdot \frac{\partial y_1}{\partial W_1} \quad ; \quad \alpha : \text{tasa de aprendizaje}$$

$$W_1 = W_1 + \alpha \cdot e_1 \cdot (y_1 (1 - y_1) \cdot W_2^T \cdot a_1 (1 - a_1)) * x^T$$

$$b_1 = b_1 + \alpha \cdot e_1 \cdot \frac{\partial y_1}{\partial b_1}$$

$$b_1 = b_1 + \alpha \cdot e_1 \cdot y_1 (1 - y_1) \cdot W_2^T \cdot a_1 (1 - a_1)$$

$$W_2 = W_2 + \alpha \cdot e_1 \cdot \frac{\partial y_1}{\partial W_2}$$

$$W_2 = W_2 + \alpha \cdot e_1 \cdot y_1 (1 - y_1) * a_1^T$$

$$b_2 = b_2 + \alpha \cdot e_1 \cdot \frac{\partial y_1}{\partial b_2}$$

$$b_2 = b_2 + \alpha \cdot e_1 \cdot y_1(1 - y_1)$$

Ejemplo:

Consideremos $W = [0 \ 0]$, $B = [0]$

Primera Iteración

$$X = \begin{bmatrix} 0.4 \\ 0.5 \end{bmatrix} , \quad V = (0)(0.4) + (0)(0.5) + 0 = 0 , \quad \varphi(V) = 1 , \quad e = 0 - 1 = -1$$

$$\text{reestructuramos } W = [0 \ 0] + (-1)[0.4 \ 0.5] = [-0.4 \ -0.5] , \quad B = [0] + [-1] = [-1]$$

$$X = \begin{bmatrix} 0.4 \\ 1.0 \end{bmatrix} , \quad V = (-0.4)(0.4) + (-0.5)(1) + (-1) = -1.66 , \quad \varphi(V) = 0$$

$$X = \begin{bmatrix} 0.9 \\ 0.5 \end{bmatrix} , \quad V = (-0.4)(0.9) + (-0.5)(0.5) + (-1) = -1.61 , \quad \varphi(V) = 0 , \quad e = 1 - 0 = 1$$

$$\text{reestructuramos } W = [-0.4 \ -0.5] + (1)[0.9 \ 0.5] = [0.5 \ 0] , \quad B = [-1] + [1] = [0]$$

$$X = \begin{bmatrix} 0.9 \\ 0.66 \end{bmatrix} , \quad V = (0.5)(0.9) + (0)(0.66) + (0) = 0.45 , \quad \varphi(V) = 1$$

Segunda Iteración

$$X = \begin{bmatrix} 0.4 \\ 0.5 \end{bmatrix} , \quad V = (0.5)(0.4) + (0)(0.5) + 0 = 0.2 , \quad \varphi(V) = 1 , \quad e = 0 - 1 = -1$$

$$\text{reestructuramos } W = [0.5 \ 0] + (-1)[0.4 \ 0.5] = [0.1 \ -0.5] , \quad B = [0] + [-1] = [-1]$$

$$X = \begin{bmatrix} 0.4 \\ 1.0 \end{bmatrix} , \quad V = (0.1)(0.4) + (-0.5)(1) + (-1) = -1.46 , \quad \varphi(V) = 0$$

$$X = \begin{bmatrix} 0.9 \\ 0.5 \end{bmatrix}, \quad V = (0.1)(0.9) + (-0.5)(0.5) + (-1) = -0.35, \quad \varphi(V) = 0, \quad e = 1 - 0 = 1$$

$$\text{reestructuramos } W = [0.1 \ -0.5] + (1)[0.9 \ 0.5] = [1 \ 0], \quad B = [-1] + [1] = [0]$$

$$X = \begin{bmatrix} 0.9 \\ 0.66 \end{bmatrix}, \quad V = (1)(0.9) + (0)(0.66) + (0) = 0.9, \quad \varphi(V) = 1$$

Tercera Iteración

$$X = \begin{bmatrix} 0.4 \\ 0.5 \end{bmatrix}, \quad V = (1)(0.4) + (0)(0.5) + 0 = 0.4, \quad \varphi(V) = 1, \quad e = 0 - 1 = -1$$

$$\text{reestructuramos } W = [1 \ 0] + (-1)[0.4 \ 0.5] = [0.6 \ -0.5], \quad B = [0] + [-1] = [-1]$$

$$X = \begin{bmatrix} 0.4 \\ 1.0 \end{bmatrix}, \quad V = (0.6)(0.4) + (-0.5)(1) + (-1) = -1.26, \quad \varphi(V) = 0$$

$$X = \begin{bmatrix} 0.9 \\ 0.5 \end{bmatrix}, \quad V = (0.6)(0.9) + (-0.5)(0.5) + (-1) = -0.71, \quad \varphi(V) = 0, \quad e = 1 - 0 = 1$$

$$\text{reestructuramos } W = [0.6 \ -0.5] + (1)[0.9 \ 0.5] = [1.5 \ 0], \quad B = [-1] + [1] = [0]$$

$$X = \begin{bmatrix} 0.9 \\ 0.66 \end{bmatrix}, \quad V = (1.5)(0.9) + (0)(0.66) + (0) = 1.35, \quad \varphi(V) = 1$$

Cuarta Iteración

$$X = \begin{bmatrix} 0.4 \\ 0.5 \end{bmatrix}, \quad V = (1.5)(0.4) + (0)(0.5) + 0 = 0.6, \quad \varphi(V) = 1, \quad e = 0 - 1 = -1$$

$$\text{reestructuramos } W = [1.5 \ 0] + (-1)[0.4 \ 0.5] = [1.1 \ -0.5], \quad B = [0] + [-1] = [-1]$$

$$X = \begin{bmatrix} 0.4 \\ 1.0 \end{bmatrix}, \quad V = (1.1)(0.4) + (-0.5)(1) + (-1) = -1.06, \quad \varphi(V) = 0$$

$$X = \begin{bmatrix} 0.9 \\ 0.5 \end{bmatrix}, \quad V = (1.1)(0.9) + (-0.5)(0.5) + (-1) = -0.26, \quad \varphi(V) = 0, \quad e = 1 - 0 = 1$$

$$\text{reestructuramos } W = [1.1 \ -0.5] + (1)[0.9 \ 0.5] = [2 \ 0], \quad B = [-1] + [1] = [0]$$

$$X = \begin{bmatrix} 0.9 \\ 0.66 \end{bmatrix}, \quad V = (2)(0.9) + (0)(0.66) + (0) = 1.8, \quad \varphi(V) = 1$$

Quinta Iteración

$$X = \begin{bmatrix} 0.4 \\ 0.5 \end{bmatrix}, \quad V = (2)(0.4) + (0)(0.5) + 0 = 0.8, \quad \varphi(V) = 1, \quad e = 0 - 1 = -1$$

reestructuramos $W = [2 \ 0] + (-1)[0.4 \ 0.5] = [1.6 \ -0.5], B = [0] + [-1] = [-1]$

$$X = \begin{bmatrix} 0.4 \\ 1.0 \end{bmatrix}, \quad V = (1.6)(0.4) + (-0.5)(1) + (-1) = -0.86, \quad \varphi(V) = 0$$

$$X = \begin{bmatrix} 0.9 \\ 0.5 \end{bmatrix}, \quad V = (1.6)(0.9) + (-0.5)(0.5) + (-1) = 0.19, \quad \varphi(V) = 1$$

$$X = \begin{bmatrix} 0.9 \\ 0.66 \end{bmatrix}, \quad V = (1.6)(0.9) + (-0.5)(0.66) + (-1) = 0.11, \quad \varphi(V) = 1$$

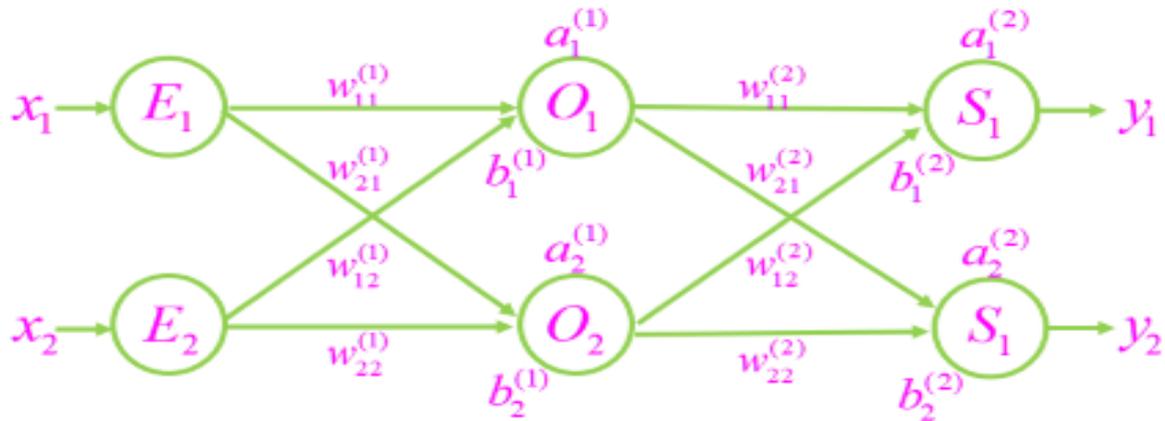
Finalmente se obtienen los pesos y la bía que nos permitirán realizar la evaluación de los 10 alumnos que llevan el curso de Matemática.

$$W = [1.6 \ -0.5], \quad B = [-1]$$

Modelo Perceptr3n Multicapa con dos salidas

Figura 17

Diagrama del Perceptr3n Multicapa con una salida



Fuente: Propia

$$X = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}_{2 \times 1} ; W_1 = \begin{bmatrix} w_{1,1}^{(1)} & w_{1,2}^{(1)} \\ w_{2,1}^{(1)} & w_{2,2}^{(1)} \end{bmatrix}_{2 \times 2} ; b_1 = \begin{bmatrix} b_1^{(1)} \\ b_2^{(1)} \end{bmatrix}_{2 \times 1} ; a_1 = \begin{bmatrix} a_1^{(1)} \\ a_2^{(1)} \end{bmatrix}_{2 \times 1}$$

$$W_2 = \begin{bmatrix} w_{1,1}^{(2)} & w_{1,2}^{(2)} \\ w_{2,1}^{(2)} & w_{2,2}^{(2)} \end{bmatrix}_{2 \times 2} ; b_2 = \begin{bmatrix} b_1^{(2)} \\ b_2^{(2)} \end{bmatrix}_{2 \times 1} ; a_2 = \begin{bmatrix} a_1^{(2)} \\ a_2^{(2)} \end{bmatrix}_{2 \times 1} ; y = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}_{2 \times 1}$$

Propagaci3n hacia adelante:

$$v_1 = W_1 * X + b_1 ; a_1 = \varphi(v_1) \text{ salida}$$

$$v_2 = W_2 * a_1 + b_2 ; a_2 = \varphi(v_2) \text{ salida}$$

Funci3n de activaci3n

$$\varphi(x) = \frac{1}{1 + e^{-x}} ; \varphi'(x) = \varphi(x)(1 - \varphi(x))$$

$$a_1^{(1)} = \varphi(w_{11}^{(1)}x_1 + w_{12}^{(1)}x_2 + b_1^{(1)}) ; a_2^{(1)} = \varphi(w_{21}^{(1)}x_1 + w_{22}^{(1)}x_2 + b_2^{(1)})$$

$$a_1^{(2)} = \varphi(w_{11}^{(2)} \cdot a_1^{(1)} + w_{12}^{(2)} \cdot a_2^{(1)} + b_1^{(2)})$$

$$a_2^{(2)} = \varphi(w_{21}^{(2)} \cdot a_1^{(1)} + w_{22}^{(2)} \cdot a_2^{(1)} + b_2^{(2)})$$

$$y_1 = a_1^{(2)} = \varphi(w_{11}^{(2)} \cdot \varphi(w_{11}^{(1)}x_1 + w_{12}^{(1)}x_2 + b_1^{(1)}) + w_{12}^{(2)} \cdot \varphi(w_{21}^{(1)}x_1 + w_{22}^{(1)}x_2 + b_2^{(1)}) + b_1^{(2)})$$

$$y_2 = a_2^{(2)} = \varphi(w_{21}^{(2)} \cdot \varphi(w_{11}^{(1)} x_1 + w_{12}^{(1)} x_2 + b_1^{(1)}) + w_{22}^{(2)} \cdot \varphi(w_{21}^{(1)} x_1 + w_{22}^{(1)} x_2 + b_2^{(1)}) + b_2^{(2)})$$

Derivadas Parciales de las salidas respecto a los pesos y bías

$$\frac{\partial y_1}{\partial w_{11}^{(1)}} = y_1(1-y_1)w_{11}^{(2)}a_1^{(1)}(1-a_1^{(1)})x_1 ; \quad \frac{\partial y_1}{\partial w_{12}^{(1)}} = y_1(1-y_1)w_{11}^{(2)}a_1^{(1)}(1-a_1^{(1)})x_2$$

$$\frac{\partial y_1}{\partial w_{21}^{(1)}} = y_1(1-y_1)w_{12}^{(2)}a_2^{(1)}(1-a_2^{(1)})x_1 ; \quad \frac{\partial y_1}{\partial w_{22}^{(1)}} = y_1(1-y_1)w_{12}^{(2)}a_2^{(1)}(1-a_2^{(1)})x_2$$

$$\frac{\partial y_1}{\partial b_1^{(1)}} = y_1(1-y_1)w_{11}^{(2)}a_1^{(1)}(1-a_1^{(1)}) ; \quad \frac{\partial y_1}{\partial b_2^{(1)}} = y_1(1-y_1)w_{12}^{(2)}a_2^{(1)}(1-a_2^{(1)})$$

$$\frac{\partial y_1}{\partial w_{11}^{(2)}} = y_1(1-y_1)a_1^{(1)} ; \quad \frac{\partial y_1}{\partial w_{12}^{(2)}} = y_1(1-y_1)a_2^{(1)} ; \quad \frac{\partial y_1}{\partial b_1^{(2)}} = y_1(1-y_1)$$

$$\frac{\partial y_2}{\partial w_{11}^{(1)}} = y_2(1-y_2)w_{21}^{(2)}a_1^{(1)}(1-a_1^{(1)})x_1$$

$$\frac{\partial y_2}{\partial w_{12}^{(1)}} = y_2(1-y_2)w_{21}^{(2)}a_1^{(1)}(1-a_1^{(1)})x_2$$

$$\frac{\partial y_2}{\partial w_{21}^{(1)}} = y_2(1-y_2)w_{22}^{(2)}a_2^{(1)}(1-a_2^{(1)})x_1$$

$$\frac{\partial y_2}{\partial w_{22}^{(1)}} = y_2(1-y_2)w_{22}^{(2)}a_2^{(1)}(1-a_2^{(1)})x_2$$

$$\frac{\partial y_2}{\partial b_1^{(1)}} = y_2(1-y_2)w_{21}^{(2)}a_1^{(1)}(1-a_1^{(1)}) , \quad \frac{\partial y_2}{\partial b_2^{(1)}} = y_2(1-y_2)w_{22}^{(2)}a_2^{(1)}(1-a_2^{(1)})$$

$$\frac{\partial y_2}{\partial w_{21}^{(2)}} = y_2(1-y_2)a_1^{(1)} , \quad \frac{\partial y_2}{\partial w_{22}^{(2)}} = y_2(1-y_2)a_2^{(1)} , \quad \frac{\partial y_2}{\partial b_2^{(2)}} = y_2(1-y_2)$$

