

UNIVERSIDAD NACIONAL DEL SANTA
ESCUELA DE POSGRADO
Programa de Doctorado en Matemática



UNS
ESCUELA DE
POSGRADO

**“Cambios demográficos en la población de Lima Metropolitana,
mediante una red neuronal supervisada, durante el período
2020 de desarrollo de la pandemia covid-19 y su proyección
2021-2025”**

**Tesis para optar el grado académico de
Doctor en Matemática**

Autor:

Mg. Nuñez Ramirez, Luis Miguel

Asesor:

Dr. Morales Marchena, Herón Juan
Código ORCID: 0000-0002-5394-0958
DNI. N° 32837715

Linea de Investigación
Ciencias Naturales

Nuevo Chimbote - PERÚ
2023



UNS
ESCUELA DE
POSGRADO

CONSTANCIA DE ASESORAMIENTO DE LA TESIS DOCTORAL

Yo, MORALES MARCHENA HERÓN JUAN, mediante la presente, certifico mi asesoramiento de la tesis doctoral titulada:

CAMBIOS DEMOGRÁFICOS EN LA POBLACIÓN DE LIMA METROPOLITANA, MEDIANTE UNA RED NEURONAL SUPERVISADA, DURANTE EL PERÍODO 2020, EN DESARROLLO DE LA PANDEMIA COVID-19 Y SU PROYECCIÓN 2021-2025, elaborado por el magister LUIS MIGUEL NUÑEZ RAMIREZ para obtener el grado académico de Doctor en MATEMÁTICA en la escuela de posgrado de la Universidad Nacional del Santa.

Nuevo Chimbote, 03 de agosto de 2023

Dr. Morales Marchena, Herón Juan

ASESOR

Código ORCID: 0000-0002-5394-0958

DNI N° 32837715



UNS
ESCUELA DE
POSGRADO

CONFORMIDAD DEL JURADO EVALUADOR

**CAMBIOS DEMOGRÁFICOS EN LA POBLACIÓN DE LIMA METROPOLITANA,
MEDIANTE UNA RED NEURONAL SUPERVISADA, DURANTE EL PERÍODO
2020, EN DESARROLLO DE LA PANDEMIA COVID-19 Y SU PROYECCIÓN 2021-
2025**

TESIS PARA OPTAR EL GRADO ACADÉMICO DE
DOCTOR EN MATEMÁTICA

Revisado y aprobado por el jurado evaluador:

CEDRÓN LEÓN, ERNESTO ANTONIO

PRESIDENTE

Código ORCID: 0000-0002-3198-831X

DNI N° 32966495

MOORE FLORES, TEODORO

SECRETARIO

Código ORCID: 0000-0002-1755-3459

DNI N° 32763522

Dr. MORALES MARCHENA, HERÓN JUAN

VOCAL

Código ORCID: 0000-0002-5394-0958

DNI N° 32837715



UNS
ESCUOLA DE
POSGRADO

ACTA DE EVALUACIÓN DE SUSTENTACIÓN DE TESIS

A los tres días del mes de agosto del año 2023, siendo las 12:00 horas, en el aula multimedia N° P-2 de la Escuela de Posgrado de la Universidad Nacional del Santa, se reunieron los miembros del Jurado Evaluador conformado por los docentes: el Dr. Ernesto Cedrón (Presidente), el Dr. Teodoro Moore Flores (Secretario), Dr. Herón Juan Morales Marchena (Vocal), designados mediante Resolución Directoral N° 147-2023-EPG-UNS de fecha 27.06.2023, con la finalidad de evaluar la tesis titulada: **"CAMBIOS DEMOGRÁFICOS EN LA POBLACIÓN DE LIMA METROPOLITANA, MEDIANTE UNA RED NEURONAL SUPERVISADA, DURANTE EL PERÍODO 2020 DE DESARROLLO DE LA PANDEMIA COVID-19 Y SU PROYECCIÓN 2021-2025"**; presentado por el tesista Luis Miguel Nuñez Ramírez, egresado del programa de Doctorado en Matemática.

Sustentación autorizada mediante Resolución Directoral N° 182-2023-EPG-UNS de fecha 01 de agosto de 2023.

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: Dieciocho 18.

Siendo las 13:40 horas del mismo día se da por finalizado el acto académico, firmando la presente acta en señal de conformidad.


Dr. Ernesto Antonio Cedrón León
Presidente


Dr. Teodoro Moore Flores
Secretario


Dr. Herón Juan Morales Marchena
Vocal

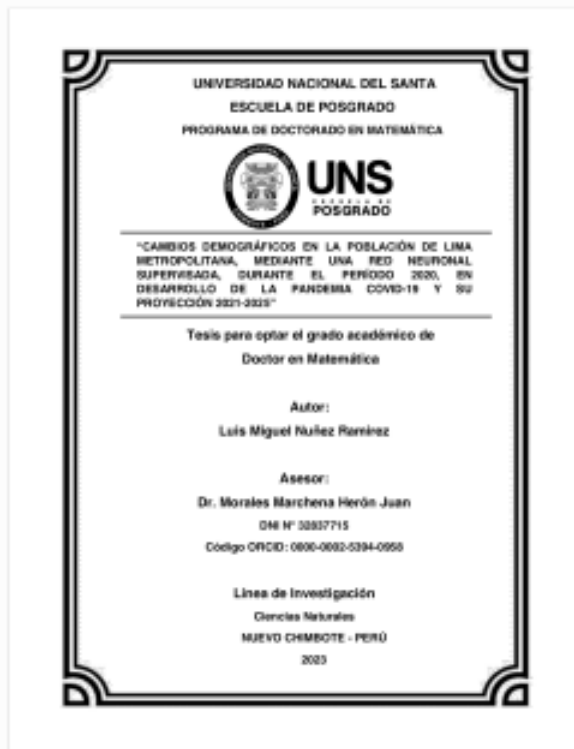


Recibo digital

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: Luis Nuñez
Título del ejercicio: Tesis final
Título de la entrega: Tesis corregida
Nombre del archivo: TESIS_FINAL_CORREGIDA_-_LUIS_MIGUEL_NU_EZ_RAMIREZ_20...
Tamaño del archivo: 4.38M
Total páginas: 163
Total de palabras: 29,705
Total de caracteres: 139,492
Fecha de entrega: 19-ago.-2023 03:21p. m. (UTC-0500)
Identificador de la entre... 2148038473



Tesis corregida

INFORME DE ORIGINALIDAD

14%	14%	5%	5%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	www.scielo.org.co Fuente de Internet	1%
2	hdl.handle.net Fuente de Internet	1%
3	www.itson.mx Fuente de Internet	1%
4	documentop.com Fuente de Internet	1%
5	repositorio.lamolina.edu.pe Fuente de Internet	1%
6	repositorio.uns.edu.pe Fuente de Internet	1%
7	bdigital.unal.edu.co Fuente de Internet	1%
8	fich.unl.edu.ar Fuente de Internet	1%
9	repositorio.urp.edu.pe Fuente de Internet	<1%

DEDICATORIA

A Dios, por permitirme seguir con salud y vida.

A mis padres Luis Alfonso Núñez Florián y Rosa Aurora
Ramírez de Núñez, que ya no se encuentran con nosotros.

A mis hermanos Carlos Antonio, Jorge Alfonso, Richard
Juber, Leda Luz y Verónica Angela.

A mi sobrina Yadira Yazmín.

A mis hijos Carlos Daniel y Vanessa

AGRADECIMIENTO

A mis padres y hermanos, por el apoyo que siempre me brindan.

A los miembros de jurado, por las observaciones y sugerencias que me hicieron para mejorar este trabajo de investigación, en especial al Dr. Herón Juan Morales Marchena por ser el motivador principal de este proyecto y a todos mis profesores de la UNS, por sus enseñanzas y oportunos consejos en mi formación del doctorado.

Asimismo, a mis compañeros de promoción del doctorado por acompañarme siempre en todo el proceso de formación y culminación del doctorado y a mi amiga la Dra. Esther Berger Vidal.