Representación matricial de las Derivadas Parciales

$$\frac{\partial y_1}{\partial W_1} = \begin{bmatrix} \frac{\partial y_1}{\partial w_{11}^{(1)}} & \frac{\partial y_1}{\partial w_{12}^{(1)}} \\ \frac{\partial y_1}{\partial w_{21}^{(1)}} & \frac{\partial y_1}{\partial w_{22}^{(1)}} \end{bmatrix}_{2 \times 2}$$

$$\frac{\partial y_1}{\partial W_1} = \begin{bmatrix} y_1(1-y_1).w_{11}^{(2)}.a_1^{(1)}(1-a_1^{(1)})x_1 & y_1(1-y_1).w_{11}^{(2)}.a_1^{(1)}(1-a_1^{(1)})x_2 \\ y_1(1-y_1).w_{12}^{(2)}.a_2^{(1)}(1-a_2^{(1)})x_1 & y_1(1-y_1).w_{12}^{(2)}.a_2^{(1)}(1-a_2^{(1)})x_2 \end{bmatrix}_{2 \times 2}$$

$$\frac{\partial y_1}{\partial W_1} = y_1(1-y_1) \cdot \begin{bmatrix} w_{11}^{(2)} \\ w_{12}^{(2)} \end{bmatrix} \cdot \begin{bmatrix} a_1^{(1)}(1-a_1^{(1)}) \\ a_2^{(1)}(1-a_2^{(1)}) \end{bmatrix}_{2 \times 1} * [x_1 \ x_2]_{1 \times 2}$$

$$\frac{\partial y_1}{\partial W_1} = (y_1(1-y_1)) \cdot \begin{bmatrix} w_{11}^{(2)} \\ w_{12}^{(2)} \end{bmatrix} \cdot a_1(1-a_1) * x^T \quad \dots\dots\dots (1)$$

$$\frac{\partial y_1}{\partial b_1} = \begin{bmatrix} \frac{\partial y_1}{\partial b_1^{(1)}} \\ \frac{\partial y_1}{\partial b_2^{(1)}} \end{bmatrix} = \begin{bmatrix} y_1(1-y_1).w_{11}^{(2)}.a_1^{(1)}(1-a_1^{(1)}) \\ y_1(1-y_1).w_{12}^{(2)}.a_2^{(1)}(1-a_2^{(1)}) \end{bmatrix}_{2 \times 1}$$

$$\frac{\partial y_1}{\partial b_1} = y_1(1-y_1) \begin{bmatrix} w_{11}^{(2)} \\ w_{12}^{(2)} \end{bmatrix}_{2 \times 1} \cdot \begin{bmatrix} a_1^{(1)}(1-a_1^{(1)}) \\ a_2^{(1)}(1-a_2^{(1)}) \end{bmatrix}_{2 \times 1}$$

$$\frac{\partial y_1}{\partial b_1} = y_1(1-y_1) \cdot \begin{bmatrix} w_{11}^{(2)} \\ w_{12}^{(2)} \end{bmatrix} \cdot a_1(1-a_1) \quad \dots\dots\dots (2)$$

$$\frac{\partial y_1}{\partial W_2} = \begin{bmatrix} \frac{\partial y_1}{\partial w_{11}^{(2)}} & \frac{\partial y_1}{\partial w_{12}^{(2)}} \end{bmatrix} = \begin{bmatrix} y_1(1-y_1).a_1^{(1)} & y_1(1-y_1).a_2^{(1)} \end{bmatrix} = y_1(1-y_1) \begin{bmatrix} a_1^{(1)} & a_2^{(1)} \end{bmatrix}$$

$$\frac{\partial y_1}{\partial W_2} = y_1(1-y_1) * a_1^T \quad \dots\dots\dots (3)$$

$$\frac{\partial y_1}{\partial b_2} = \begin{bmatrix} \frac{\partial y_1}{\partial b_1^{(2)}} \end{bmatrix} = [y_1(1-y_1)] \quad \dots\dots\dots (4)$$

$$\frac{\partial y_2}{\partial W_1} = \begin{bmatrix} \frac{\partial y_2}{\partial w_{11}^{(1)}} & \frac{\partial y_2}{\partial w_{12}^{(1)}} \\ \frac{\partial y_2}{\partial w_{21}^{(1)}} & \frac{\partial y_2}{\partial w_{22}^{(1)}} \end{bmatrix}_{2 \times 2}$$

$$\frac{\partial y_2}{\partial W_1} = \begin{bmatrix} y_2(1-y_2).w_{21}^{(2)}.a_1^{(1)}(1-a_1^{(1)})x_1 & y_2(1-y_2).w_{21}^{(2)}.a_1^{(1)}(1-a_1^{(1)})x_2 \\ y_2(1-y_2).w_{22}^{(2)}.a_2^{(1)}(1-a_2^{(1)})x_1 & y_2(1-y_2).w_{22}^{(2)}.a_2^{(1)}(1-a_2^{(1)})x_2 \end{bmatrix}_{2 \times 2}$$

$$\frac{\partial y_2}{\partial W_1} = y_2(1-y_2) \cdot \begin{bmatrix} w_{21}^{(2)} \\ w_{22}^{(2)} \end{bmatrix} \cdot \begin{bmatrix} a_1^{(1)}(1-a_1^{(1)}) \\ a_2^{(1)}(1-a_2^{(1)}) \end{bmatrix}_{2 \times 1} * [x_1 \ x_2]_{1 \times 2}$$

$$\frac{\partial y_2}{\partial W_1} = (y_2(1-y_2)) \cdot \begin{bmatrix} w_{21}^{(2)} \\ w_{22}^{(2)} \end{bmatrix} \cdot a_1(1-a_1) * x^T \quad \dots\dots\dots (5)$$

$$\frac{\partial y_2}{\partial b_1} = \begin{bmatrix} \frac{\partial y_2}{\partial b_1^{(1)}} \\ \frac{\partial y_2}{\partial b_2^{(1)}} \end{bmatrix} = \begin{bmatrix} y_2(1-y_2) \cdot w_{21}^{(2)} \cdot a_1^{(1)}(1-a_1^{(1)}) \\ y_2(1-y_2) \cdot w_{22}^{(2)} \cdot a_2^{(1)}(1-a_2^{(1)}) \end{bmatrix}_{2 \times 1}$$

$$\frac{\partial y_2}{\partial b_1} = y_2(1-y_2) \begin{bmatrix} w_{21}^{(2)} \\ w_{22}^{(2)} \end{bmatrix}_{2 \times 1} \cdot \begin{bmatrix} a_1^{(1)}(1-a_1^{(1)}) \\ a_2^{(1)}(1-a_2^{(1)}) \end{bmatrix}_{2 \times 1}$$

$$\frac{\partial y_2}{\partial b_1} = y_2(1-y_2) \cdot \begin{bmatrix} w_{21}^{(2)} \\ w_{22}^{(2)} \end{bmatrix} \cdot a_1(1-a_1) \quad \dots\dots\dots (6)$$

$$\frac{\partial y_2}{\partial W_2} = \begin{bmatrix} \frac{\partial y_2}{\partial w_{21}^{(2)}} & \frac{\partial y_2}{\partial w_{22}^{(2)}} \end{bmatrix} = \begin{bmatrix} y_2(1-y_2) \cdot a_1^{(1)} & y_2(1-y_2) \cdot a_2^{(1)} \end{bmatrix} = y_2(1-y_2) \begin{bmatrix} a_1^{(1)} & a_2^{(1)} \end{bmatrix}$$

$$\frac{\partial y_2}{\partial W_2} = y_2(1-y_2) * a_1^T \quad \dots\dots\dots (7)$$

$$\frac{\partial y_2}{\partial b_2} = \begin{bmatrix} \frac{\partial y_2}{\partial b_1^{(2)}} \end{bmatrix} = [y_2(1-y_2)] \quad \dots\dots\dots (8)$$

Gradiente de la función error respecto a los pesos y bias

$$E = \frac{1}{2} ((s_1 - y_1)^2 + (s_2 - y_2)^2) \text{ función error}$$

Donde $e_1 = s_1 - y_1$, $e_2 = s_2 - y_2$ errores relativos

$$\frac{\partial E}{\partial W_1} = -(s_1 - y_1) \frac{\partial y_1}{\partial W_1} - (s_2 - y_2) \frac{\partial y_2}{\partial W_1}$$

$$\frac{\partial E}{\partial W_1} = -[e_1 \ e_2] \begin{bmatrix} \frac{\partial y_1}{\partial W_1} \\ \frac{\partial y_2}{\partial W_1} \end{bmatrix} \dots\dots\dots (9)$$

$$\frac{\partial E}{\partial b_1} = -(s_1 - y_1) \frac{\partial y_1}{\partial b_1} - (s_2 - y_2) \frac{\partial y_2}{\partial b_1}$$

$$\frac{\partial E}{\partial b_1} = -[e_1 \ e_2] \begin{bmatrix} \frac{\partial y_1}{\partial b_1} \\ \frac{\partial y_2}{\partial b_1} \end{bmatrix} \dots\dots\dots (10)$$

$$\frac{\partial E}{\partial W_2} = -(s_1 - y_1) \frac{\partial y_1}{\partial W_2} - (s_2 - y_2) \frac{\partial y_2}{\partial W_2}$$

$$\frac{\partial E}{\partial W_2} = -[e_1 \ e_2] \begin{bmatrix} \frac{\partial y_1}{\partial W_2} \\ \frac{\partial y_2}{\partial W_2} \end{bmatrix} \dots\dots\dots (11)$$

$$\frac{\partial E}{\partial b_2} = -(s_1 - y_1) \frac{\partial y_1}{\partial b_2} - (s_2 - y_2) \frac{\partial y_2}{\partial b_2}$$

$$\frac{\partial E}{\partial b_2} = -[e_1 \ e_2] \begin{bmatrix} \frac{\partial y_1}{\partial b_2} \\ \frac{\partial y_2}{\partial b_2} \end{bmatrix} \dots\dots\dots (12)$$

Propagación hacia atrás en los pesos y bias

$$W_1 = W_1 + \alpha \cdot [e_1 \ e_2]^* \begin{bmatrix} \frac{\partial y_1}{\partial W_1} \\ \frac{\partial y_2}{\partial W_1} \end{bmatrix} \dots\dots\dots (13)$$

$$b_1 = b_1 + \alpha \cdot [e_1 \ e_2]^* \begin{bmatrix} \frac{\partial y_1}{\partial b_1} \\ \frac{\partial y_2}{\partial b_1} \end{bmatrix} \dots\dots\dots (14)$$

$$W_2 = W_2 + \alpha \cdot [e_1 \ e_2]^* \begin{bmatrix} \frac{\partial y_1}{\partial W_2} \\ \frac{\partial y_2}{\partial W_2} \end{bmatrix} \dots\dots\dots (15)$$

$$b_2 = b_2 + \alpha \cdot [e_1 \ e_2]^* \begin{bmatrix} \frac{\partial y_1}{\partial b_2} \\ \frac{\partial y_2}{\partial b_2} \end{bmatrix} \dots\dots\dots (16)$$

2.1.4. Análisis de Correspondencias Múltiples (ACM)

Se debe considerar una tabla de contingencia formada por n filas que representan a los individuos y por, s columnas que representan las variables categóricas con sus respectivas modalidades p, mutuamente excluyentes y exhaustivas (Figueras, 2003).

La tabla tendrá la forma $Z = [Z_1; \dots; Z_s]$ con Z_i matriz $n \times pk$; para $k = \{1; \dots; s\}$, de manera que:

$Z_{ij} = 1$ si el i-ésimo dato $i = \{1; \dots; n\}$, seleccionó la modalidad $j = \{1; \dots; p\}$,

$Z_{ij} = 0$ en caso contrario

A continuación, se muestra la proposición siguiente indica la forma del estadístico ji-cuadrado para la matriz binaria Z en caso esta fuera tratada como una tabla de contingencia.

Proposición El estadístico ji-cuadrado asociado a la prueba de independencia sobre la matriz binaria Z viene dado por:

$$X^2 = n(pk - s)$$

Se recuerda que la inercia en una tabla de contingencia se calcula como el estadístico ji-cuadrado dividido entre n. Sin embargo, dentro del contexto de la matriz binaria, n tendría que ser reemplazado por nQ. Así se tiene que la inercia de esta matriz viene dada por:

$$\mathcal{J}(Z) = \frac{X_Z^2}{nQ} = \frac{n(J - Q)}{nQ}$$

Análisis con la Matriz de Burt

Una estructura alternativa de datos para el ACM es tomar, en lugar de la matriz binaria Z , la matriz Burt B definida por:

$$B = Z^T Z = [Z_1 Z_2 \dots Z_Q]^T [Z_1 Z_2 \dots Z_Q]$$

$$= \begin{bmatrix} Z_1^T Z_1 & Z_1^T Z_2 \dots & Z_1^T Z_Q \\ Z_2^T Z_1 & Z_2^T Z_2 \dots & Z_2^T Z_Q \\ \vdots & \vdots & \vdots \\ Z_Q^T Z_1 & Z_Q^T Z_2 & Z_Q^T Z_Q \end{bmatrix} = \begin{bmatrix} D_1 & N_{12} \dots & N_{1Q} \\ N_{12}^T & D_2 & N_{2Q} \\ \vdots & \vdots & \vdots \\ N_{1Q}^T & N_{1Q}^T & D_Q \end{bmatrix}$$

Compuesta por todas las tablas de contingencia N_{qs} resultantes de cruzar todas las variables de interés dos a dos para $q \neq s$ y matrices diagonales D_q conteniendo las frecuencias marginales de las categorías de la variable q de cruzar esta variable consigo misma. La otra forma 'clásica' de definir el ACM es efectuando el AC a la matriz de Burt. En tal caso un análisis similar al visto en la proposición anterior lleva a descomponer el estadístico ji-cuadrado de independencia para la matriz de Burt de la manera siguiente.

El estadístico ji-cuadrado asociado a la prueba de independencia sobre la matriz de Burt B viene dado por:

$$X^2(B) = \sum_{q \neq s} \sum X_{qs}^2 + n(J - Q)$$

Donde X_{qs}^2 denota al estadístico ji-cuadrado asociado a la tabla de contingencia N_{qs} .

Comparación del ACM de las matrices binaria y de Burt

Las dos formas de definir el ACM se relacionan de la siguiente manera:

- En los dos análisis, las coordenadas estándares son idénticas.
- Las inercias principales del análisis de Burt son los cuadrados de los de la matriz binaria.
- Dado que las inercias principales son menores que 1, sus cuadrados darán valores más pequeños. en consecuencia, los porcentajes de inercia serán siempre mayores en el análisis de Burt.

Inercia de la matriz de Burt

Todas las subtablas que componen la matriz de Burt tienen los mismos valores marginales totales de las y columnas. La inercia de B será la media de las inercias de las sub tablas Bqs, que lo componen. Los altos valores de las inercias de las matrices de la diagonal de la matriz de Burt explican por qué su inercia total es tan alta y por lo tanto también explica los bajos porcentajes de la inercia de los ejes. Esto provoca una subestimación de la calidad de los mapas que resulten de este tipo de análisis.

Nuevamente, la pregunta que surge es cuantas dimensiones considerar. De acuerdo con Camiz y Gomes (2012), esto puede ser resuelto aplicando el argumento sugerido por Benzécri (1979) y Greenacre (1988, 2006) que sostiene que hay que limitar la atención solamente a los autovalores de la matriz binaria mayores que su media. Se prueba que dicha media es $1/Q$. Siendo los autovalores de la matriz de Burt las raíces de los autovalores de la matriz binaria, entonces solo deberá considerarse las dimensiones que cumplan:

$$\sqrt{\lambda_x} > \frac{1}{Q}$$

Por otra parte, Ben Ammu y Saporta (1998, 2003) sugieren estimar la significatividad de los autovalores del ACM (nuevamente considerando la matriz binaria) de acuerdo a su distribución. Para esto muestran que, bajo la Hipótesis de independencia por pares, la medida de dispersión de los autovalores en el ACM:

$$S_\lambda^2 = \frac{1}{k} \sum_{k=1}^k \left(\lambda_k - \frac{1}{Q} \right)^2$$

Satisface que:

$$\sigma^2 = E[S_\lambda^2] = \frac{1}{nQ^2(J-Q)} \sum_{i \neq j} (J_i - Q)(J_j - 1)$$

y consideran que el intervalo $1/Q \pm 2\sigma$ deberá de contener aproximadamente alrededor del 95 % de los autovalores.

Etapas del Análisis de Correspondencia Múltiple – HOMALS

Según Saavedra (2012) son los siguientes:

Objetivos del modelo de correspondencia múltiple: El objetivo del análisis de correspondencia múltiple es describir las relaciones entre dos o más variables nominales múltiples en un espacio de pocas dimensiones. Dichas dimensiones contienen las categorías de las variables, así como los objetos pertenecientes a dichas categorías. La forma de visualizar dichas dimensiones es a través de Mapas Perceptuales. Un mapa perceptual está compuesto de ejes de coordenadas y puntos. Los puntos representan a objetos y categorías de las variables. Los ejes (dimensiones) definen el espacio de representación de los puntos. A diferencia de las técnicas estándar, además de evaluar las relaciones entre variables, permite conocer la relación entre las categorías de una misma variable y entre las categorías de distintas variables.