ÍNDICE

Constancia de asesoramiento	ii
Hoja de conformidad del asesor	iii
Acta de sustentación de tesis	iv
Recibo Digital	v
Resultado porcentual de similitud	vi
DEDICATORIA	vii
AGRADECIMIENTO	viii
Índice	ix
Lista de Tablas	xii
Lista de Figuras	xiii
RESUMEN	xvii
ABSTRACT	xvii
INTRODUCCIÓN	xviii
CAPITULO I: PROBLEMA DE INVESTIGACIÓN	1
1.1. Planteamiento y fundamentación del problema de investigación	2
1.2. Antecedentes de investigación	4
1.3. Formulación del Problema de Investigación	7
1.4. Delimitación del Estudio	7
1.5. Justificación e Importancia de la Investigación	7
1.6. Objetivos de la Investigación	8
1.6.1. Objetivo general	8
1.6.2. Objetivos específicos	8
CAPITULO II: MARCO TEÓRICO	10
2.1. Fundamentos Teóricos de la Investigación	11

2.2. Marco conceptual	79
A.1. Variable independiente: Red neuronal supervisada	83
A.2. Variable dependiente: variación de la población fija	83
CAPITULO III: MARCO METODOLÓGICO	81
3.1. Fundamentos Teóricos de la Metodología	82
3.1.1. Hipótesis general	82
3.1.2. Hipótesis nula	82
3.1.3. Hipótesis específicas	82
3.2. Variables e Indicadores de la Investigación	83
3.3. Métodos de la Investigación	85
3.4. Diseño o Esquema de la Investigación	85
3.4.1. Nivel de investigación	86
3.4.2. Diseño	86
3.4.3. Enfoque	87
3.5. Población y Muestra	87
3.5.1. Población	87
3.5.2. Muestra	87
3.6. Actividades e Instrumentos de la Investigación	88
3.7. Técnicas e Instrumentos de la Investigación	90
3.8. Procedimientos para la Recolección de Datos	91
3.9. Técnicas de Procesamiento y Análisis de los Datos	102
CAPITULO IV: RESULTADOS Y DISCUSIÓN	103
4.1. Resultados	104
4.1.1. Análisis de la Estructura de la Red Neuronal Artificial	105
4.1.2. Aprendizaje y Entrenamiento de la Red Neuronal Artificial	105
4.1.3. Evaluación del Desempeño de la Red Neuronal Artificial	107
4.1.4. Programación de la Red Neuronal en MATLAB	107
4.1.5. Análisis de Resultados	109

4.2. Discusión	119
CAPITULO V: CONCLUSIONES Y RECOMENDACIONES	129
5.1. Conclusiones	130
5.2. Recomendaciones	131
REFERENCIA BIBLIOGRÁFICA Y VIRTUAL	132
ANEXOS	140
Anexo 1	140
Anexo 2	142
Anexo 3	144

LISTA DE TABLAS

Tabla 1: Patrones de entrenamiento NAND	35
Tabla 2: Patrones de entrenamiento para aprobar el curso de matemática	39
Tabla 3: Patrones del estado de los cursos	40
Tabla 4: Datos normalizados	41
Tabla 5: Evaluación Normalizada	48
Tabla 6: Patrones de entrenamiento	50
Tabla 7: Equivalencia entre términos estadísticos y de RNA	65
Tabla 8: Comparación entre modelos estadísticos y modelos RNA	66
Tabla 9: Definición operacional	84
Tabla 10: Indicadores	85
Tabla 11: Fallecidos por Covid-19 año 2020 Lima Metropolitana	92
Tabla 12: Fallecidos por Covid-19 año 2021 Lima Metropolitana	95
Tabla 13: Fallecidos por Covid-19 año 2022 Lima Metropolitana	98
Tabla 14: Nacidos en el año 2020 Lima Metropolitana	101
Tabla 15: Nacidos en el año 2021 Lima Metropolitana	101
Tabla 16: Nacidos en el año 2022 Lima Metropolitana	102

LISTA DE FIGURAS

Figura 1: Representación de una neurona biológica del ser humano	13
Figura 2: Modelo matemático simple para una neurona	14
Figura 3: Red Neuronal Multicapa	18
Figura 4: Modelo monocapa con entradas, sinapsis, funciones y salida	18
Figura 5: Predicción de Y en función de X	21
Figura 6: Elementos con dos características	21
Figura 7: Ilustración del gradiente	30
Figura 8: Función Sigmoidal	32
Figura 9: Función Tangente Hiperbólica	33
Figura 10: Función RELU	34
Figura 11: Modelo original Perceptrón de neurona artificial con salida binaria	57
Figura 12: Esquema Sigmoidal de Egmont-Petersen	58
Figura 13: Función de base radial	58
Figura 14: Perceptrón simple con función lineal = Modelo de regresión lineal	67
Figura 15: Modelo de red jerárquica	72
Figura 16: Modelo de Red Secuencial	73
Figura 17: Modelo de la investigación	87
Figura 18: Actividades del proceso investigativo	89
Figura 19: Esquema de la Red Neuronal	104
Figura 20: Data de Fallecidos por COVID 19 en Lima Metropolitana sin entrenar	109
Figura 21: Data de Fallecidos por COVID 19 en Lima Metropolitana entrenadas	110
Figura 22: Data de Nacimientos en Lima Metropolitana sin entrenar	111

Figura 23: Data de Nacimientos en Lima Metropolitana entrenadas	112
Figura 24: Gráfica de fallecidos del 2020	113
Figura 25: Gráfica de fallecidos del 2020	114
Figura 26: Gráfica de fallecidos del 2022	114
Figura 27: Gráfica de fallecidos del 2023	115
Figura 28: Gráfica de fallecidos del 2024	115
Figura 29: Gráfica de fallecidos del 2025	116
Figura 30: Gráfica de nacidos del 2020	116
Figura 31: Gráfica de nacidos del 2021	117
Figura 32: Gráfica de nacidos del 2022	117
Figura 33: Gráfica de nacidos del 2023	118
Figura 34: Gráfica de nacidos del 2024	118
Figura 35: Gráfica de nacidos del 2025	119
Figura 36: Diagrama de barra de fallecidos del 2020	123
Figura 37: Diagrama de barra de fallecidos del 2021	123
Figura 38: Diagrama de barra de fallecidos del 2022	124
Figura 39: Diagrama de barra de fallecidos del 2023	124
Figura 40: Diagrama de barra de fallecidos del 2024	125
Figura 41: Diagrama de barra de fallecidos del 2025	125
Figura 42: Diagrama de barra de nacidos del 2020	126
Figura 43: Diagrama de barra de nacidos del 2021	126
Figura 44: Diagrama de barra de nacidos del 2022	127
Figura 45: Diagrama de barra de nacidos del 2023	127
Figura 46: Diagrama de barra de nacidos del 2024	128

RESUMEN

El presente trabajo de investigación tuvo un diseño no experimental de nivel explicativo, de tipo observacional y predictivo, tuvo como objetivo determinar los cambios demográficos de la población de Lima Metropolitana durante la pandemia del COVID-19 que sigue azotando a nuestro país y a toda la comunidad internacional. Empleó un modelo matemático de Red Neuronal Supervisada para establecer cambios en la natalidad y mortalidad, y utilizó el algoritmo de optimización gradiente descendente para minimizar una función de activación que mide el error de predicción del modelo en el conjunto de datos. La población estuvo constituida por los habitantes de Lima Metropolitana, al inicio del periodo de estudio. Se usó un procedimiento aleatorio para elegir los elementos de la muestra, mediante el muestreo sistemático. Las actividades del proceso de investigación estuvieron dadas por el planteamiento del problema, la metodología a emplear, las metas (descripción y explicación) y las conclusiones. Finalmente, el procesamiento de la información se realizó mediante pruebas iterativas aplicadas a la Red Neuronal, para desarrollar el aprendizaje supervisado, verificar las respuestas, su cercanía a las respuestas deseadas y retroalimentar para realizar las modificaciones en los casos necesarios, hasta encontrar los resultados óptimos o deseados finales. El análisis y entrenamiento de los datos se lleva a cabo mediante el uso de herramientas del programa MATLAB que proporciona visualizaciones gráficas, cálculos matemáticos, cuadros matriciales y el estudio de las proyecciones realizadas al usar las redes neuronales construidas por el programa MATLAB, entrenadas por el algoritmo de aprendizaje BACK PROPAGATION.

Palabras claves: Datos Poblacionales, Red neuronal, Función de activación, Gradiente descendente, Back Propagation.

ABSTRACT

The present research work had a non-experimental design of an explanatory level, of an observational and predictive type, its objective was to determine the demographic changes of the population of Metropolitan Lima during the COVID-19 pandemic that continues to plague our country and the entire community. international. It used a Supervised Neural Network mathematical model to establish changes in birth and mortality, and obtained the gradient descent optimization algorithm to minimize an activation function that measures the prediction error of the model in the data set. The population consisted of the inhabitants of Metropolitan Lima, at the beginning of the study period. A random procedure was used to choose the elements of the sample, through the systematic. The activities of the research process were given by the problem statement, the methodology to be used, the goals (description and explanation) and the conclusions. Finally, the information processing was carried out through iterative tests applied to the Neural Network, to develop supervised learning, verify the answers, their proximity to the desired answers and provide feedback to make the modifications in the necessary cases, until finding the optimal results. or desired endings. The analysis and training of the data is carried out through the use of MATLAB program tools that provide graphical visualizations, mathematical calculations, matrix tables and the study of the projections made using the neural networks built by the MATLAB program, trained by the BACKPROPAGATION learning algorithm. **Keywords:** Population data, Neural network, activation function, gradient descent, Back Propagation

INTRODUCCIÓN

La pandemia causada por la enfermedad del Coronavirus (COVID-19) ha generado un impacto a nivel poblacional y socioeconómico en todos los países, sobre todo en las tasas de natalidad, mortalidad y en la economía nacional.

La finalidad del presente estudio de investigación es determinar y analizar los cambios poblacionales en Lima Metropolitana, así como sus proyecciones, haciendo uso de modelos matemáticos de Redes Neuronales Artificiales (RNA) y el programa MATLAB.

En particular, las RNA realizan aprendizaje del mismo modo que lo hace el ser humano, esto es, por medio de la experiencia.

El presente trabajo de tesis está conformado por cinco capítulos, con el objetivo de analizar los cambios demográficos en la población de Lima Metropolitana durante el periodo 2020 de desarrollo de la pandemia COVID-19 y su proyección 2021-2025, aplicando una Red Neuronal supervisada,

En el Capítulo I, se presenta la problemática del estudio que incluye la justificación, delimitación y los objetivos de la investigación.

El Capítulo II, está compuesto por el Marco Teórico que incluye las formas teóricas fundamentales de la investigación y el Marco Conceptual.

El Capítulo III, está contiene el Marco Metodológico que incluye las hipótesis de investigación, las variables de estudio, la técnica de investigación, el diseño de investigación, la población (Lima Metropolitana), así como el análisis, corrección y procesamiento de los datos.

En el Capítulo IV, se presentan los Resultados mediante tablas, gráficas, así como las estimativas del modelo matemático vía las Redes Neuronales supervisadas usando MATLAB. En este capítulo se presenta también la Discusión de los resultados.

Finalmente, el Capítulo V comprende las Conclusiones y Recomendaciones relacionadas con el proceso de investigación del presente trabajo

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN

1.1. Planteamiento y Fundamentación del Problema de Investigación

La pandemia causada por la enfermedad del coronavirus (COVID-19) se inició en el año 2019, habiéndose identificado los primeros casos como un tipo de neumonía desconocida ocurridos en Wuhan, China. La propagación del virus fue muy rápida, debido a que se contagia de persona a persona, llegando a varios países de Asia, Oceanía, África, Europa y América, esta enfermedad es mortal especialmente en personas con un sistema inmune débil y en personas con comorbilidades (Otoya-Tono et al., 2020).

La Organización Mundial de la Salud la declaró pandemia mundial el 11 de marzo del 2020. Esta situación tuvo y tiene aún un impacto desfavorable en la economía mundial, debido que los países han tomado decisiones difíciles como el confinamiento, la restricción de los viajes, el cierre de fronteras aéreas, terrestres y marítimas, el cierre de eventos masivos, decisiones que tuvieron como objetivo reducir, prevenir y frenar el nivel de contagio de la enfermedad. A pesar de ello, esta pandemia trajo consigo alto nivel de desarrollo científico y tecnológico (Foladori & Delgado, 2020).

Evidentemente, la pandemia generó un impacto a nivel poblacional y socioeconómico en todos los países, sobre todo en las tasas de mortalidad y en la economía nacional. El Perú fue uno de los países que evidenciaron altos efectos en su crecimiento demográfico, así, la Universidad John Hopkins, anunció en el momento más crítico, que fue en nuestro país donde se presentó la mayor incidencia de fallecimientos por cada cien mil habitantes. Las cifras acumuladas de fallecimientos por Covid-19 en el Perú sobrepasaron las doscientos mil personas con los efectos sobre la estabilidad social y económica que ello conlleva. Si bien es cierto que la tasa de crecimiento poblacional se mantuvo por el efecto de los nacimientos y muy poco por la inmigración en ese período, la tasa neta de crecimiento dada por la diferencia entre crecimiento y disminución poblacional en el período crítico de la pandemia, fue negativa para el país, como también fueron negativas sus consecuencias inmediatas.

Esta situación motivó el interés por realizar esta investigación y determinar el impacto futuro en el desarrollo socio-económico de nuestro país.

La siguiente es una breve reseña de cómo se desarrollaron en el Perú los hechos relacionados con esta problemática. En el Perú, el primer caso de Covid-19 se anunció a la población el 6 de marzo del 2020, ante ello el gobierno activó medidas para prevenir el contagio. Debido al rápido incremento de casos el gobierno declaró, el 15 de marzo del 2020, el aislamiento social obligatorio y el estado de emergencia, por esa razón se cerraron las fronteras y el transporte, medidas que entraron en vigor el 16 de marzo, estas medidas causaron problemas tales como la adaptación del sistema educativo público y privado, el cierre de los establecimientos comerciales, el cierre de las empresas, con la finalidad de reducir los contagios en la población peruana (Pighi, 2020).

Debido a la evolución de la enfermedad conforme avanzaba el tiempo, se amplió el aislamiento social en el Perú hasta el 26 de junio del 2020, después de ello se adoptó un aislamiento social focalizado y a diferentes niveles de severidad en las regiones según la proporción de los casos de contagio y muerte. A nivel socioeconómico, esa situación perjudicó la economía de gran cantidad de empresas y hogares por la generación de desempleo masivo, miles de empresas quebraron financieramente y cerraron.

El gobierno lanzó rápidamente un programa de protección parcial o total a las empresas y a sus trabajadores y de reactivación de empresas otorgándoles a través de la banca, préstamos blandos con el aval del Estado, de modo tal que el impacto sobre la Economía del país sea menor.

Como indicamos anteriormente, según datos de la Universidad John Hopkins (2020) sobre el análisis de la mortalidad por el nuevo coronavirus contagiado por la Covid-19, el Perú alcanzó en determinado período de la pandemia la mayor tasa de mortalidad a nivel global por cada 100 mil habitantes; esto se debió a muchos factores como las deficiencias en el sistema de salud, la irresponsabilidad de muchos

ciudadanos, la informalidad en el sector económico además de problemas de salud como la obesidad, hipertensión, cáncer, siendo estos tipos de pacientes algunos de los de más alto riesgo.

Las medidas restrictivas se repitieron durante el año 2020, hasta que la afectación de la Economía hizo que se flexibilizaran y se focalizaran según las regiones afectadas y según su grado de afectación.

El número de contagiados desde el inicio de la pandemia COVID-19, 15 de marzo de 2020 hasta finales de diciembre de 2020 superaba el 1'017,128 y el número de fallecidos superaba los 37254, según el MINSA, cifras, imposibles de imaginar y predecir al comenzar la pandemia en el Perú (Ministerio de Salud [MINSA], 2021).

Los efectos de esta enfermedad aún son inciertos y variables a largo plazo, ya que deja secuelas y presenta complicaciones de salud en diferentes niveles. Los impactos secundarios de esta pandemia ponen en riesgo la vida de muchos niños y el futuro de la población peruana en general.