Supuestos en el análisis de correspondencia múltiple: El análisis de correspondencia múltiple posee una relativa libertad respecto a supuestos básicos. Los datos pueden estar medidos en cualquier escala, principalmente nominal, y representa igualmente bien relaciones lineales como no lineales. Lo importante es la existencia de relaciones (asociación) entre las variables.

Obtención de resultados y valoración del ajuste conjunto

1) Procedimiento

La técnica consiste en transformar una serie de variables nominales en dimensiones numéricas. Las nuevas dimensiones recogen la asociatividad existente entre las variables nominales, es decir, las primeras dimensiones recogen lo común, y las últimas captan lo específico, que existe entre las variables del análisis.

En forma básica, el procedimiento de obtención de resultados implica 2 etapas generales:

1.1) Obtención de Dimensiones (Factores)

1.2) Obtención de valores numéricos para los objetos (casos) y cuantificación de categorías.

2) Valoración del ajuste conjunto

En resumen, el análisis de correspondencias múltiples consiste en la creación de nuevas dimensiones, similar al análisis de componentes principales. La mayoría de las veces el modelo genera más de dos dimensiones, pero en la práctica se utilizan las dos primeras dimensiones para interpretar una serie de relaciones. Los textos de análisis de datos fundamentan la utilización sola de las dos primeras dimensiones, debido a que los mapas perceptuales con más dimensiones complejizan el análisis y son de difícil interpretación. Esta posición práctica del análisis excluye el carácter estructural de la técnica y no contesta una de las preguntas claves del análisis:

¿Son suficientes las dos primeras dimensiones, que se utilizan en el mapa perceptual, para explicar las relaciones entre las variables incluidas en el modelo? Para responder dicha pregunta, es necesario un análisis digital de toda la información, para recién en su etapa posterior utilizar el mapa, ya validado con dos o más dimensiones. Los textos de análisis de datos utilizan la información digital a partir del mapa ya generado, y concentran su análisis en las dimensiones del mapa.

3) Interpretación de los resultados

La interpretación de resultados comienza con un análisis del ajuste total y la historia de iteraciones. Observar las iteraciones permite ver ¿con qué dificultad se obtuvo el resultado?, Es decir, a mayor número de iteraciones mayor es la dificultad de obtener una solución óptima.

Reglas para la interpretación

Para ver que existen afinidades entre resultados, equivale decir que hay individuos que han seleccionado simultáneamente todas o casi todas, los mismos resultados. El análisis de correspondencia múltiples evidencia a los individuos con perfiles semejantes respecto a los atributos seleccionados en su descripción. De acuerdo con las distancias entre elementos de la tabla disyuntiva completa y la relaciones baricéntricas, y se expresa.

Dos individuos son semejantes si han seleccionado globalmente las mismas modalidades, eso quiere decir que la cercanía entre individuos en términos es de semejanzas.

La cercanía o proximidad entre modalidades de variables diferentes en términos de asociación; es decir, estas modalidades corresponden a puntos medios de los individuos que las han seleccionado, y son próximas porque están ligadas a los mismos individuos o individuos parecidos.

La proximidad entre dos modalidades de una misma variable en términos de semejanza; por construcción, los procedimientos de una misma variable son excluyentes. Si ellas están cerca, su proximidad se llega a interpretar en términos de semejanza entre grupos de individuos que se hayan seleccionado (con respecto a las otras variables activas del análisis) (Luis Guillermo Díaz Monroy, 2012).

2.1.5. Algoritmo de Levenberg-Marquardt

En matemáticas y computación, el algoritmo de Levenberg-Marquardt (LMA o simplemente LM), también conocido como el método de mínimos cuadrados amortiguados (DLS), se utiliza para resolver problemas de mínimos cuadrados no lineales. Estos problemas de minimización surgen especialmente en el ajuste de curvas de mínimos cuadrados.

El LMA se usa en muchas aplicaciones de software para resolver problemas genéricos de ajuste de curvas. Sin embargo, como ocurre con muchos algoritmos de ajuste, el LMA solo encuentra un mínimo local, que no es necesariamente el mínimo global. El LMA interpola entre el algoritmo de Gauss-Newton (GNA) y el método de descenso de gradiente. El LMA es más robusto que el GNA, lo que significa que en muchos casos encuentra una solución incluso si comienza muy lejos del mínimo final. Para funciones de buen comportamiento y parámetros de inicio razonables, el LMA tiende a ser un poco más lento que el GNA. El LMA también se puede ver como Gauss-Newton utilizando un enfoque de región de confianza.

El algoritmo fue publicado por primera vez en 1944 por Kenneth Levenberg, mientras trabajaba en el Arsenal del Ejército de Frankford. Fue redescubierto en 1963 por Donald Marquardt, quien trabajó como estadístico en DuPont, e independientemente por Girard Wynne y Morrison.

El problema

La aplicación principal del algoritmo de Levenberg-Marquardt se encuentra en el problema de ajuste de curvas de mínimos cuadrados: dado un conjunto de m pares de datos empíricos $(\mathbf{x}_i, \mathbf{y}_i)$ de variables independientes y dependientes, encuentre los parámetros β de la curva del modelo $f(\mathbf{x}, \beta)$ de modo que la suma de los cuadrados de las desviaciones $\mathbf{S}(\beta)$ se minimice:

$\hat{\beta} \in \operatorname{argmin}_{\beta} S(\beta) \equiv \operatorname{argmin}_{\beta} \sum_{i=1}^m [y_i - f(x_i, \beta)]^2$ que se supone que no está vacío.

La solución

Al igual que otros algoritmos de minimización numérica, el algoritmo de Levenberg-Marquardt es un procedimiento iterativo. Para iniciar una minimización, el usuario debe proporcionar una estimación inicial del vector de parámetros β . En los casos con solo un mínimo, una conjetura estándar no informada como $\beta^T = (1, 1, \dots, 1)$ funcionará bien; en los casos con múltiples mínimos, el algoritmo converge al mínimo global solo si la estimación inicial ya es algo cercana a la solución final. En cada paso de iteración, el vector parámetro β se reemplaza por una nueva estimación $\beta + \delta$. Para determinar δ , la función $f(x_i, \beta + \delta)$ se aproxima por su linealización:

$$f(x_i, \beta + \delta) \approx f(x_i, \beta) + J_i \delta, \text{ donde } J_i = \frac{\partial f(x_i, \beta)}{\partial \beta}$$

es el gradiente (fila-vector en este caso) de f con respecto a β .

La suma $\mathbf{S}(\beta)$ de desviaciones cuadradas tiene su mínimo en un gradiente de cero con respecto a β . La anterior aproximación de primer orden de $f(x_i, \beta + \delta)$ da

ECUACIONES PARA LA TESIS

$$S(\boldsymbol{\beta} + \boldsymbol{\delta}) \approx \sum_{i=1}^m [y_i - f(x_i, \boldsymbol{\beta}) - J_i \boldsymbol{\delta}]^2,$$

o en notación vectorial,

$$\begin{aligned} S(\boldsymbol{\beta} + \boldsymbol{\delta}) &\approx \|\mathbf{y} - \mathbf{f}(\boldsymbol{\beta}) - \mathbf{J}\boldsymbol{\delta}\|^2 \\ &= [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta}) - \mathbf{J}\boldsymbol{\delta}]^T [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta}) - \mathbf{J}\boldsymbol{\delta}] \\ &= [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})]^T [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})] - [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})]^T \mathbf{J}\boldsymbol{\delta} - (\mathbf{J}\boldsymbol{\delta})^T [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})] + \boldsymbol{\delta}^T \mathbf{J}^T \mathbf{J}\boldsymbol{\delta} \\ &= [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})]^T [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})] - 2[\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})]^T \mathbf{J}\boldsymbol{\delta} + \boldsymbol{\delta}^T \mathbf{J}^T \mathbf{J}\boldsymbol{\delta} \end{aligned}$$

Tomando la derivada de $S(\boldsymbol{\beta} + \boldsymbol{\delta})$ con respecto a $\boldsymbol{\delta}$ y establecer el resultado a cero da $(\mathbf{J}^T \mathbf{J})\boldsymbol{\delta} = \mathbf{J}^T [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})]$,

donde \mathbf{J} es la **matriz jacobiana**, cuya fila i es igual a \mathbf{J}_i , y donde \mathbf{F} y \mathbf{y} son vectores con i -componente $\mathbf{f}(x_i + \boldsymbol{\beta})$ y y_i respectivamente. Este es un conjunto de ecuaciones lineales, que se pueden resolver para $\boldsymbol{\delta}$.

La contribución de Levenberg es reemplazar esta ecuación por una "versión amortiguada":

$$(\mathbf{J}^T \mathbf{J} + \lambda \mathbf{I})\boldsymbol{\delta} = \mathbf{J}^T [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})],$$

donde \mathbf{I} es la matriz de identidad, dando como incremento $\boldsymbol{\delta}$ al vector de parámetros estimado $\boldsymbol{\beta}$.

El factor de amortiguamiento (no negativo) λ se ajusta en cada iteración. Si la reducción de S es rápida, se puede usar un valor más pequeño, acercando el algoritmo al algoritmo de **Gauss-Newton**, mientras que si una iteración produce una reducción insuficiente del residual, λ puede aumentarse, dando un paso más cerca del descenso del gradiente dirección. Tenga en cuenta que el **gradiente** de S con respecto a $\boldsymbol{\beta}$ es igual a $-2(\mathbf{J}^T [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})])^T$. Por lo tanto, para valores grandes de λ , el paso se tomará aproximadamente en la dirección del gradiente. Si la longitud del paso calculado $\boldsymbol{\delta}$ o la reducción de la suma de cuadrados del último vector de parámetros $\boldsymbol{\beta} + \boldsymbol{\delta}$ cae por debajo de los límites predefinidos, la iteración se detiene, y el último vector de parámetros $\boldsymbol{\beta}$ se considera la solución.

Si el valor del factor de amortiguamiento λ es grande en relación con la norma de $\mathbf{J}^T \mathbf{J}$, no es necesario resolver el sistema con matriz $\mathbf{J}^T \mathbf{J} + \lambda \mathbf{I}$, dado que esta matriz se puede aproximar mediante $\lambda \mathbf{I}$. En este caso el algoritmo realiza una actualización en la dirección del gradiente, con un paso pequeño: $\boldsymbol{\delta} = \frac{1}{\lambda} \mathbf{J}^T [\mathbf{y} - \mathbf{f}(\boldsymbol{\beta})]$.

R. Fletcher proporcionó la idea de que podemos escalar cada componente del gradiente según la curvatura, de modo que haya un movimiento más grande a lo largo de las direcciones donde el gradiente es más pequeño. Esto evita la convergencia lenta en la dirección del gradiente pequeño. Por lo tanto, Fletcher en su artículo de 1971 "*Una subrutina de Marquardt modificada para mínimos cuadrados no lineales*", reemplazó la matriz de identidad I con la matriz diagonal que consiste en los elementos diagonales de $J^T J$, lo que hace que la escala de la solución sea invariante:

$$[J^T J + \lambda \text{diag}(J^T J)]\delta = J^T [y - f(\beta)]$$

Un factor de amortiguación similar aparece en la regularización de Tikhonov, que se utiliza para resolver problemas lineales mal planteados, así como en la regresión de crestas, una técnica de estimación en estadística.

Elección del parámetro de amortiguación

Se han presentado varios argumentos más o menos heurísticos para la mejor opción para el parámetro de amortiguación λ . Existen argumentos teóricos que muestran por qué algunas de estas opciones garantizan la convergencia local del algoritmo; sin embargo, estas elecciones pueden hacer que la convergencia global del algoritmo sufra de las propiedades indeseables del descenso más pronunciado, en particular, una convergencia muy lenta cerca del óptimo.

Los valores absolutos de cualquier elección dependen de qué tan escalada esté el problema inicial. Marquardt recomendó comenzar con un valor λ_0 y un factor $v > 1$. Configurando inicialmente $\lambda = \lambda_0$ y calculando la suma residual de cuadrados $S(\beta)$ después de un paso desde el punto de inicio con el factor de amortiguamiento de $\lambda = \lambda_0$ y en segundo lugar con λ_0/v . Si ambos de estos son peores que el punto inicial, entonces la amortiguación se incrementa por multiplicación sucesiva por v hasta que se encuentra un punto mejor con un nuevo factor de amortiguación de $\lambda_0 v^k$ para algunos k .

Si el uso del factor de amortiguación λ / v da como resultado una reducción en el residuo al cuadrado, esto se toma como el nuevo valor de λ (y la nueva ubicación óptima se toma como la obtenida con este factor de amortiguación) y el proceso continúa; si el uso de λ/v resultó en un peor residuo, pero el uso de λ resultó en un mejor residuo, entonces λ se mantiene sin cambios y el nuevo óptimo se toma como el valor obtenido con λ como factor de amortiguamiento.

2.1.6. Gradiente Descendente

Es un algoritmo de optimización el cual permite encontrar de forma automática el mínimo de una función. Para ello hace uso del gradiente (o derivada) de dicha función, que permite “guiar” al algoritmo para que de manera progresiva acercarse al mínimo ideal de dicha función.

El gradiente es un cálculo que nos permite saber cómo ajustar los parámetros de la red de tal forma que se minimice su desviación a la salida.

Los datos de entrenamiento ayudan a que estos modelos aprendan con el tiempo, y la función de costo dentro del descenso de gradiente actúa específicamente como un barómetro, midiendo su precisión con cada iteración de actualizaciones de parámetros. Hasta que la función sea cercana o igual a cero, el modelo continuará ajustando sus parámetros para producir la menor cantidad de errores posible. Los modelos de machine learning, una vez optimizados para la precisión, pueden ser potentes herramientas para aplicaciones de inteligencia artificial (IA) y ciencias de la computación.

Funcionamiento de descenso de gradiente

El punto de partida es solo un punto arbitrario para que podamos evaluar el rendimiento. Desde ese punto de partida, encontraremos la derivada (o pendiente), y desde allí, podemos usar una recta tangente para observar la inclinación de la pendiente. La pendiente informará las actualizaciones de los parámetros, es decir, los pesos y el sesgo. La pendiente en el punto de partida será más pronunciada, pero a medida que se generen nuevos parámetros, la pendiente debe reducirse gradualmente hasta alcanzar el punto más bajo de la curva, conocido como punto de convergencia.

Del mismo modo que se detecta la mejor línea de ajuste en la regresión lineal, el objetivo del descenso de gradiente es minimizar la función de costo, o el error entre la "y" real y su valor pronosticado. Para hacer esto, se necesitan dos puntos de datos: una dirección y una tasa de aprendizaje. Estos factores determinan los cálculos de derivadas parciales de iteraciones futuras, lo que le permite llegar gradualmente al mínimo local o global (es decir, punto de convergencia).

- × **Índice de aprendizaje** (también conocida como tamaño de paso, o alfa) es el tamaño de los pasos que se dan para alcanzar el mínimo. Suele ser un valor pequeño y se evalúa y actualiza en función del comportamiento de la

función de costos. Los índices de aprendizaje altos dan como resultados pasos más grandes, pero existe el riesgo de exceder el mínimo. Por el contrario, los índices de aprendizaje bajos generan tamaños de paso más pequeños. Si bien tiene la ventaja de una mayor precisión, el número de iteraciones compromete la eficiencia general, ya que esto requiere más tiempo y cálculos para alcanzar el mínimo.

- × **La función de costo (o pérdida)** mide la diferencia, o error, entre la "y" real y la "y" pronosticada en su posición actual. Esto mejora la eficacia del modelo de machine learning, ya que proporciona información al modelo para que pueda ajustar los parámetros para minimizar el error y encontrar el mínimo local o global. Repite continuamente, moviéndose a lo largo de la dirección de descenso más pronunciado (o el gradiente negativo) hasta que la función de costo se acerca o llega a cero. En este punto, el modelo dejará de aprender. Además, si bien los términos función de costo y función de pérdida se consideran sinónimos, existe una ligera diferencia entre ellos. Vale la pena señalar que una función de pérdida se refiere al error de un ejemplo de entrenamiento, mientras que una función de costo calcula el error promedio en todo un conjunto de entrenamiento.

Tipos de descenso de gradiente

Hay tres tipos de algoritmos de aprendizaje de descenso de gradiente: descenso de gradiente por lotes, descenso de gradiente estocástico y descenso de gradiente por mini lotes.

× **Descenso de gradiente por lotes**

El descenso de gradiente por lotes suma el error para cada punto en un conjunto de entrenamiento, actualizando el modelo solo después de que todos los ejemplos de entrenamiento han sido evaluados. Este proceso se conoce como época de entrenamiento.

Si bien este procesamiento por lotes proporciona eficiencia de cálculo, aún puede tener un tiempo de procesamiento prolongado para grandes conjuntos de datos de entrenamiento, ya que aún necesita almacenar todos los datos en la memoria. El descenso del gradiente por lotes también suele producir un gradiente de error estable y una convergencia, pero a veces ese punto de convergencia no es el ideal y encuentra el mínimo local frente al global.

× **Descenso de gradiente estocástico**

El descenso de gradiente estocástico (SGD) ejecuta una época de entrenamiento para cada ejemplo dentro del conjunto de datos y actualiza los parámetros del ejemplo de entrenamiento uno por uno. Dado que solo necesita mantener un ejemplo de entrenamiento, es más fácil almacenarlos en la memoria. Si bien estas actualizaciones frecuentes pueden ofrecer más detalles y velocidad, pueden resultar en pérdidas en la eficiencia computacional en comparación con el descenso de gradiente por lotes. Sus actualizaciones frecuentes pueden resultar en gradientes ruidosos, pero esto también puede ser útil para omitir el mínimo local y encontrar el global.

× **Descenso de gradiente por mini lotes**

El descenso de gradiente por mini lotes combina conceptos tanto del descenso de gradiente por lotes como del descenso de gradiente estocástico. Divide el conjunto de datos de entrenamiento en pequeños tamaños de lote y realiza actualizaciones en cada uno de esos lotes. Este enfoque logra un equilibrio entre la eficiencia computacional del lote de descenso de gradiente y la velocidad del descenso de gradiente estocástico.

Problemas de descenso de gradiente

En redes neuronales más profundas, en particular redes neuronales recurrentes, también podemos encontrarnos con otros dos problemas cuando el modelo se entrena con descenso de gradiente y retropropagación.

- × **Desaparición de gradientes:** esto ocurre cuando el gradiente es demasiado pequeño. A medida que nos movemos hacia atrás durante la retropropagación, el gradiente continúa haciéndose más pequeño, lo que hace que las capas anteriores de la red aprendan más lentamente que las capas posteriores. Cuando esto sucede, los parámetros de peso se actualizan hasta que se vuelven insignificantes, es decir, 0, lo que genera un algoritmo que ya no está aprendiendo.
- × **Explosión de gradientes:** esto sucede cuando el gradiente es demasiado grande, creando un modelo inestable. En este caso, los pesos del modelo crecerán demasiado y eventualmente se representarán como NaN. Una solución a este problema es aprovechar una técnica de reducción de dimensionalidad, que puede ayudar a minimizar la complejidad dentro del modelo.

CAPÍTULO III

MARCO METODOLÓGICO

3.1. Hipótesis central de la investigación

El rendimiento académico de los estudiantes de la Universidad Nacional del Santa en función de los factores Socioeconómicos en el semestre 2020 I y II es determinado mediante la implementación de una Red Neuronal Supervisada.

3.2. Variables e indicadores de la investigación

- **Variable Independiente**
Factores Socioeconómicos
- **Variable Dependiente**
Rendimiento académico de los estudiantes
- **Operacionalización de variables**

Tabla 1

Operacionalización de variables

VARIABLES	DIMENSIONES	DEFINICIÓN OPERACIONAL	INDICADORES
Rendimiento Académico de los estudiantes	Promedio final del semestre	Está representado por el promedio ponderado del estudiante en las asignaturas matriculados en el semestre 2020 I y II.	Nota promedio del semestre Número de materias aprobadas Número de materias desaprobadas
Factores Socioeconómicos	Aspecto Personal Aspecto Familiar Aspecto Económico Aspecto Vivienda Aspecto Académico Aspecto Conectividad Aspecto Salud Aspecto Emergencia	Los factores socioeconómicos están determinados por la información obtenida en las fichas socioeconómica aplicada a los estudiantes en el semestre 2020 I y II.	Edad del estudiante Nivel de instrucción de los padres Ingreso de los padres ...

3.3. Métodos de la investigación

La presente investigación utiliza el método inductivo - deductivo, al partir de un conjunto de datos históricos de las variables que intervienen en el cálculo del rendimiento académico de los estudiantes, y es a través de una red neuronal backpropagation se obtiene un modelo que generaliza esta información para cada estudiante, y el aspecto deductivo corresponde al predecir el cálculo del rendimiento académico de los estudiantes que no fueron considerados en estos datos históricos.

3.4. Diseño o esquema de la investigación

La investigación es del tipo aplicada, donde se desarrolla la herramienta de las redes neuronales artificiales para determinar la incidencia de los factores socioeconómicos en el rendimiento académico de los estudiantes. Su diseño corresponde al tipo experimental, dado a que se cuenta con una Red neuronal backpropagation que va a predecir los resultados y a comparar con los obtenidos en los datos históricos.

3.5. Población y muestra

3.5.1. Población:

La población está conformada por 6022 estudiantes de los ciclos: 2020 – I y 2020 – II.

3.5.2. Muestra:

El tamaño de la muestra fue 2979 estudiantes del ciclo 2020 – I y 2020 – II.

3.6. Actividades del proceso investigativo

- a. Obtención de Fichas Socioeconómicas.
- b. Análisis de las variables y su dependencia.
- c. Diseño de la Red Neuronal Artificial.
- d. Normalización de la BD de entrada y salida.
- e. Entrenamiento de la Red Neuronal Artificial.
- f. Evaluación la Red Neuronal Artificial.
- g. Análisis de los Errores.

3.7. Técnicas e instrumentos de la investigación

▪ Técnicas

Se emplearán las técnicas de observación, análisis documental y encuestas.

- ✓ **Observación**, Se estuvo presente en algunas encuestas realizadas por el personal encargado de la aplicación de las fichas socioeconómicas.
- ✓ **Encuestas online**, mediante los registros de fichas virtuales permitirá recolectar información para los datos de entrada de la Red Neuronal permitiendo contar con una gran cantidad de datos para la construcción de la base de datos y el entrenamiento.
- ✓ **Análisis documental**, por medio del registro de consolidados de notas, facilitará el entrenamiento y evaluación de resultados esperados.

▪ Instrumentos

- ✓ Cuestionarios online
- ✓ Análisis documental
- ✓ Red neuronal

3.8. Procedimiento para la recolección de datos

El procedimiento para la recolección de datos de la presente investigación será:

1. Se solicitó a las oficinas pertinentes las fichas socioeconómicas virtuales y los consolidados de notas de todos los estudiantes los ciclos 2020-I, 2020-II.
2. Se construyó la base de datos a partir de las fichas y consolidados de los estudiantes en los ciclos 2020-I, 2020-II.
3. Se depuró la base de datos buscando la dependencia de los mismos
4. Se desarrolló un algoritmo de aprendizaje profundo por medio de una red neuronal supervisada que nos va permitir evaluar el grado de aproximación con los valores deseados.
5. Se entrenó la red neuronal con el registro de datos de los estudiantes en las fichas socioeconómicas y los datos de promedios globales por ciclo de los consolidados de notas.

6. Se realizó la evaluación de la red neuronal.

3.9. Técnicas de procesamiento y análisis de los datos

En el presente trabajo de investigación se utilizó la Estadística Descriptiva e Inferencial y el entrenamiento y validación de la red neuronal.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1 Resultado del Objetivo General

Tabla 2

Análisis de correspondencia múltiple, priorización y relación de las variables de los factores socioeconómicos y el rendimiento académico de los estudiantes de la UNS en el semestre 2020 I y II.

Número de iteración	Varianza contabilizada para		Pérdida
	Total	Aumentar	
38 ^a	5.2475201	.000006	10.547299

a. El proceso de iteración se ha detenido porque se ha alcanzado el valor de prueba de convergencia.

Nota. En la Tabla 2 de ACM, permite observar que tiene un número de iteraciones de 38 para llegar a encontrar el modelo adecuado, lo que me permite crear 3 dimensiones para un mayor análisis.

Tabla 3

Resumen del modelo de ACM.

Dimensión	Alfa de Cronbach	Varianza contabilizada para	
		Total (autovalor)	Inercia
1	,607	2,332	,137
2	,584	2,221	,131
3	,463	1,773	,104
Total		6,326	,372
Media	,559 ^a	2,109	,124

a. La media de alfa de Cronbach se basa en la media de autovalor.

Nota. Podemos observar que los valores de inercia de la Tabla 3 para la dimensión 1 es 0.137, para la dimensión 2 es 0.131 y para la dimensión 3 es 0.104, respectivamente, lo que nos indica que la más importante para el modelo es la primera dimensión con un 13.7%, que la segunda con 13.1% y la tercera con 10.4%.

Por lo cual se concibe que las dimensiones que se esperan luego que las mismas se obtienen a raíz del análisis de correspondencia, donde se infiere que a mayor dependencia de las variables mayor inercia, esto quiere decir que las categorías

presentan mayor dispersión de varianza en la primera dimensión mientras que en la segunda y tercera dimensión son parecidas en cuanto a variabilidad.

El alfa de Cronbach indica también que tan relacionadas están las variables observables que componen las variables latentes, las dimensiones, por lo que ambas dimensiones tienen una relación directa.

El autovalor de cuenta en la proporción de información del modelo que es explicada por cada dimensión; permite analizar la importancia de cada una de ellas.

Tabla 4

Medidas discriminantes de correlaciones del rendimiento académico de los estudiantes de la UNS en función de los factores socioeconómicos en el semestre 2020 I y II.

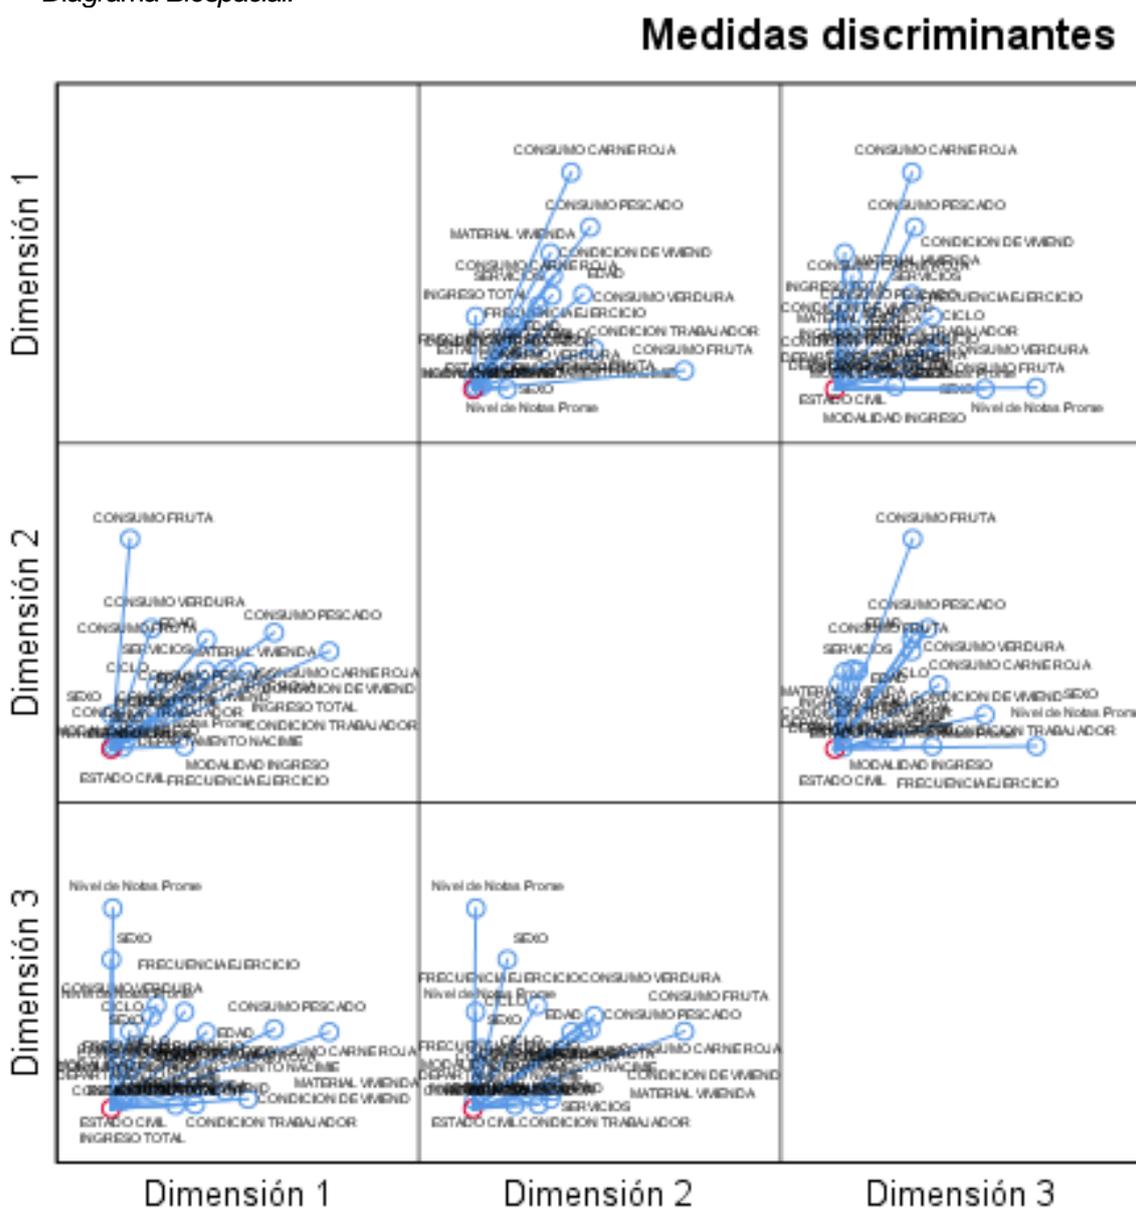
	Dimensión			Media
	1	2	3	
Nivel de Notas Promedio	,003	,006	,318	,109
CICLO	,090	,127	,164	,127
SEXO	,001	,068	,237	,102
ESTADO CIVIL	,022	,003	,013	,013
EDAD	,188	,217	,121	,176
MODALIDAD INGRESO	,007	,017	,095	,039
DEPARTAMENTO NACIMIENTO	,031	,019	,063	,038
CONDICION TRABAJADOR	,127	,083	,005	,072
RESPONSABLE CASA				
INGRESO TOTAL	,166	,129	,006	,100
MATERIAL VIVIENDA	,226	,158	,028	,137
CONDICION DE VIVIENDA	,270	,153	,015	,146
SERVICIOS	,187	,156	,037	,126
CONSUMO CARNE ROJA	,431	,194	,122	,249
CONSUMO PESCADO	,322	,231	,126	,226
CONSUMO FRUTA	,037	,417	,123	,192
CONSUMO VERDURA	,080	,239	,147	,155
FRECUENCIA EJERCICIO FISICO	,145	,005	,154	,101
Total, activo	2,332	2,221	1,773	2,109

Nota. En la primera dimensión de la Tabla 4 se muestra las medidas discriminantes de todas las variables en estudio y las importantes por las 3 dimensiones son:

Para la Dimensión 1: El consumo de carne con un 0.431, el consumo de carne de pescado con 0.332 luego condición de vivienda con 0.270, el material de vivienda con 0.226 pertenecientes a las dimensiones salud y vivienda.

En la Dimensión 2: el consumo de fruta con un 0.417, el consumo de verdura con 0.239 y el consumo de pescado con 0.231 pertenecientes a la dimensión salud, y con menor relación. En la Dimensión 3; están el sexo con 0.237 y pertenece a la dimensión personal.

Figura 18
Diagrama Biespacial.



Fuente: Propia

Nota. Se presenta el diagrama de dispersión biespacial por medidas discriminantes según el análisis de correspondencia múltiple (ACM) del rendimiento académico de los estudiantes de la UNS en función de los factores socioeconómicos en el semestre 2020 I y II.