Actualmente, que se conoce mucho más de la enfermedad, se ha fortalecido en el país la infraestructura de equipos especializados para la atención de pacientes en cuidados intensivos, se viene fortaleciendo el equipamiento y atención en los establecimientos de primer nivel, a fin de lograr resolver los casos de covid-19 en la etapa inicial y evitar que los pacientes requieran hospitalización (Organización Mundial de la Salud [OMS], 2021).

También, se ha incrementado la cantidad de personal especialista en la atención en cuidados intensivos, aunque esta es una gran limitación debido a que la formación de un intensivista requiere varios años, sin embargo, se está preparando a personal médico y paramédico de especialidades aproximadas a la de intensivista. También se han intensificado las medidas de protección y prevención, se está desarrollando la vacunación de la población según rangos etarios debido a lo cual se vienen manifestando descensos significativos en los niveles de contagio y fallecimiento.

Asimismo, gracias a la flexibilización de las medidas relacionadas con la Economía, esta se está reactivando, manifestándose un incremento en los valores de los indicadores de crecimiento económico.

1.2. Antecedentes de la Investigación

Bietta et al. (2020) realizaron una prepublicación de un artículo de investigación titulado: “Impacto del Covid-19 en la tasa de mortalidad de la población de la región de Umbría en Italia”, para contribuir a la investigación realizada por la OMS acerca de la reciente enfermedad. El estudio observacional-descriptivo tuvo como objetivo analizar la relación del nuevo virus Covid-19 con el cambio en la tasa de mortalidad en la región de Umbría durante el periodo diciembre 2019 – abril 2020 en comparación con los años anteriores. Los resultados mostraron un descenso en la tasa de mortalidad durante los meses de diciembre, enero y febrero; sin embargo, durante los meses con bajas temperaturas como en marzo se observó un incremento del 6%.

Márquez (2020). Inteligencia Artificial y Big Data como soluciones frente a la Covid-19. Revista Bioética y Derecho, N0 50, Barcelona 2020, Epub 23-Nov 2020. En esta investigación se relacionan Big Data e Inteligencia Artificial para tratar problemas que manejan grandes cantidades de datos como los relacionados con la COVID -19. El artículo muestra investigaciones realizadas sobre Ciencia de Datos, Big Data, aprendizaje automático, aprendizaje profundo, que se utilizan actualmente en el área de salud para el diagnóstico, seguimiento y tratamiento de enfermedades ocasionadas por los virus. Esa sinergia entre las técnicas permite desarrollar estudios avanzados para la toma de decisiones en el campo de la salud.

Pernalet y Odor (2021). Modelo espacio temporal y red neuronal de Kohonen en la estimación del Producto Interno Bruto, Exportaciones e Importaciones post Covid-19. Ciencia Latina, 2021, Vol. 5 N0 2.

En esta investigación se presentan los resultados de utilizar una red neuronal no supervisada de tipo competitivo, de Kohonen sobre mapas autoorganizados con el

objetivo de realizar una investigación de nivel descriptivo, documental, para pronosticar el PBI, así como las exportaciones e importaciones del período 2020-2022, en millones de soles. Obtuvo como resultado que, considerando esa misma unidad de medida monetaria, ante 20 000 unidades de incremento en el PBI, las exportaciones e importaciones varían respectivamente en 4000 y 6000 unidades. La base de datos pertenece al INEI, períodos 2007 – 2020.

Sosa et al. (2020). Impacto del rezago social en el número de muertes y contagios por COVID-19 en México, análisis con redes neuronales artificiales empleando información a nivel municipal. Vol. 65, Nº.5, 2020.

Con motivo de la pandemia Covid-19, como en otros de países de América Latina, se hizo notoria en México la vulnerabilidad de determinadas regiones debido a las carencias en la educación, vivienda, salud y servicios como electricidad, agua y alcantarillado. En la investigación se analiza el impacto sobre la incidencia de contagios que ante la Covid-19 tiene en la población debido a la falta de tales servicios. El análisis se realizó aplicando redes neuronales artificiales haciendo uso de datos municipales sobre el Índice de Rezago Social y datos oficiales sobre muertes y contagios acumulados. Como resultado se obtuvo que las carencias detectadas son, en estas regiones, determinantes para la cantidad de contagios y fallecimientos.

1.3. Formulación del Problema de Investigación

1.3.1. Problema general de investigación

¿Será posible determinar un modelo matemático de red neuronal supervisada para explicar los cambios demográficos en la población de Lima Metropolitana, durante el período 2020 y su proyección y efectos sobre la actividad socio-económica en el período 2021-2025?

1.3.2. Problemas específicos de la investigación

¿Será posible determinar un modelo matemático de red neuronal supervisada para explicar los cambios que se produjeron en la natalidad de la población de Lima Metropolitana, durante el período 2020 de desarrollo de la pandemia Covid-19 y su proyección para el período 2021-2025?

¿Será posible definir un modelo matemático de red neuronal supervisada para explicar los cambios que se produjeron en la mortalidad de la población de Lima Metropolitana, durante el período 2020 de desarrollo de la pandemia Covid-19 y su proyección para el período 2021-2025?

¿Será posible establecer un modelo matemático de red neuronal supervisada para explicar cómo afectarán los cambios demográficos de la población de Lima Metropolitana ocurridos durante el período 2020 de desarrollo de la pandemia Covid-19 a las actividades socio económicas del período 2021-2025?

1.4. Delimitación del Estudio

El estudio se realizó considerando la información obtenida de las entidades pertinentes: Ministerio de Salud, INEI, Instituto Nacional de Salud y mediante el trabajo de campo.

1.5. Justificación e Importancia de la Investigación

La investigación permitirá resolver un problema relacionado con la determinación de las variaciones en las características poblacionales causadas por un problema grave de salud pública en el Perú, tal es la pandemia Covid-19 y su impacto futuro, social y económico.

Es importante, porque se plantea un análisis basado en información real y reciente y los resultados, serán útiles a las instituciones relacionadas con la problemática, en salud pública y economía, para la toma de decisiones que permitan atenuar el impacto futuro de esta situación en la vida socio económica de Lima Metropolitana.

El resultado de este estudio será de utilidad para la comunidad médica y social que dispondrá de una información relevante sobre los cambios en los aspectos demográficos en Lima Metropolitana, lo cual les ayudará a tomar decisiones importantes relacionadas con estos aspectos.

Además, resulta de suma importancia abordar este tema debido a que está causando muchos problemas económicos, de salud, trabajo, psicológicos, de violencia familiar, educativos en todos los países del mundo, así como en nuestro país.

Asimismo, con este proyecto podremos generar conciencia en la población de lo indispensable que es respetar las nuevas normas propuestas por el Estado para evitar la propagación de este virus y disminuir lo más posible la cantidad de personas hospitalizadas o fallecidas en nuestro país.

1.6. Objetivos de la Investigación

1.6.1. Objetivo general

Determinar un modelo matemático de red neuronal supervisada para explicar los cambios demográficos en la población de Lima Metropolitana, durante el período 2020 y su proyección y efectos sobre la actividad socio-económica en el período 2021-2025.

1.6.2. Objetivos específicos

Determinar un modelo matemático de red neuronal supervisada para explicar los cambios que se produjeron en la natalidad de la población de Lima Metropolitana,

durante el período 2020 de desarrollo de la pandemia Covid-19 y su proyección para el período 2021-2025.

Definir un modelo matemático de red neuronal supervisada para explicar los cambios que se produjeron en la mortalidad de la población de Lima Metropolitana, durante el período 2020 de desarrollo de la pandemia Covid-19 y su proyección para el período 2021-2025.

Establecer un modelo matemático de red neuronal supervisada para explicar cómo afectarán los cambios demográficos de la población de Lima Metropolitana ocurridos durante el período 2020 de desarrollo de la pandemia Covid-19 a las actividades socio económicas del período 2021-2025.

CAPÍTULO II: MARCO TEÓRICO

2.1. Fundamentos Teóricos de la Investigación

En esta sección se ha considerado presentar los conceptos básicos fundamentos sobre las redes neuronales artificiales de aprendizaje supervisado y los cambios demográficos medidos por la variable: variación de la población fija.

A. Fundamentos Teóricos Básicos

A.1. Redes neuronales

En este proyecto se busca dar respuesta a la pregunta de investigación haciendo uso de modelos matemáticos de Redes Neuronales Artificiales (RNA).