Según el diagrama de dispersión en función a los objetos y centroides se visualiza que en las variables donde más hace falta como el consumo de carne roja, pescado, verduras y fruta como las carencias básicas como los factores socioeconómicos que influyen al rendimiento académico de los estudiantes, como se refleja en la figura 18.

4.2 Resultado del Objetivo específico n° 1

Se recopiló la información en los aspectos personal, familiar, económico, vivienda, académico, conectividad, salud y emergencia de 6022 alumnos de las fichas socioeconómicas de los semestres 2020-I y 2020-II, exportados en un archivo excel: https://drive.google.com/drive/folders/1BvGsw0EI-4dOo5CwFfppE6pvA5wyl1dn?usp=drive_link, así como los promedios de esos mismos alumnos, según figuras anexo n°01.

4.3 Resultado del Objetivo específico n° 2

Hipótesis:

H₀: No hay relación entre las dimensiones Educación y Económico, Vivienda y Salud del Rendimiento Académico de los estudiantes de la UNS en función de los Factores Socioeconómicos.

H₁: Si hay relación entre las dimensiones Educación y Económico, Vivienda y Salud del Rendimiento Académico de los estudiantes de la UNS en función de los Factores Socioeconómicos.

Tabla 5

Relación que Existe entre las Dimensiones Educación y las Dimensiones Económico, Vivienda y Salud, del Rendimiento Académico de los estudiantes de la UNS en función de los Factores Socioeconómicos en el semestre 2020 I y II.

Educación	Económico	Vivienda	Salud
Chi-cuadrado de Pearson	9.668	37.654	36.570
Sig. (bilateral)	0.378	0.006	0.007
N	2978	2978	2978

Nota: En el caso, la relación entre las dimensiones Educación y Económico se acepta la hipótesis Nula, el valor de $X^2 (0.95;6) = 12.59$ se encuentra en la región de aceptación, con el valor calculado de Chi cuadrado de Pearson = 9.668 y el valor $p=0.378$ y es mayor a 0.05, podemos concluir que no existe diferencia significativa y por lo tanto no existe relación entre las dimensiones Educación y Económico.

Por otro lado, en el caso de las dimensiones Educación y Vivienda se rechaza la hipótesis nula, el valor de $X^2 (0.95;9) = 16.92$ se encuentra en la región de aceptación de la hipótesis alternativa donde el valor $p=0.006$ es menor a 0.05, podemos concluir que existe diferencia significativa y por lo tanto existe relación entre las dimensiones mencionadas.

Y por último las dimensiones Educación y Salud se rechaza la hipótesis nula, el valor de $X^2 (0.95;9) = 16.92$ se encuentra en la región de aceptación de la hipótesis alternativa donde el valor $p=0.007$ es menor a 0.05, podemos concluir que existe diferencia significativa y por lo tanto existe relación entre las dimensiones de Educación y Salud.

4.4 Resultado del Objetivo específico n° 3

Elaboración de la Red Neuronal Supervisada

Normalización de las variables

Fórmula para normalizar datos

$$Valor_{normalizado} = \frac{X - Valor_{mínimo}}{Valor_{Máximo} - Valor_{mínimo}}$$

Tabla 6

Variables de Entrada Normalizadas

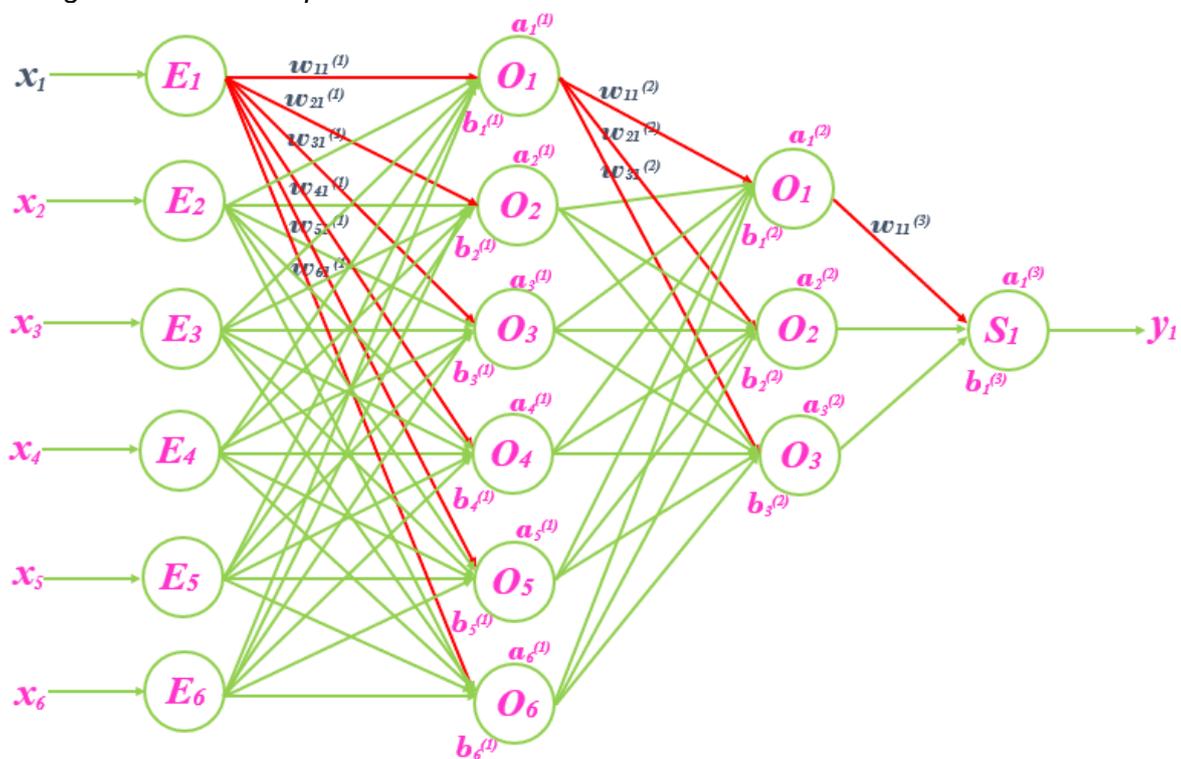
DIMENSIÓN	CATEGORÍA	VALOR ESCALAR	VALOR REAL NORMALIZADO A INGRESAR
MATERIAL VIVIENDA	Noble(Ladrillo o bloque de cemento)	1	1
	Madera	2	0.86
	Piedra con barro	3	0.71
	Piedra o sillar con cal o cemento	4	0.57
	Adobe o tapia	5	0.43
	Esteras	6	0.29
	Quincha (caña con barro)	7	0.14
	Otro material	8	0
CONDICION DE VIVIENDA	Buena	1	1
	En construcción	2	0.75
	Cercado	3	0.5
	Regular	4	0.25
	Mala	5	0
CONSUMO CARNE ROJA	Casi nunca	1	0
	Una vez por semana	2	0.2
	Dos veces por semana	3	0.4
	Tres veces por semana	4	0.6
	Mas de tres veces por semana	5	0.8
	Todos los días de la semana	6	1
CONSUMO PESCADO	Casi nunca	1	0
	Una vez por semana	2	0.2
	Dos veces por semana	3	0.4
	Tres veces por semana	4	0.6
	Mas de tres veces por semana	5	0.8
	Todos los días de la semana	6	1
CONSUMO FRUTA	Casi nunca	1	0
	Una vez por semana	2	0.2
	Dos veces por semana	3	0.4
	Tres veces por semana	4	0.6
	Mas de tres veces por semana	5	0.8
	Todos los días de la semana	6	1
CONSUMO VERDURA	Casi nunca	1	0
	Una vez por semana	2	0.2
	Dos veces por semana	3	0.4
	Tres veces por semana	4	0.6
	Mas de tres veces por semana	5	0.8
	Todos los días de la semana	6	1

		0	0
		1	0.05
		2	0.1
		3	0.15
		4	0.2
		5	0.25
		6	0.3
		7	0.35
		8	0.4
		9	0.45
		10	0.5
		11	0.55
		12	0.6
		13	0.65
		14	0.7
		15	0.75
		16	0.8
		17	0.85
		18	0.9
		19	0.95
		20	1

Construcción de la Red Neuronal Supervisada

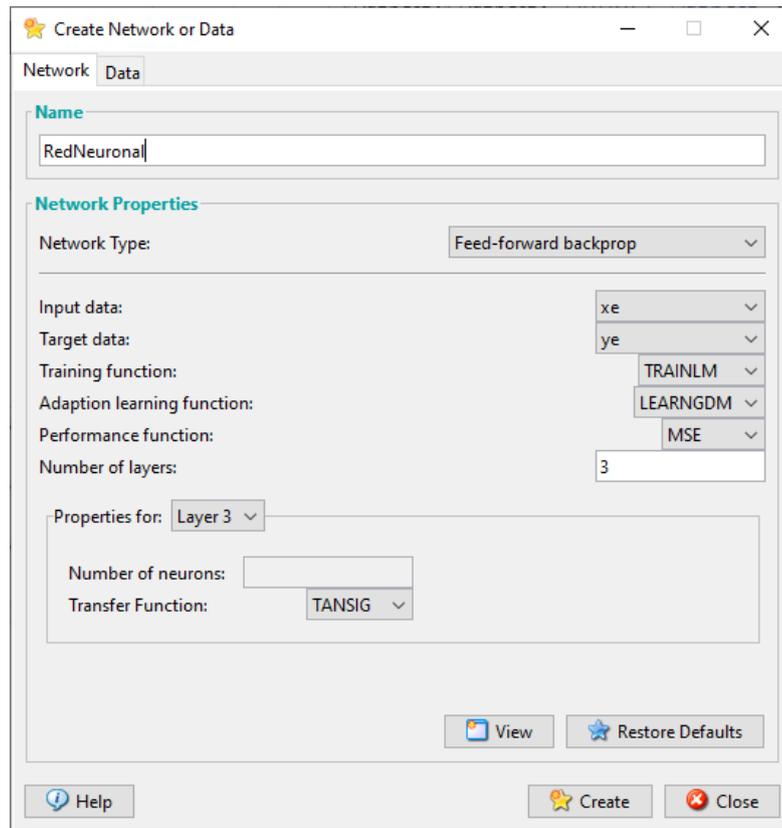
Figura 19

Diagrama de la RNA supervisada



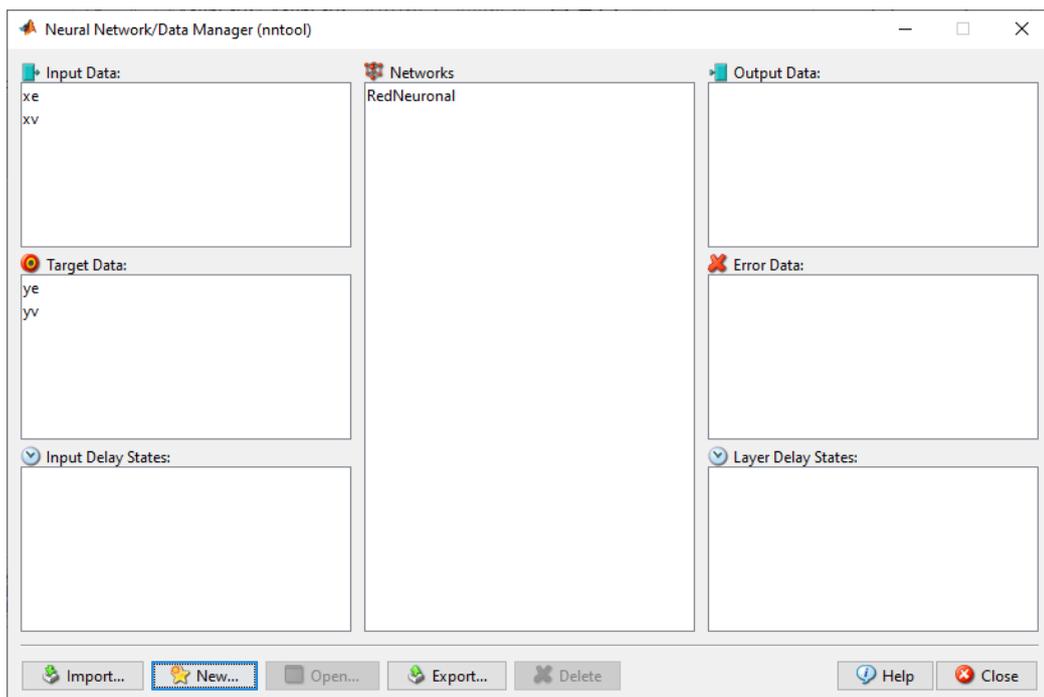
Fuente: Propia

Figura 20
Creando la RNA supervisada



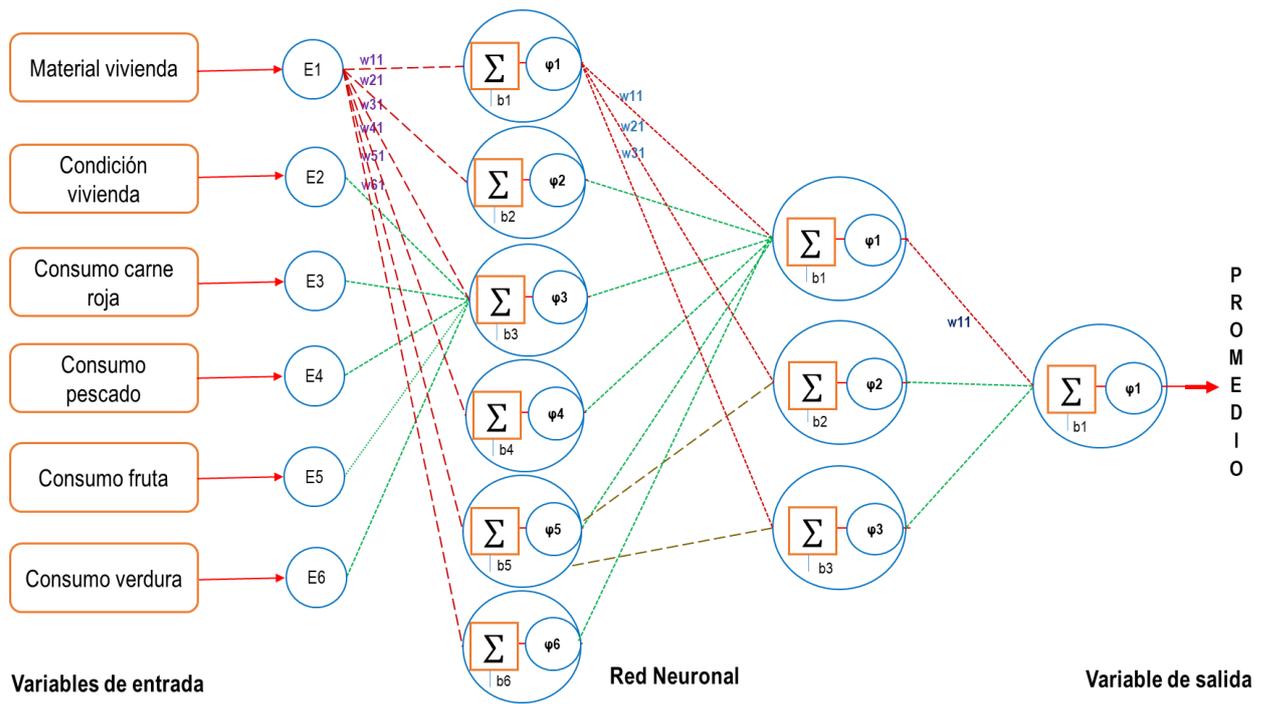
Fuente: Propia

Figura 21
Creando las variables de entrada y salida para la RNA supervisada



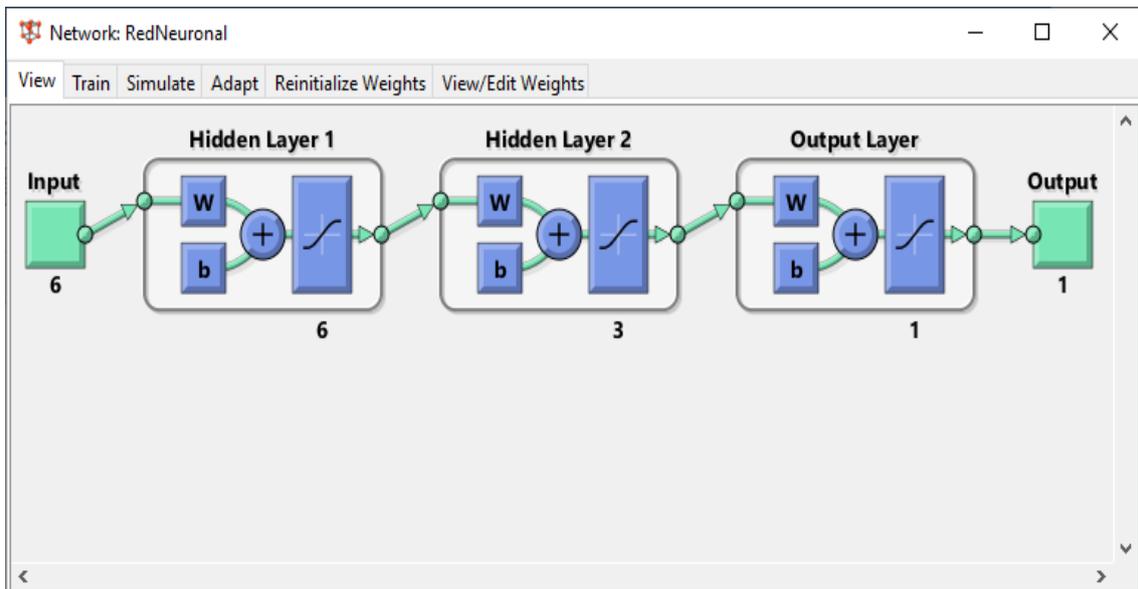
Fuente: Propia

Figura 22
Esquema de la RNA supervisada



Fuente: Propia

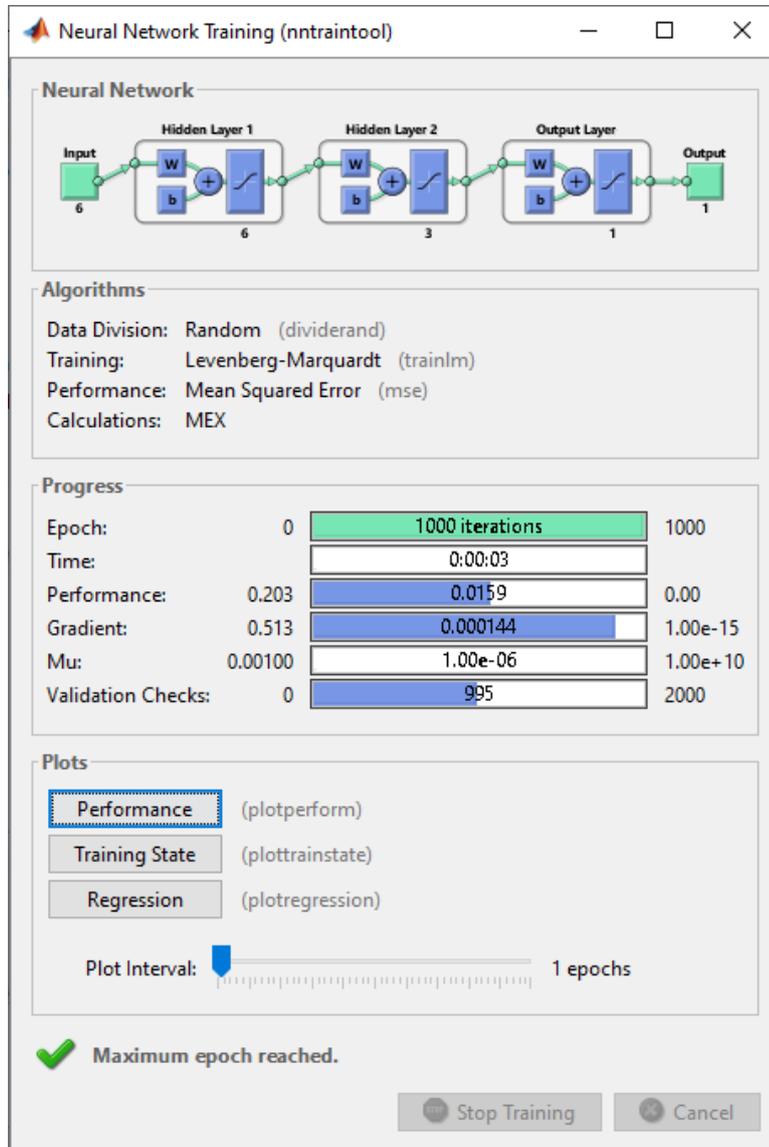
Figura 23
Creando las capas, neuronas y función de activación de la RNA supervisada.



Fuente: Propia

4.5 Resultado del Objetivo específico n° 4

Figura 24
Entrenando la RNA supervisada



Fuente: Propia

Matrices de entrada, de pesos y bias en la primera capa oculta.

$$X = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \end{bmatrix}_{6 \times 1} ; W_1 = \begin{bmatrix} w_{1,1}^{(1)} & w_{1,2}^{(1)} & w_{1,3}^{(1)} & w_{1,4}^{(1)} & w_{1,5}^{(1)} & w_{1,6}^{(1)} \\ w_{2,1}^{(1)} & w_{2,2}^{(1)} & w_{2,3}^{(1)} & w_{2,4}^{(1)} & w_{2,5}^{(1)} & w_{2,6}^{(1)} \\ w_{3,1}^{(1)} & w_{3,2}^{(1)} & w_{3,3}^{(1)} & w_{3,4}^{(1)} & w_{3,5}^{(1)} & w_{3,6}^{(1)} \\ w_{4,1}^{(1)} & w_{4,2}^{(1)} & w_{4,3}^{(1)} & w_{4,4}^{(1)} & w_{4,5}^{(1)} & w_{4,6}^{(1)} \\ w_{5,1}^{(1)} & w_{5,2}^{(1)} & w_{5,3}^{(1)} & w_{5,4}^{(1)} & w_{5,5}^{(1)} & w_{5,6}^{(1)} \\ w_{6,1}^{(1)} & w_{6,2}^{(1)} & w_{6,3}^{(1)} & w_{6,4}^{(1)} & w_{6,5}^{(1)} & w_{6,6}^{(1)} \end{bmatrix}_{6 \times 6} ; b_1 = \begin{bmatrix} b_1^{(1)} \\ b_2^{(1)} \\ b_3^{(1)} \\ b_4^{(1)} \\ b_5^{(1)} \\ b_6^{(1)} \end{bmatrix}_{6 \times 1} ; a_1 = \begin{bmatrix} a_1^{(1)} \\ a_2^{(1)} \\ a_3^{(1)} \\ a_4^{(1)} \\ a_5^{(1)} \\ a_6^{(1)} \end{bmatrix}_{6 \times 1}$$

Aplicación de la función de activación en la primera capa oculta, propagación hacia adelante.

$$v_1 = W_1 * X + b_1 ; a_1 = \varphi(v_1) \text{ salida}$$

$$a_i^{(1)} = \varphi(w_{i1}^{(1)}x_1 + w_{i2}^{(1)}x_2 + w_{i3}^{(1)}x_3 + w_{i4}^{(1)}x_4 + w_{i5}^{(1)}x_5 + w_{i6}^{(1)}x_6 + b_i^{(1)})$$

Para $i = 1, 2, 3, 4, 5, 6$

Función de activación

$$\varphi(x) = \frac{2}{1 + e^{(-2x)}} - 1$$

Matrices de entrada, de pesos y bias en la segunda capa oculta.

$$a_1 = \begin{bmatrix} a_1^{(1)} \\ a_2^{(1)} \\ a_3^{(1)} \\ a_4^{(1)} \\ a_5^{(1)} \\ a_6^{(1)} \end{bmatrix}_{6 \times 1} ; W_2 = \begin{bmatrix} w_{1,1}^{(2)} & w_{1,2}^{(2)} & w_{1,3}^{(2)} & w_{1,4}^{(2)} & w_{1,5}^{(2)} & w_{1,6}^{(2)} \\ w_{2,1}^{(2)} & w_{2,2}^{(2)} & w_{2,3}^{(2)} & w_{2,4}^{(2)} & w_{2,5}^{(2)} & w_{2,6}^{(2)} \\ w_{3,1}^{(2)} & w_{3,2}^{(2)} & w_{3,3}^{(2)} & w_{3,4}^{(2)} & w_{3,5}^{(2)} & w_{3,6}^{(2)} \end{bmatrix}_{3 \times 6} ; b_2 = \begin{bmatrix} b_1^{(2)} \\ b_2^{(2)} \\ b_3^{(2)} \end{bmatrix}_{3 \times 1} ; a_2 = \begin{bmatrix} a_1^{(2)} \\ a_2^{(2)} \\ a_3^{(2)} \end{bmatrix}_{3 \times 1}$$

Aplicación de la función de activación en la segunda capa oculta, propagación hacia adelante.

$$v_2 = W_2 * a_1 + b_2 ; a_2 = \varphi(v_2) \text{ salida}$$

$$a_i^{(2)} = \varphi(w_{i1}^{(2)}a_1^{(1)} + w_{i2}^{(2)}a_2^{(1)} + w_{i3}^{(2)}a_3^{(1)} + w_{i4}^{(2)}a_4^{(1)} + w_{i5}^{(2)}a_5^{(1)} + w_{i6}^{(2)}a_6^{(1)} + b_i^{(2)})$$

Para $i = 1, 2, 3$

Función de activación

$$\varphi(x) = \frac{2}{1 + e^{(-2x)}} - 1$$

Matrices de entrada, de pesos y bías en la capa de salida.

$$a_2 = \begin{bmatrix} a_1^{(2)} \\ a_2^{(2)} \\ a_3^{(2)} \end{bmatrix}_{3 \times 1} ; W_3 = [w_{1,1}^{(3)} \ w_{1,2}^{(3)} \ w_{1,3}^{(3)}]_{1 \times 3} ; b_3 = [b_1^{(3)}]_{1 \times 1} ; y = [a_1^{(3)}]_{1 \times 1}$$

Aplicación de la función de activación en la capa de salida, propagación hacia adelante.

$$v_3 = W_3 * a_2 + b_3 ; y = \varphi(v_3) \text{ salida(promedio)}$$

$$y = a_1^{(3)} = \varphi(w_{11}^{(3)} a_1^{(2)} + w_{12}^{(3)} a_2^{(2)} + w_{13}^{(3)} a_3^{(2)} + b_1^{(3)})$$

Función de activación

$$\varphi(x) = \frac{2}{1 + e^{(-2x)}} - 1$$

El aprendizaje en la Red Neuronal se da por la modificación de los pesos y bías iniciales, mediante el incremento de la razón de cambio de la función error respecto a cada peso y bía, este proceso recibe el nombre de propagación hacia atrás.

Función error(E) y error relativo(e)

$$E = \frac{1}{2} (s_1 - y)^2 ; e = s_1 - y$$

Donde s_1 es el valor deseado y y es el valor obtenido

Propagación hacia atrás en los pesos y bías

$$W_i = W_i + \alpha \cdot e \cdot \frac{\partial y}{\partial W_i} \quad i = 1,2,3, \quad \alpha : \text{tasa de aprendizaje}$$

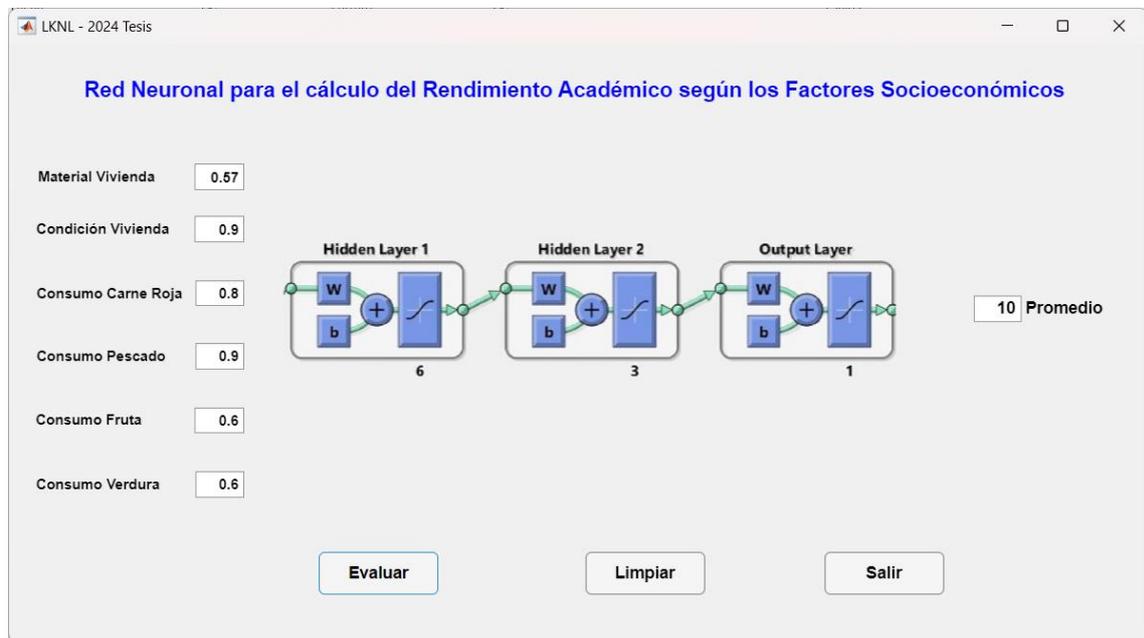
$$b_i^j = b_i^j + \alpha \cdot e \cdot \frac{\partial y}{\partial b_i^j}$$

4.6 Resultado del Objetivo específico n° 5

Evaluación de la Red Neuronal Supervisada

Figura 25

Evaluando la RNA supervisada en el Sistema



Fuente: Propia

Programación

```
function startupFcn(app)
    pp=get(0,'screensize');
    pg=app.ANN.Position;
    xr=pp(3)-pg(3);
    xp=round(xr)/2;
    yr=pp(4)-pg(4);
    yp=round(yr)/2;
    app.ANN.Position=[xp yp pg(3) pg(4)];
    im=imread('ANNe.jpg');
    imshow((im),'parent',app.ImANN);
end

% Button pushed function: Evaluar
function EvaluarPushed(app, event)
```

```
% Entradas a la Red Neuronal
```

```
e1=app.mv.Value;
```

```
e2=app.cvi.Value;
```

```
e3=app.cc.Value;
```

```
e4=app.cp.Value;
```

```
e5=app.cf.Value;
```

```
e6=app.cve.Value;
```

```
x=[e1;e2;e3;e4;e5;e6];
```

```
% Pesos y bias en la primera capa
```

```
w1=[2.6008 1.286 0.83141 1.4608 3.1717 -1.5467;...
```

```
1.7827 1.3105 0.8181 -2.2142 -3.1537 0.61814;...
```

```
-3.8795 -3.9038 -0.14734 -1.9208 -0.7408 4.0731;...
```

```
1.2219 -2.4861 -0.91854 2.6895 4.3644 -1.1973;...
```

```
-0.35468 2.484 -0.32729 -1.3985 1.6623 -0.33673;...
```

```
2.8998 -4.1119 -2.5769 -1.7841 -3.5924 3.1312];
```

```
b1=[-4.1338;-3.5178;1.5516;0.54032;-4.2723;3.7435];
```

```
% Entrada neta y función de activación
```

```
v1=w1*x+b1;
```

```
a1=tansig(v1);
```

```
% Pesos y bias en la segunda capa
```

```
w2=[-1.6692 -0.36629 -3.895 2.6034 0.99869 -2.492;...
```

```
-1.792 -0.019685 -3.7261 2.7411 0.65245 -2.2893;...
```

```
1.3458 -0.46532 -0.26654 0.33899 1.0359 -0.62036];
```

```
b2=[2.5642;1.9253;1.0848];
```

```
% Entrada neta y función de activación
```

```
v2=w2*a1+b2;
```

```
a2=tansig(v2);
```

```
% Pesos y bias en la capa de salida
```

```
w3=[-2.1566 2.1683 -0.0036903];
```

```
b3=[0.47605];

% Entrada neta y función de activación
v3=w3*a2+b3;
y=purelin(v3)

% Valor de salida
app.Promedio.Value=round(20*y)
end

% Button pushed function: Limpiar
function LimpiarButtonPushed(app, event)

app.mv.Value=0;
app.cvi.Value=0;
app.cc.Value=0;
app.cp.Value=0;
app.cf.Value=0;
app.cve.Value=0;
app.Promedio.Value=0;
end

% Button pushed function: Salir
function SalirButtonPushed(app, event)
close(app.ANN)
end
```

Análisis de los errores de la Red Neuronal Supervisada

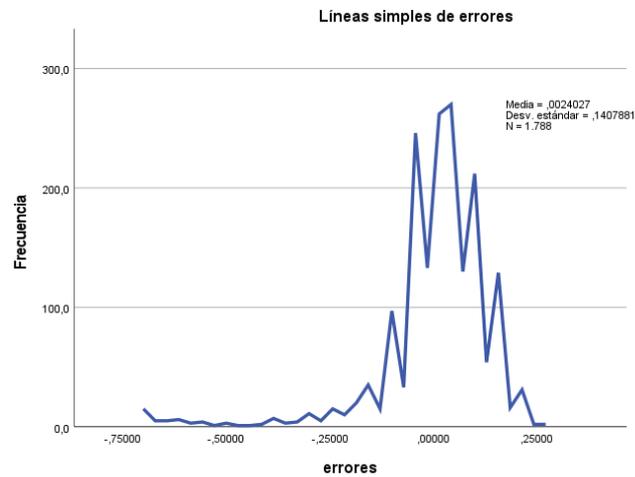
Tabla 7

Medidas estadísticas de los errores de la red neuronal supervisada para determinar el rendimiento académico de los estudiantes de la UNS en función de los factores socioeconómicos en el semestre 2020 I y II.