Las Redes Neuronales Artificiales son catalogadas dentro del campo de la Inteligencia Artificial, disciplina científica que plantea modelos computacionales de aprendizaje basados en los modos de aprendizaje usados por las redes neuronales biológicas del cerebro humano, gracias a ello, es posible actualmente procesar grandes cantidades de datos y tomar decisiones en tiempos mínimos (Russel & Norving, 2010; Mathivet, 2018).

En particular, las RNA realizan aprendizaje del mismo modo que lo hace el ser humano: por medio de la experiencia. Existen diferentes tipos de redes neuronales artificiales, según la forma de aprendizaje de conocimientos de la red, las más importantes son:

Redes de aprendizaje supervisado.

Redes de aprendizaje no supervisado.

A continuación, se presentan los conceptos relacionales con las redes neuronales biológicas y cómo son emuladas por las redes neuronales artificiales para la solución de problemas.

Redes neuronales biológicas

En el cerebro humano, existen redes neuronales biológicas que están compuestas por más 10^{11} de neuronas, es decir, más de cien mil millones de neuronas y 10^{14} *sinapsis*. La *sinapsis* es la conexión entre dos neuronas, esa conexión se realiza a través de impulsos nerviosos. Al conectarse dos neuronas se procesa información relativa a los sistemas biológicos (Russell & Norving, 2010).

Las *neuronas* tienen tres partes:

Cuerpo Celular. Cuyo centro contiene un órgano de procesamiento de información denominado *núcleo* o *soma*.

Dendritas. Que tienen forma de ramas que son los medios mediante los cuales la neurona realiza la sinapsis.

Axón. De forma alargada que tiene en su parte final prolongaciones de salida que se conectan con dendritas de entrada de otras neuronas transmitiéndoles información.

En los sistemas nerviosos cerebrales existen tres funciones muy importantes:

Memoria distribuida. Por la cual la memoria se encuentra repartida entre las diferentes neuronas del cerebro humano, de tal manera que si muere una neurona se pierde una cantidad ínfima de información.


El Cálculo paralelo. Por el cual el cerebro humano realiza gran cantidad de cálculos casi simultáneos.

La Adaptabilidad al entorno. Por la cual el cerebro produce los cambios en sus respuestas según los cambios en los estímulos externos. Una neurona envía información a otra haciendo uso de uno de sus componentes identificado como axón el cual traslada la información por medio de ***diferencias de potencial eléctrico***.

Esa información está relacionada con una serie de capacidades del ser humano como el reconocimiento de figuras o patrones, el reconocimiento del habla, el control de dispositivos, la clasificación de objetos, entre otros.

Figura 1

Representación de una neurona biológica del ser humano



Fuente: Licencia CC-BY-SA

A.1.2 REDES NEURONALES ARTIFICIALES

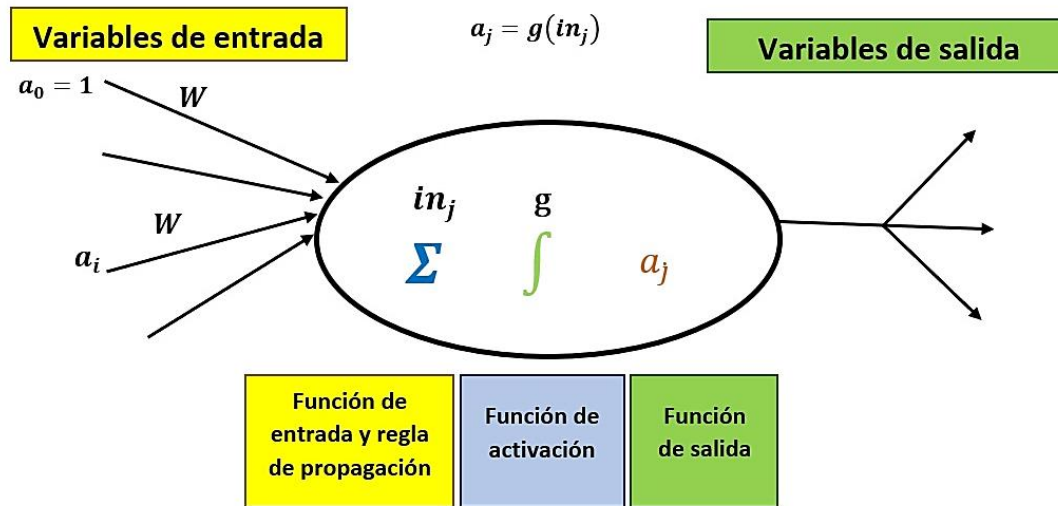
MacCulloch y Pits (1943) tomaron la actividad cerebral desarrollada por las neuronas como medio para representar problemas de diversa naturaleza y darles solución.

Considerando que la mente desarrolla en las redes de neuronas, actividad electroquímica, estos autores diseñaron su propuesta inicial de red neuronal artificial, para emular el comportamiento de las redes neuronales biológicas.

Así surgió el modelo matemático básico y simple de neurona artificial representado en la Figura 2.

Figura 2

Modelo matemático simple para una neurona



Fuente propia

Tanto las redes neuronales biológicas como las artificiales tienen entradas o dendritas, salidas o axón y pesos o sinapsis.

Una neurona biológica puede estar en estado **activo o excitado** o en estado, **inactivo o no excitado**.

En la neurona artificial la unidad de activación de salida es $a_j = g(\sum_{i=0,n} w_{ij} a_i)$, siendo a_i la activación de salida de la unidad i y $w_{i,j}$ es el peso sobre el enlace de la unidad i con j .

Según Jorge (2001), una neurona trata a varios o muchas entradas como una única **entrada global**.

El problema consiste en cómo combinar las entradas individuales en la entrada global, lo cual se consigue mediante la función de entrada que se halla por medio del

vector de entrada y un operador determinado. Se describe la función de entrada por: entrada $j = (en_{j1})(w_{j1}) * (en_{j2})(w_{j2}) * \dots (en_{j3})(w_{j3})$, Jorge, (2001), siendo:

El Operador Elegido. El cual puede ser una sumatoria, un producto, un máximo, entre otros.

n : cantidad de entradas a la neurona N_i

w_i : es el peso

$in_j = (in_{j1}, in_{j2}, \dots, in_{jn})$, es el vector de entradas.

Lo que ocurre es que los valores asociados a las entradas se multiplican por los pesos de las neuronas que modifican las influencias de las entradas, así, por ejemplo, un valor grande de entrada puede tener una influencia pequeña y uno pequeño puede tener una influencia grande (Jorge, 2001).

La Memoria Distribuida. Es la función por la cual la memoria en el cerebro humano no se encuentra localizada en un solo lugar sino en las sinapsis entre las neuronas de modo tal que si deja de funcionar una neurona la cantidad de información guardada en la memoria relacionada es ínfima.

El Procesamiento Paralelo. De información está relacionado con la ejecución de gran cantidad de cálculos en una cantidad muy reducida de tiempo.

La Adaptabilidad. Al entorno está referida al aprendizaje, al aprovechamiento de la experiencia y a la capacidad de inducción generalizando conceptos a partir de ideas particulares.

Russell y Norving, (2010) lo definen como una red neuronal artificial es una colección de unidades conectadas entre sí, tal que las propiedades de la red son determinadas por su estructura y por las propiedades de las neuronas artificiales.

Las redes neuronales son tratadas por la Inteligencia Artificial siendo una de sus propiedades relevantes el desarrollo de sus procesos de aprendizaje.

Siguiendo la representación mediante Grafos, las redes neuronales artificiales (RNA), tienen las siguientes características:

Una RNA es representada por un grafo orientado cuyos nodos simbolizan neuronas.

Las relaciones entre nodos son las *sinapsis* y están representadas por arcos.

Un arco tiene como nodo inicial a la neurona que envía información o neurona presináptica y como nodo final a la neurona que recibe información o neurona postsináptica.

El movimiento de la información es siempre en un solo sentido, no existen arcos de retorno en la interacción entre dos células neuronales artificiales, tampoco existen ciclos ni bucles que representarían retornos.

Un arco de i a j , representado como (i, j) , simboliza la propagación de la activación a_i de i a j .

Cada arco también tiene asociada una ponderación o peso numérico w_{ij} que indica la importancia y el signo de la conexión.