		Estadístico	
errores	Media	,0024027	
	95% de intervalo de confianza para la media	Límite inferior	-,0041275
		Límite superior	,0089329
	Media recortada al 5%	,0181183	
	Mediana	,0158500	
	Varianza	,020	
	Desviación estándar	,14078810	
	Coeficiente de Variación	58.595	
	Mínimo	-,70340	
	Máximo	,26380	
	Rango	,96720	
	Rango intercuartil	,12840	
	Asimetría	-2,450	
	Curtosis	8,782	

Nota: En las evaluaciones de los errores el valor de la base mediana es de 0.01585, no siendo superada por la media con un valor de 0.0024027 esto significa que existe mucha dispersión entre los errores, esto también lo confirma el coeficiente de variación que es superior de 30% lo que confirma una alta dispersión, la asimetría indica que la tendencia es para la derecha con un acumulación negativa y la curtosis indica que los errores tiene una tendencia elevada, esto lo puede demostrar en la figura 26.

Figura 26
Frecuencia de errores de la RNA supervisada



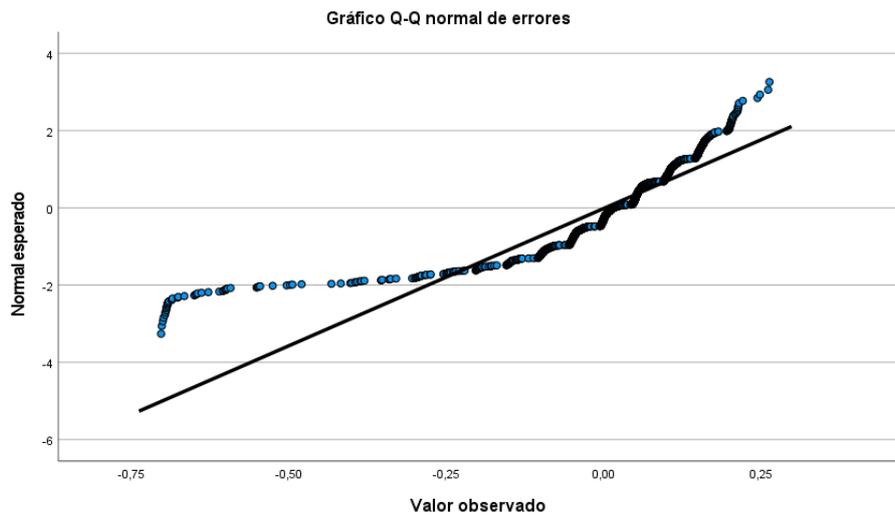
Fuente: Propia

Nota: La prueba de la normalidad verifica cómo se comportan los errores si todos tienen una tendencia normal o no lo que dice Kolmogorov es que el valor de la significancia debe de ser mayor a 0.05 para probar que los datos tienen una tendencia normal, se llega a la conclusión que los datos no tienen una tendencia normal como se puede ver en la figura 26.

Tabla 8
Errores según Kolmogorov

	Kolmogórov-Smirnov			
	Estadístico	gl	Sig.	Estadístico
errores	,174	1788	,000	,787

Figura 27
Significancia de errores de la RNA supervisada



Fuente: Propia

Tabla 9

Validando entradas y salidas de las notas

Notas		
Salida creada		24-JAN-2023 12:17:21
Comentarios		
Entrada	Conjunto de datos activo	ConjuntoDatos0
	Filtro	<ninguno>
	Ponderación	<ninguno>
	Segmentar archivo	<ninguno>
	N de filas en el archivo de datos de trabajo	1788
Manejo de valores perdidos	Definición de perdidos	Los valores perdidos definidos por el usuario se tratan como perdidos.
	Casos utilizados	Las estadísticas se basan en todos los casos con datos válidos.
Sintaxis		FREQUENCIES VARIABLES=errores /ORDER=ANALYSIS.
Recursos	Tiempo de procesador	00:00:00.03
	Tiempo transcurrido	00:00:00.03

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

CONCLUSIONES

La presente investigación nos permitió: Elaborar una Red Neuronal Supervisada del tipo Feed-forward backpropagation para el cálculo del Rendimiento Académico de los estudiantes de la UNS en función de los Factores Socioeconómicos en el semestre 2020 I y II, utilizando el algoritmo de Levenberg – Marquardt para su entrenamiento, del análisis de los errores se concluyó como no significativo y que se puede minimizar adicionando capas y el número de neuronas a la Red Neuronal.

Para ello se logró:

Recopilar información de las fichas socioeconómicas y calificativos del rendimiento académico de un total de 2979 estudiantes de la UNS de los semestres 2020 I y II, y efectuando una depuración de aspectos que no contaban con información completa y significativa.

https://drive.google.com/drive/folders/1BvGsw0EI-4dOo5CwFfppE6pvA5wyl1dn?usp=drive_link

Describir los factores socioeconómicos y la dependencia entre dichos factores mediante una regresión de cada una de ellas con el promedio final en el procesamiento estadístico, determinando una influencia lineal de las dimensiones: Material vivienda, Condición vivienda, Consumo carne roja, Consumo pescado, Consumo fruta, Consumo verdura (variables independientes) sobre las Notas promedios (variable dependiente) de los estudiantes de la Universidad Nacional del Santa (tabla 3 y 4).

Diseñar la red neuronal supervisada del tipo Feed-forward backpropagation (figura 22 y 23), para determinar la incidencia de los factores socioeconómicos en el rendimiento académico de los estudiantes con 6 variables de entrada que representan a los factores socioeconómicos, 2 capas ocultas con 6 y 3 neuronas respectivamente, y una capa de salida con 1 neurona que muestra el rendimiento académico de los estudiantes. Su diseño corresponde al tipo descriptivo proposicional, considerando los datos históricos y la construcción de una Red neuronal backpropagation que predice los resultados y compara con los obtenidos en los datos históricos.

Entrenar la red neuronal supervisada (figura 24) con 1,787 datos normalizados en un rango de [0 - 1], y que representa el 60 % de datos de la muestra, a través del algoritmo de Levenberg – Marquardt, y con funciones de activación del tipo tansig (figura 6).

Evaluar la red neuronal supervisada con 1192 datos normalizados en un rango de [0 - 1] (figura 25), y que representa el 40 % de datos de la muestra, para determinar el rendimiento académico de los estudiantes de la UNS, con las matrices de pesos y bias obtenidas en la etapa del entrenamiento.

RECOMENDACIONES

Incrementar el número de capas y neuronas en la red neuronal para mejorar su capacidad de aprendizaje y generalización. Esto puede ayudar a capturar relaciones más complejas entre los factores socioeconómicos y el rendimiento académico de los estudiantes.

Experimentar con diferentes funciones de activación en las capas ocultas de la red neuronal. La elección de la función de activación puede afectar significativamente el rendimiento y la capacidad de convergencia de la red.

Implementar técnicas de regularización, como la regularización L1 o L2, para evitar el sobreajuste de la red neuronal a los datos de entrenamiento. Además, considera la optimización de hiperparámetros, como la tasa de aprendizaje y el tamaño del lote, para mejorar el rendimiento del modelo.

No limitar a una sola arquitectura de red neuronal. Explora otras arquitecturas, como redes neuronales convolucionales o recurrentes, si crees que pueden capturar mejor las relaciones en tus datos.

Considerar la posibilidad de recopilar datos adicionales que puedan influir en el rendimiento académico de los estudiantes, como el nivel de participación en actividades extracurriculares, el entorno familiar y las condiciones emocionales. Estos datos adicionales pueden mejorar la capacidad predictiva del modelo.

REFERENCIAS BIBLIOGRÁFICAS

- Basogain Olabe, X. (1998). *Redes Neuronales Artificiales y sus Aplicaciones*. Madrid: Publicaciones de la Escuela de Ingenieros.
- Blake, P., & Wadhwa, D. (12 de 2020). *Crupo Banco Mundial*. Obtenido de Banco Mundial Blogs: <https://blogs.worldbank.org/es/voices/resumen-anual-2020-el-impacto-de-la-covid-19-coronavirus-en-12-graficos>
- Carrión Pérez, E. (2007). Validación de Características al Ingreso como Predictores del Rendimiento Académico en la Carrera de Medicina. *Revista Cubana de Educación Médica Superior*, 1(16).
- Castejón, J., & Pérez, A. (1998). Un Modelo Causal - Explicativo de las variables Psicosociales en el Rendimiento Académico. *Revista Bordón*, 50(2), 171-185.
- Choi de Mendizábal, Á. B. (2018). *Fundación "La Caixa"*. Obtenido de El Observatorio Social: <https://observatoriosociallacaixa.org/-/desigualdades-socioeconomicas-y-rendimiento-academico>
- Durón, T., & Oropeza, T. (1999). *Análisis Predictivo a partir de la Interacción Familiar y Escolar de Estudiantes de Nivel Superior*. Universidad Nacional Autónoma de México, México.
- Espada, M., Rocu, P., Navia, J., & Gómez, M. (2020). Rendimiento Académico y Satisfacción de los Estudiantes Universitarios hacia el Método Flipped Classroom. *Profesorado, Revista del Currículum y Formación del Profesorado*, 116-135.
- Gallo, C. (2021). Estrategias didácticas y el rendimiento académico en los estudiantes de la Escuela de Ingeniería. *Revista Peruana de Educación*, 37-48.
- Gonzales, E., & Evaristo, I. (2021). Rendimiento académico y deserción de estudiantes universitarios de un curso en modalidad virtual y presencial. *Revista Iberoamericana de Educación a Distancia*, 189-198. Obtenido de <https://www.redalyc.org/articulo.oa?id=331466109011>
- Pérez Luño, A., Ramón Jerónimo, J., & Sánchez Vásquez, J. (2000). *Análisis Exploratorio de las Variables que Condicionan el Rendimiento Académico*. Sevilla, España: Universidad Pablo de Olavide.
- Quintana, M., Flores, J., Lazcano, S., & Landassuri, V. (2018). Ensamble de Clasificadores para Determinar el Perfil Académico del Estudiante usando Árboles de Decisión y Redes Neuronales. *ResearchGate*, 255-267.

- Rodríguez, S., Fita, S., & Torrado, M. (2004). El Rendimiento Académico en la Transición Secundaria-Universidad. *Revista de Educación. Temas Actuales de Enseñanza*, 334.
- Romero, J., Aznar, I., Hinojo, F., & Gómez, G. (2020). Uso de los dispositivos móviles en educación superior: relación con el rendimiento académico y la autorregulación del aprendizaje. *Revista Complutense de Educación*, 327-335.
- Torres, S., Aldana, M. P., & Piedra, L. (2016). Red Neuronal Multicapa para la Evaluación de Competencias Laborales. *Revista Cubana de Ciencias Informáticas*, 210-223.
- Valle Arias, A., González Cabanach, R., Núñez Pérez, J., & Martínez Rodríguez, S. (1999). Un Modelo Causal sobre los Determinantes cognitivo - Motivacionales del Rendimiento Académico. *Revista de Psicología General Aplicada*, 52(4), 499-519.
- Vélez Van, M., & Roa, N. (2005). Factors Associated with Academic Performance in Medical Students. *PSIC. Educación Médica*, 1-10.
- Vemuri, V. (1990). *Artificial Neural Networks: Theoretical Concepts* Computer Society Press. Los Alamitos C.A.
- Viñuela, P., & León, I. (2004). *Redes Neuronales Artificiales: Un Enfoque Práctico*. Madrid: Editorial Pearson Prentice Hall.

Anexo N°01: FICHA SOCIOECONÓMICA

UNIVERSIDAD NACIONAL DEL SANTA		UNIDAD DE DESARROLLO, EVALUACION Y MANTENIMIENTO DE SISTEMAS DE INFORMACION	
Ficha Socioeconómica del Estudiante: Oficina Central de Bienestar Universitario		Bienvenido: Cerrar Sesión	
Página Principal Debe Guardar cada Aspecto, después de haber llenado sus datos			
Aspecto Personal Aspecto Familiar Aspecto Económico Aspecto Vivienda Aspecto Académico Aspecto Conectividad Aspecto Salud Aspecto Emergencia			
Modalidad de Ingreso:			
DNI:			
Fecha de nacimiento:	<input type="text"/>	Edad:	<input type="text"/>
Lugar de Nacimiento:	ANCASH / SANTA / CHIMBOTE		
Sexo:	<input type="radio"/> Varón <input checked="" type="radio"/> Mujer		
Estado Civil:	<input checked="" type="radio"/> Soltero <input type="radio"/> Casado <input type="radio"/> Conviviente <input type="radio"/> Viudo <input type="radio"/> Divorciado <input type="radio"/> Separados <input type="radio"/> Madre/Padre Soltero(a)		
Teléfono Fijo:	<input type="text"/>		
Teléfono Móvil:	<input type="text"/>		
Correo Electrónico:	<input type="text"/>		
Grupo Sanguíneo:	<input checked="" type="radio"/> No Precisa <input type="radio"/> A+ <input type="radio"/> A- <input type="radio"/> B+ <input type="radio"/> B- <input type="radio"/> AB+ <input type="radio"/> AB- <input type="radio"/> O+ <input type="radio"/> O-		
Lugar de Residencia:	<input type="text"/> <input type="text"/> <input type="text"/>		
	Dirección:	<input type="text"/>	
	Referencia de la Dirección:	<input type="text"/>	

Figura N°01. Aspecto personal

[Página Principal](#)

Debe Guardar cada Aspecto, después de haber llenado sus datos

[Aspecto Personal](#)
[Aspecto Familiar](#)
[Aspecto Económico](#)
[Aspecto Vivienda](#)
[Aspecto Académico](#)
[Aspecto Conectividad](#)
[Aspecto Salud](#)
[Aspecto Emergencia](#)

[+ Añadir](#)

Apellidos y Nombres	Fecha de Nacimiento	Edad	Estado Civil	Grado Instrucción	Parentesco	Ocupación	Operacion
		59 años	Casado	Secundaria Completa	Madre	Ninguna.	 
		70 años	Casado	Secundaria Completa	Padre	Ninguna.	 
		36 años	Soltero	Secundaria Completa	Hermano(a)	Ninguna.	 
		34 años	Soltero	Secundaria Completa	Hermano(a)	Ninguna.	 
		40 años	Soltero	Superior Completa	Hermano(a)	Ninguna.	 
		39 años	Soltero	Secundaria Completa	Hermano(a)	Ninguna.	 