Una unidad j determinada halla la suma de las ponderaciones de sus entradas, de la siguiente manera:

$$in_j = g(\sum_{i=0,n} w_{ij} a_i)$$

a la cual le aplica una función de activación g para obtener la salida.

$$a_j = g(in_j) = g(\sum_{i=0,n} w_{ij} a_i)$$

La **Función de Activación**. Puede ser una función escalera, una función logística o sigmoidea. Esta función se utiliza para imitar el estado en que puede encontrarse una neurona biológica: **activa o inactiva**.

Cuando es una función escalera se le denomina **perceptrón** y cuando es una función logística se denomina **perceptrón sigmoideo**. La denominación perceptrón proviene del término percepción que es lo que se realiza en un proceso de aprendizaje: se perciben hechos y conocimientos por medio del cerebro.

Con esta función se puede realizar una **regresión del tipo logístico** que permite realizar *pronósticos*.

Con los nodos y arcos del grafo podemos representar una RNA que está compuesta por niveles de nodos denominados *capas*.

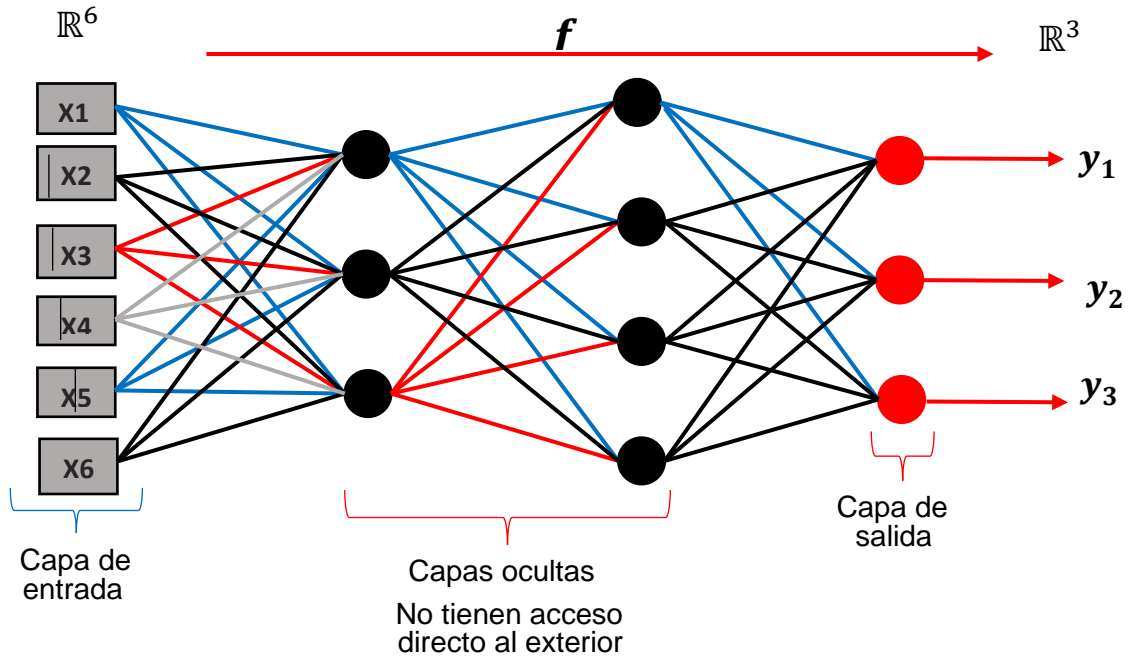
Una *capa* es un conjunto de neuronas de una red nivelada, es decir, ordenada por subconjuntos de nodos que se encuentran al mismo nivel y que reciben información de una capa anterior o reciben información de entrada a la red si forman parte de la primera capa.

Una red neuronal puede estar constituida por una capa: *red monocapa*, o por múltiples capas: *red multicapa*.

Gráficamente, en la Figura 3 podemos apreciar la red más general, multicapa. Las capas internas se denominan capas ocultas y una RNA puede tener al menos una capa oculta.

Figura 3

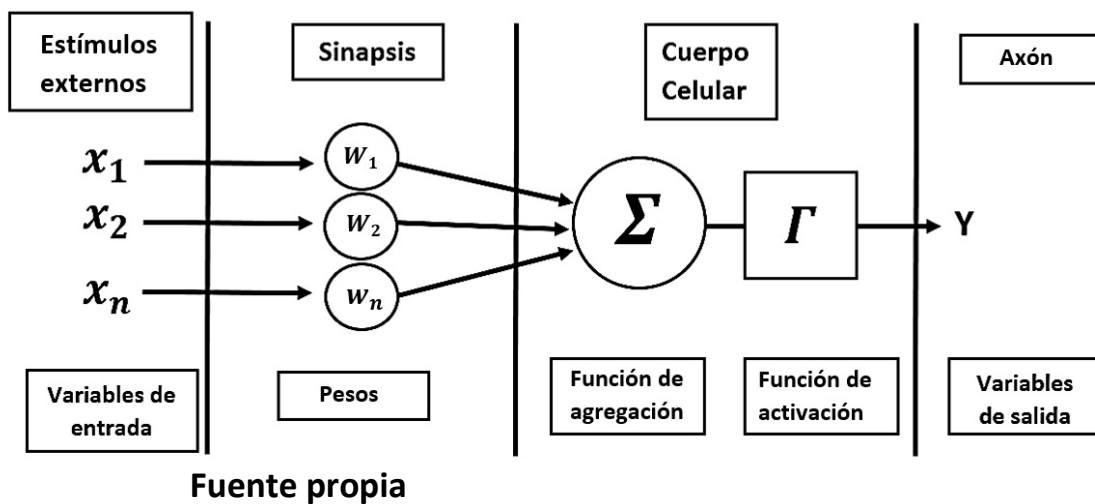
Red Neuronal Multicapa



Fuente propia

Figura 4

Modelo monocapa con entradas, sinapsis, funciones y salida



Fuente propia

A.1.3. Mecanismos de aprendizaje de redes neuronales

Las redes neuronales artificiales generalizan a partir de un conjunto de casos anteriores en los problemas de decisión. La RNA debe aprender a calcular salidas a partir de conjuntos de datos de entrada de los casos ejemplos. El proceso de aprendizaje de una RNA es denominado *proceso de entrenamiento o de acondicionamiento*. El conjunto de datos de entrada o ejemplos se denomina *conjunto de datos de entrenamiento* (Jorge, 2001).

El aprendizaje consiste en la auto modificación de pesos por la RNA para responder a las entradas. Los cambios consisten en la creación, modificación y destrucción de conexiones como ocurre en los sistemas biológicos. Cuando se crea una nueva conexión su peso es diferente de cero y si se destruye es igual a cero.

Los cambios en los pesos quedan definidos por:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t)$$

Es decir, que el peso nuevo será igual al peso anterior más el cambio en el peso anterior.

A.1.3.1 Métodos de aprendizaje. Entre los métodos de aprendizaje más utilizados se encuentran el *aprendizaje no supervisado* y el *aprendizaje supervisado* (Jorge, 2001).

A.1.3.2 Aprendizaje supervisado. En este caso, un maestro o supervisor controla el entrenamiento y especifica el resultado que debe obtener la red ante una entrada dada. Si no hay coincidencia se modifican los pesos con la finalidad de obtener el resultado esperado.

Se considera que el aprendizaje supervisado es el más difundido, en este se da al aprendiz que es el algoritmo un conjunto de ejemplos, luego el algoritmo compara la salida de la red con la salida esperada. Así, por ejemplo, supongamos que se diseña

un sistema para estimar el precio de un vehículo con ciertas características deseadas. Se dispondrá de información con las características de un conjunto de vehículos, como tamaño, color, calidad, resistencia, motor, circuitos eléctricos, velocidad, comodidad interna, precio de venta. Se entrena al algoritmo tomando como base los datos conocidos, se le pide que realice una estimación del precio y se realiza la comparación con el precio real. Si existe una diferencia, buscamos mejorar el algoritmo respecto al acercamiento al precio real hasta obtener los resultados más cercanos a este.