[Guardar Aspecto](#)[← Anterior](#)[→ Siguiente](#)

Figura N°02. Aspecto familiar

[Página Principal](#)

Debe Guardar cada Aspecto, después de haber llenado sus datos

- [Aspecto Personal](#)
[Aspecto Familiar](#)
[Aspecto Económico](#)
[Aspecto Vivienda](#)
[Aspecto Académico](#)
[Aspecto Conectividad](#)
[Aspecto Salud](#)
[Aspecto Emergencia](#)

Ingrese Datos Económicos	
¿De quién dependes económicamente?	<input type="radio"/> De Ambos Padres <input type="radio"/> Del Padre <input type="radio"/> De la Madre <input type="radio"/> De Los Hermanos <input type="radio"/> De Familiares/Parientes <input type="radio"/> Autosostenimiento <input type="radio"/> Esposo(a) <input type="radio"/> Apoderado <input type="radio"/> Padrastro
Condición del trabajo del responsable de Familia:	<input type="radio"/> Trabajo Dependiente <input type="radio"/> Trabajo Independiente <input type="radio"/> Trabajo Eventual <input type="radio"/> Jubilado / Cesante
Centro de trabajo del responsable:	<input type="text"/>
Ocupación del responsable:	<input type="text"/>
Trabaja Usted:	<input type="radio"/> Si, a tiempo completo <input type="radio"/> Si, a tiempo parcial <input type="radio"/> Si, ocasionalmente <input type="radio"/> No, no trabajo
Condición del trabajo del estudiante:	<input type="radio"/> Trabajo Dependiente <input type="radio"/> Trabajo Independiente <input type="radio"/> Trabajo Eventual <input type="radio"/> Jubilado / Cesante
Centro de trabajo del estudiante:	<input type="text"/>
Ocupación del estudiante:	<input type="text"/>
Ingreso Familiar:	Del Padre: <input type="text"/> Soles
	De la Madre: <input type="text"/> Soles
	Del Apoderado: <input type="text"/> Soles
	Del Estudiante: <input type="text"/> Soles
	Otros: <input type="text"/> Soles
Ingreso Total Familiar:	0 Soles

 **Guardar Aspecto**

[← Anterior](#)

[→ Siguiente](#)

Figura N°03. Aspecto económico

UNIVERSIDAD NACIONAL DEL SANTA		UNIDAD DE DESARROLLO, EVALUACION Y MANTENIMIENTO DE SISTEMAS DE INFORMACION	
Ficha Socioeconómica del Estudiante: Oficina Central de Bienestar Universitario		Bienvenido: Cerrar Sesión	
Vivienda Procedencia (Lugar de donde procede el estudiante)			
Ubicación de la Vivienda:	<input checked="" type="radio"/> Urbano <input type="radio"/> Rural <input type="radio"/> Aledaño		
Zona de la Vivienda:	<input type="radio"/> NINGUNO <input type="radio"/> Urbanización <input checked="" type="radio"/> Pueblo Joven <input type="radio"/> Asentamiento Humano <input type="radio"/> Invasión <input type="radio"/> Otro		
Nombre de la zona de la vivienda:	<input type="text"/>		
Tipo de Vivienda:	<input checked="" type="radio"/> Independiente <input type="radio"/> Departamento <input type="radio"/> Quinta <input type="radio"/> Callejón, Solar o Corralón <input type="radio"/> Otro <input type="radio"/> Pensión <input type="radio"/> Cuarto <input type="radio"/> Condominio		
Tenencia de la Vivienda:	<input checked="" type="radio"/> Propia, totalmente pagada <input type="radio"/> Alquilada <input type="radio"/> Cedida por Familia <input type="radio"/> Cedida por el centro de trabajo <input type="radio"/> Otro <input type="radio"/> Cedida por otro hogar o institución <input type="radio"/> Propia, por invasión <input type="radio"/> Propia, pagándola a plazos		
Material de la Vivienda:	<input checked="" type="radio"/> Noble(Ladrillo o bloque de cemento) <input type="radio"/> Madera <input type="radio"/> Esteras <input type="radio"/> Quincha (caña con barro) <input type="radio"/> Otro material <input type="radio"/> Adobe o tapia <input type="radio"/> Piedra o sillar con cal o cemento <input type="radio"/> Piedra con barro		
Condición de la Vivienda:	<input checked="" type="radio"/> Buena <input type="radio"/> Regular <input type="radio"/> Mala <input type="radio"/> En Construcción <input type="radio"/> Cercado		
Número de divisiones de la Vivienda:	<input type="text" value="6"/>		
Servicios de la Vivienda de procedencia:	<input checked="" type="checkbox"/> Luz <input checked="" type="checkbox"/> Agua <input checked="" type="checkbox"/> Desague <input checked="" type="checkbox"/> Teléfono <input type="checkbox"/> Internet <input type="checkbox"/> Cable <input type="checkbox"/> Otro		
Bienes de la Vivienda de procedencia:	<input checked="" type="checkbox"/> Casa <input type="checkbox"/> Terreno adicional a la vivienda <input type="checkbox"/> Equipo de Sonido <input checked="" type="checkbox"/> TV <input type="checkbox"/> VH / DVD <input type="checkbox"/> Videgrabadora/Filmadora <input type="checkbox"/> Computadora/laptop/Netbook <input type="checkbox"/> Vehículo(Mototaxi, automovil, camioneta, camión) <input type="checkbox"/> Cocina a Kerosene <input type="checkbox"/> Cocina a Gas <input type="checkbox"/> Cocina Eléctrica <input type="checkbox"/> Horno Microondas <input type="checkbox"/> Aspiradora <input type="checkbox"/> Videojuego/PlayStation <input type="checkbox"/> Lavadora <input type="checkbox"/> Refrigeradora		
<input type="button" value="Guardar Aspecto"/>			
<input type="button" value="← Anterior"/>		<input type="button" value="→ Siguiente"/>	

Figura N°04. Aspecto Vivienda

[Página Principal](#)

Debe Guardar cada Aspecto, después de haber llenado sus datos

[Aspecto Personal](#)
[Aspecto Familiar](#)
[Aspecto Económico](#)
[Aspecto Vivienda](#)
[Aspecto Académico](#)
[Aspecto Conectividad](#)
[Aspecto Salud](#)
[Aspecto Emergencia](#)

Ingrese Datos Académicos	
Colegio en que terminaste tus estudios secundarios:	NINGUNO <input type="checkbox"/> Ingrese Otro Colegio en caso de Error
Tipo de Colegio	<input type="radio"/> Nacional <input type="radio"/> Particular
Año en que terminaste tus estudios secundarios:	<input type="text" value="0"/>
Numero de veces que postulaste:	<input type="text"/>
Por que decidiste estudiar en la UNS:	<input type="radio"/> Prestigio <input type="radio"/> Tradición Familiar <input type="radio"/> Gratuidad <input type="radio"/> Cerca de Casa <input type="radio"/> Estudian Hermanos <input type="radio"/> Otro
Porque elegiste la carrera que estudias:	<input type="radio"/> Vocacion <input type="radio"/> Tradicion familiar <input type="radio"/> Facil <input type="radio"/> Carrera del Momento <input type="radio"/> Presion Familiar <input type="radio"/> Rentable <input type="radio"/> Otro
Tipo de estudios realizado:	<input type="radio"/> Ninguno <input type="radio"/> Carrera Corta de 1 Año <input type="radio"/> Instituto Incompleto <input type="radio"/> Otros Estudios
Interumpiste tus estudios universitarios:	<input checked="" type="radio"/> Si <input type="radio"/> No
Por que razón interrumpiste tus estudios:	<input type="radio"/> Recursos Económicos <input type="radio"/> Trabajo <input type="radio"/> Cambio de Domicilio <input type="radio"/> Paternidad/Maternidad <input type="radio"/> Enfermedad <input type="radio"/> Viaje <input type="radio"/> Falta Interés
Tiempo de interrupcion de estudios:	<input type="radio"/> 1 Ciclo <input type="radio"/> 2 Ciclos <input type="radio"/> 3 Ciclos <input type="radio"/> Más de tres Ciclos

Recursos de apoyo:	<input type="radio"/> Transparencias <input type="radio"/> Multimedia <input type="radio"/> Papelógrafo <input type="radio"/> Pizarra, plumón y Tiza <input type="radio"/> Slides <input type="radio"/> Otros					
Técnica de estudios:	<input type="radio"/> Expositiva <input type="radio"/> Taller <input type="radio"/> Seminario <input type="radio"/> Conferencia <input type="radio"/> Demostración Experimental <input type="radio"/> Otros					
Idioma que conoces:	<input type="button" value="+ Añadir"/>					
	<table border="1"><thead><tr><th>Idioma</th><th>Nivel</th><th>Operación</th></tr></thead><tbody><tr><td colspan="3">No records found.</td></tr></tbody></table>	Idioma	Nivel	Operación	No records found.	
Idioma	Nivel	Operación				
No records found.						

Figura N°05. Aspecto Académico

[Página Principal](#)

Debe Guardar cada Aspecto, después de haber llenado sus datos

Ingrese Datos de Conectividad	
Dispositivo con el cual te conectas con mayor frecuencia a internet:	<input type="radio"/> Laptop <input type="radio"/> Computadora de Escritorio (PC) <input type="radio"/> Teléfono Celular <input type="radio"/> Tablet <input type="radio"/> SmartTV <input type="radio"/> Otros
Tiempo al día que te conectas a internet:	<input type="radio"/> Menos de 1 hora <input type="radio"/> De 1 a 2 horas <input type="radio"/> De 2 a 3 horas <input type="radio"/> De 3 a 5 horas <input type="radio"/> De 5 a 8 horas <input type="radio"/> Más de 8 horas
Horario del día en el que utilizas internet con mas frecuencia:	<input type="radio"/> Mañana <input type="radio"/> Tarde <input type="radio"/> Noche
Desde que lugar te conectas con mayor frecuencia a internet:	<input type="radio"/> Casa <input type="radio"/> Cabina <input type="radio"/> Otros
<input type="button" value="Guardar Aspecto"/>	
<input type="button" value="← Anterior"/> <input type="button" value="→ Siguiente"/>	

Figura N°06. Aspecto Conectividad

Aspecto Personal Aspecto Familiar Aspecto Económico Aspecto Vivienda Aspecto Académico Aspecto Conectividad **Aspecto Salud** Aspecto Emergencia

Ingrese Datos sobre Salud	
¿Donde almuerzas habitualmente?:	<input type="radio"/> Hogar <input type="radio"/> Amigos <input type="radio"/> Familia <input type="radio"/> Pensión <input type="radio"/> Restaurant Público <input type="radio"/> Comedor Universitario <input type="radio"/> Comedor Popular <input type="radio"/> Cafetín Campus Universitario <input type="radio"/> Otro
Tienes enfermedad aguda:	<input type="text" value="NINGUNA"/>
Tienes discapacidad:	<input type="text" value="Ninguna Discapacidad"/>
¿Cuenta Ud. con algún tipo de seguro?:	<input type="radio"/> SI <input type="radio"/> NO
Nombre del tipo de seguro:	<input type="text" value="NINGUNO"/>
Frecuencia de consumo de carnes rojas:	<input type="radio"/> una vez por semana <input type="radio"/> dos veces por semana <input type="radio"/> tres veces por semana <input type="radio"/> mas de tres veces por semana <input type="radio"/> todos los días de la semana <input type="radio"/> casi nunca <input type="radio"/> No consumo <input type="radio"/> No realizo
Frecuencia de consumo de pescado:	<input type="radio"/> una vez por semana <input type="radio"/> dos veces por semana <input type="radio"/> tres veces por semana <input type="radio"/> mas de tres veces por semana <input type="radio"/> todos los días de la semana <input type="radio"/> casi nunca <input type="radio"/> No consumo <input type="radio"/> No realizo
Frecuencia de consumo de frutas:	<input type="radio"/> una vez por semana <input type="radio"/> dos veces por semana <input type="radio"/> tres veces por semana <input type="radio"/> mas de tres veces por semana <input type="radio"/> todos los días de la semana <input type="radio"/> casi nunca <input type="radio"/> No consumo <input type="radio"/> No realizo
Frecuencia de consumo de verduras:	<input type="radio"/> una vez por semana <input type="radio"/> dos veces por semana <input type="radio"/> tres veces por semana <input type="radio"/> mas de tres veces por semana <input type="radio"/> todos los días de la semana <input type="radio"/> casi nunca <input type="radio"/> No consumo <input type="radio"/> No realizo
Frecuencia de realizar ejercicio físico:	<input type="radio"/> una vez por semana <input type="radio"/> dos veces por semana <input type="radio"/> tres veces por semana <input type="radio"/> mas de tres veces por semana <input type="radio"/> todos los días de la semana <input type="radio"/> casi nunca <input type="radio"/> No consumo <input type="radio"/> No realizo
Deportes que practicas:	<input type="checkbox"/> Ninguno <input checked="" type="checkbox"/> Foot Ball <input type="checkbox"/> Voley Ball <input type="checkbox"/> Basquet Ball <input type="checkbox"/> Natación <input type="checkbox"/> Atletismo <input type="checkbox"/> Boxeo <input type="checkbox"/> Judo <input type="checkbox"/> Gimnasia <input type="checkbox"/> Ciclismo <input type="checkbox"/> Artes Marciales <input type="checkbox"/> Ajedrez <input type="checkbox"/> Aeróbicos <input type="checkbox"/> Yoga <input type="checkbox"/> Otro
Actividades que desarrollas:	<input type="checkbox"/> Ninguna <input checked="" type="checkbox"/> Dibujo ó Pintura <input type="checkbox"/> Poesía <input type="checkbox"/> Decoración <input type="checkbox"/> Lectura <input type="checkbox"/> Fotografía <input type="checkbox"/> Escritor <input type="checkbox"/> Mecánica <input type="checkbox"/> Teatro <input type="checkbox"/> Danza <input type="checkbox"/> Ballet <input type="checkbox"/> Música <input type="checkbox"/> Carpintería <input type="checkbox"/> Artesanía <input type="checkbox"/> Sastrería <input type="checkbox"/> Costura <input type="checkbox"/> Oratoria <input type="checkbox"/> Canto <input type="checkbox"/> Manualidad <input type="checkbox"/> Repostería <input type="checkbox"/> Tejido <input type="checkbox"/> Pintura en tela <input type="checkbox"/> Corte y confección <input type="checkbox"/> Corte de cabello <input type="checkbox"/> Cosmetología <input type="checkbox"/> Manicure <input type="checkbox"/> Dibujo <input type="checkbox"/> Instrumento musical <input type="checkbox"/> Paseo al aire libre <input type="checkbox"/> Paseo a la playa <input type="checkbox"/> Caminata <input type="checkbox"/> Paseo al campo <input type="checkbox"/> Viajes Turísticos <input type="checkbox"/> Festivales deportivos <input type="checkbox"/> Culturales <input type="checkbox"/> Natación <input type="checkbox"/> Bailoterapia <input type="checkbox"/> Aeróbicos <input type="checkbox"/> Taebo <input type="checkbox"/> Yoga <input type="checkbox"/> Gimnasia <input type="checkbox"/> Otro <input type="checkbox"/> Otro <input type="checkbox"/> Andar en bicicleta <input type="checkbox"/> Otro <input type="checkbox"/> Otro <input type="checkbox"/> Ninguna <input type="checkbox"/> Ninguna <input type="checkbox"/> Ninguna <input type="checkbox"/> Ninguna
Que Religión profesa:	<input type="text" value="ninguna religión"/>

Figura N°07. Aspecto Salud

Anexo N°02: BASE DE DATOS DE ALUMNOS UNS SEMESTRE 2020-I Y II

VE-1: MATERIAL VIVIENDA	VE-2: CONDICION DE VIVIENDA	VE-3: CONSUMO CARNE ROJA	VE-4: CONSUMO PESCADO	VE-5: CONSUMO FRUTA	VE-6: CONSUMO VERDURA	VS-7: PROMEDIO FINAL
1	0.25	0	0.4	0	0	0.45
1	0.25	1	1	0	0	0.7
1	0.75	0	0.2	0.4	0.8	0.65
1	0.25	1	1	0	0.8	0.7
1	0.75	0.6	0.4	0.2	0.2	0.75
1	0.25	0.2	0	0.6	0.6	0.75
1	1	1	0.2	0.2	0.6	0.75
1	0.25	0.6	1	0	0.2	0.85
1	0	0.2	0.8	0.2	0.2	0.7

La data completa en el siguiente enlace:

https://drive.google.com/drive/folders/1BvGsw0EI-4dOo5CwFfppE6pvA5wyl1dn?usp=drive_link