En el aprendizaje supervisado existen dos actividades importantes, estas son ***el desarrollo de una regresión y la realización de una clasificación.***

La ***regresión*** se utiliza para hallar un valor lo más próximo posible al valor real a partir de los datos.

La ***clasificación*** se aplica para establecer la clase en la que se encuentra un elemento tomando como base sus características o atributos. Por ejemplo, los clientes pueden clasificarse como puntuales en sus pagos, esporádicamente impuntuales.

Supongamos que en una empresa los pagos se deben realizar durante los siete días de la primera semana de cada mes, entonces, tendremos clientes que pagan al inicio de la semana, durante la semana y al final de la semana, pero todos son puntuales.

Si consideramos estos pagos como puntos, no son iguales, pero son similares, cercanos y conforman una clase, la clase de los clientes puntuales; también tenemos los que esporádicamente son impuntuales y si definimos como tres la cantidad máxima de impuntualidades en esta clase, también tendremos elementos similares que a lo más se retrasan tres veces al año y por último tenemos los clientes impuntuales que conformarán esta clase por tener una frecuencia de impuntualidades en un rango mayor a tres.

Esto hace que se pueda maximizar la similitud entre los datos de una misma clase porque son puntos cercanos.

Mathivet (2018) da dos ejemplos gráficos que pueden ser resueltos por redes neuronales, en la Figura 5 se trata de predecir la variable **Y** en función de la variable **X** basados en ejemplos representados por cruces **X**, el modelo correspondiente es uno de regresión.

En la Figura 6 se muestran los signos **x** y **+** que representan dos características cuyo modelo es la línea trazada, en este caso existe un problema de clasificación en el cual tenemos dos clases de elementos que es necesario separar debido a dos características X_1 y X_2 .

Figura 5

Predicción de Y en función de X

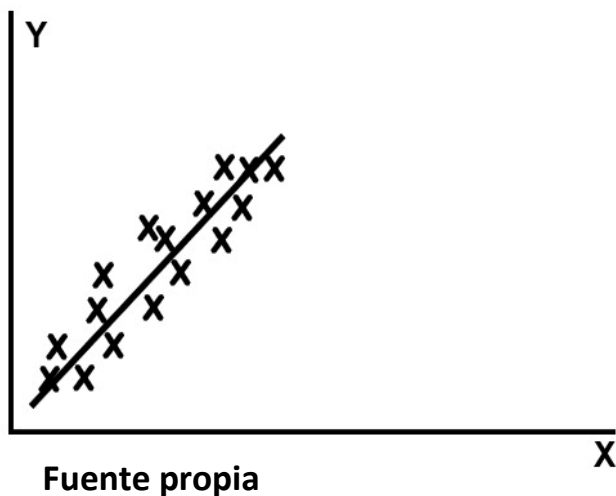
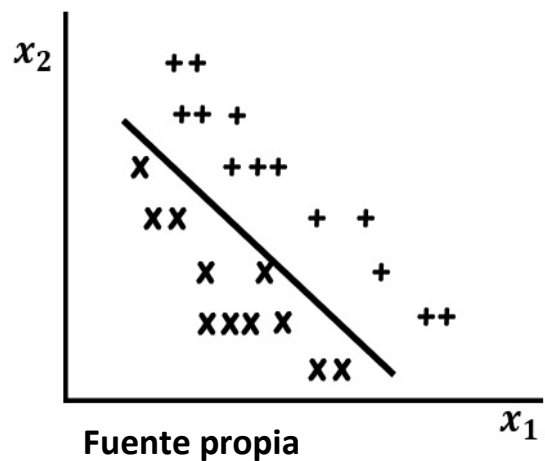


Figura 6

Elementos con dos características



La regresión y los algoritmos de regresión lineal son problemas comunes en *Machine learning* (ML) identificado en castellano como *Aprendizaje automático*, que es el conjunto de técnicas que facilitan a un algoritmo el *aprendizaje a partir de ejemplos* sin programar directamente la solución.

Machine learning es muy útil cuando no es posible representar la realidad mediante un modelo para resolver problemas, pero sobre la cual podemos proporcionar ejemplos. La mayor parte de algoritmos de ML son matemáticos, estadísticos, metaheurísticos o de redes neuronales o Deep Learning.

Machine learning contribuye a dar solución a diferentes problemas que se presentan hasta en tres formas de aprendizaje: *el aprendizaje no supervisado*, *el aprendizaje supervisado* y *el aprendizaje por refuerzo* (Mathivet, 2018).

Existen tres formas de realizar el aprendizaje supervisado:

a. El aprendizaje por Corrección de Errores

En este aprendizaje se reajustan los pesos en función de la magnitud de los errores. La RNA denominada Perceptrón aprende con este mecanismo.

b. El Aprendizaje por Refuerzo

Este aprendizaje se basa en que no se dispone de información completa sobre casos anteriores, tampoco se indica la salida deseada. El supervisor tiene la única función de indicar el éxito o fracaso del resultado, es decir, si la decisión que el algoritmo tomó es buena o no lo es. La respuesta es global, el algoritmo no sabe cuál habría sido la mejor decisión y si se reajustan los pesos se hace en términos probabilísticos

Según Mathivet (2018), esta es la forma en que aprenden a caminar los seres humanos y los animales, ellos saben que lo que desean conseguir es caminar, pero no saben cómo conseguirlo, los músculos que deben mover y el orden en que deben hacer los movimientos, así, el niño pequeño trata de caminar y da un paso cuando lo hace bien o se cae cuando lo hace mal. Al repetir un número de veces refuerza su aprendizaje de éxitos y fracasos y aprende cómo debe hacer para no caerse y va perfeccionando la acción de caminar hasta poder correr.

A pesar de ser algo tan común al ser humano esta forma de aprendizaje se utiliza muy poco, excepto en ciertos casos importantes como en la robótica.

Cuando se utilizan redes neuronales, el aprendizaje por refuerzo se aplica cuando se deben tomar varias decisiones simultáneas o sucesivas como cuando se busca ganar un videojuego.

Las **metaheurísticas** permiten realizar el aprendizaje supervisado gracias a que optimizan funciones que no conocen previamente siendo los más usados los **algoritmos genéticos** que imitando la evolución de los seres vivos optimizan las ponderaciones y encuentran estrategias ganadoras sin conocer previamente el resultado esperado.

c. Aprendizaje Estocástico

Para realizar este proceso de aprendizaje se modifica aleatoriamente los pesos y se evalúa sus efectos sobre el objetivo deseado, usándose distribuciones de probabilidad.

En esta investigación se diseñará una red neuronal de aprendizaje supervisado destinada a analizar tendencias en la demografía de la población de Lima Metropolitana y a realizar pronósticos sobre las tendencias en los próximos cinco años.

Elección del estado inicial de una RNA

Para iniciar el entrenamiento de una RNA se determina un estado inicial conformado por un conjunto inicial de ponderaciones o pesos para las conexiones entre las neuronas, para lo cual existen diferentes criterios.

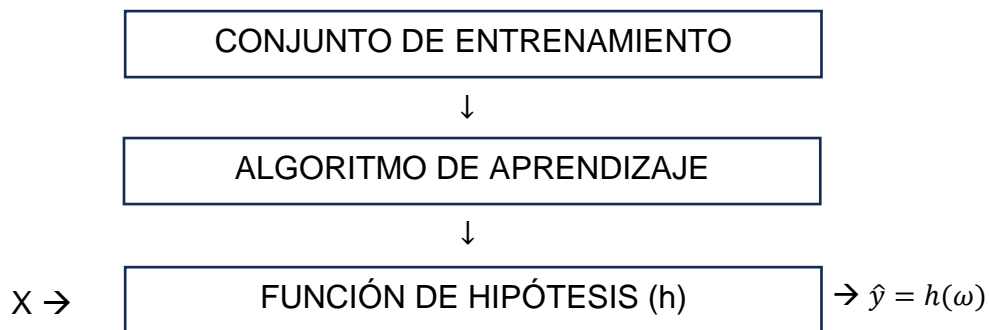
Un aspecto muy importante es la capacidad de la RNA para generalizar a partir de ejemplos.

Indicadores de la Variable Red Neuronal Supervisada

Desviación de la salida del objetivo o error. Es la diferencia entre la solución que da el algoritmo y el valor esperado o deseado. Si la diferencia no es aceptable, la red neuronal modifica los pesos sinápticos y repite la iteración en búsqueda de la solución, compara con el resultado deseado o esperado y repite el proceso hasta que entre ambos valores la diferencia sea aceptable. Los pesos sinápticos son en realidad las incógnitas en el entrenamiento.

Mínimo error cuadrado. Se trata de hallar una matriz de pesos **W** tal que dé valores óptimos de solución de un problema aplicando el método de mínimos cuadrados en iteraciones repetidas. Mediante esa función de error se mide el rendimiento actual de la red neuronal que depende de los pesos o valores sinápticos y que establece cómo modificarlos para alcanzar el punto óptimo de la red.

El aprendizaje supervisado es una manera de aprendizaje automático donde el sistema tiene viabilidad a la respuesta correcta para cada uno de los datos. Un esquema ilustrativo se da de la siguiente manera:



Donde se predice valores reales para la Salida $y \in \mathbb{R}$, dada una entrada X con n componentes ($x \in \mathbb{R}^n$). Esto es, en este problema se obtiene una función de hipótesis $h: \mathbb{R}^n \rightarrow \mathbb{R}$.

Notación:

Sea $D = \{(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(n)}, y^{(n)})\}$ conjunto de datos para el entrenamiento que contiene n instancias o ejemplos.

Donde

n : número de instancias, muestras o ejemplos de entrenamiento.

$(x^{(i)}, y^{(i)})$: instancia i -ésima de entrenamiento.

$x^{(i)} \in \mathbb{R}^n$: Vector de n componentes de entrada correspondiente a la i -ésima instancia de entrenamiento, tal que:

$$x^{(i)} = \begin{bmatrix} x_1^{(i)} \\ x_2^{(i)} \\ \vdots \\ x_n^{(i)} \end{bmatrix}$$

A los componentes también se les denomina Características.

$y^{(i)} \in \mathbb{R}$: Salida correspondiente a la i -ésima instancia.

Función de hipótesis

Sea $h: \mathbb{R}^n \rightarrow \mathbb{R}$ función tales que

$$h(x) = h_\omega(x) = \omega_0 + \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n$$

donde cada ω_i es un parámetro o peso que se debe encontrar.

Además, al escalar ω_0 se le denomina Sesgo o bias del modelo.

De forma equivalente, podemos decir que, si consideramos.

$$x = \begin{bmatrix} x_0 \\ x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad y \quad \omega = \begin{bmatrix} \omega_0 \\ \omega_1 \\ \omega_2 \\ \vdots \\ \omega_n \end{bmatrix}, \quad \text{con } x_0 = 1,$$

la función hipótesis se puede escribir de la forma,

$$h_{\omega} = \omega^t \cdot x = \sum_{i=0}^n \omega_i x_i, \text{ donde } \omega^t \text{ es la matriz traspuesta.}$$

Nótese, que algunas veces a la función hipótesis se le puede expresar como,

$$h_{\omega}(x) = \omega^t \cdot x + b, \text{ donde } \omega_0 = b \text{ como valor de bias o sesgo.}$$

Función de costo

Asumiendo que existen n datos o instancias de entrenamiento, viene dada por:

$$J(\omega) = \frac{1}{2n} \sum_{i=1}^n (h_{\omega}(x^{(i)}) - y^{(i)})^2,$$

Donde J se denomina función de error cuadrático medio. Cuando no aparece el factor $\frac{1}{2n}$, la función de costo se denomina suma de cuadrados residuales (RSS). El término $h_{\omega}(x^{(i)}) - y^{(i)}$ representa el error en el cual incurre la función de hipótesis h_{ω} en la instancia $x^{(i)}$ para predecir el valor del $y^{(i)}$.

De este modo, el problema es encontrar, $\min_{\omega} J(\omega)$.

Estimación de parámetros: descenso del gradiente

La idea general para estimar parámetros adecuados es empezar con algún valor de pesos ω (valor inicial), e ir cambiando estos pesos ω de manera que con cada iteración se reduzca el costo $J(\omega)$, hasta encontrar el costo mínimo.

El algoritmo de descenso de gradiente es un algoritmo iterativo que buscan encontrar el peso ω que minimice $J(\omega)$ después de algunas iteraciones.

Esto es,

$$\omega_j(k+1) = \omega_j(k) - \alpha \frac{\partial}{\partial \omega_j(k)} (J(\omega^{(k)})), \text{ donde}$$

$\omega_j(k)$ indica el componente j -ésimo del vector de pesos ω en el instante de tiempo k y α es el llamado factor de aprendizaje (learning rate).

Algunos expertos consideran que el algoritmo de descenso de gradiente se detiene en la iteración k si se cumple que:

$$\left| J_{(\omega(k))} - J_{(\omega(k-1))} \right| < \varepsilon, \text{ donde } \varepsilon \text{ es un valor relativamente pequeño}$$

Asimismo, las derivadas parciales de la función de costo J , pueden calcularse de manera analítica como,

$$\begin{aligned} \frac{\partial}{\partial \omega_j} J(\omega) &= \frac{\partial}{\partial \omega_j} \left(\frac{1}{2n} \sum_{i=1}^n (h_{\omega}(x^{(i)}) - y^{(i)})^2 \right) \\ &= \frac{1}{2n} \frac{\partial}{\partial \omega_j} \sum_{i=1}^n (\omega_0 x_0^{(i)} + \omega_1 x_1^{(i)} + \dots + \omega_d x_d^{(i)} - y^{(i)})^2 \\ &= \frac{1}{2n} (2) \sum_{i=1}^n (h_{\omega}(x^{(i)}) - y^{(i)}) \frac{\partial}{\partial \omega_j} (\omega_0 x_0^{(i)} + \omega_1 x_1^{(i)} + \dots + \omega_d x_d^{(i)} - y^{(i)}) \\ &= \frac{1}{n} \sum_{i=1}^n (h_{\omega}(x^{(i)}) - y^{(i)}) x_j^{(i)} \end{aligned}$$

Luego reemplazando en la expresión anterior, se tiene,

$$\omega_{j+1}^{(k)} = \omega_j^{(k)} - \alpha \cdot \frac{1}{n} \sum_{i=1}^n (h_{\omega}(x^{(i)}) - y^{(i)}) x_j^{(i)}$$

A esta expresión se le conoce como la fórmula de Aprendizaje de Widrow-Hoff.

Factor de aprendizaje (α)

El factor de aprendizaje, es un parámetro que se fija de manera manual, cuyo valor es crítico en la convergencia del algoritmo de descenso del gradiente. Un factor adecuado

permitirá un aprendizaje adecuado. Algunas consideraciones que hay que tener en cuenta para la elección del factor de aprendizaje α :

- Si α es muy pequeño, el descenso del gradiente es lento.
- Si α es muy grande, el descenso del gradiente puede hacer un overshoot o exceso del mínimo y puede divergir.

Para asegurarse de tener un aprendizaje adecuado, debemos verificar que la función de costo $J(\omega)$ disminuya luego de cada iteración.

En resumen, podríamos decir que las características del cálculo de ω usando el descenso del gradiente son:

- Se necesita elegir el valor del factor de aprendizaje α .
- Se necesitan varias iteraciones.
- Trabaja muy bien cuando se tiene muchas instancias, esto es, cuando n es grande.

Por otro lado, de forma general se puede definir una función de hipótesis como una combinación lineal de bases no lineales $\phi_i(x)$ como,

$$h_{\omega}(x) = \omega^t \cdot \phi(x) = \sum_{i=0}^n \omega_i \phi_i(x) , \text{ donde}$$

$$\phi(x) = \begin{bmatrix} \phi_0(x) \\ \phi_1(x) \\ \vdots \\ \phi_n(x) \end{bmatrix}$$

es el vector de bases no lineales y $\phi_i(x)$ es una base no lineal. Asimismo, al igual que para la regresión lineal, $\phi_0(x) = 1$, de manera que ω_0 se comporta como un Sesgo o bias. Nótese que las bases no lineales pueden ser de varios tipos:

- Bases polinomiales: $\phi_i(x) = x^i$

- Bases gaussianas: $\phi_i(x) = e^{-\frac{1}{2}\left(\frac{x-u_i}{s}\right)^2}$, donde u_i , S son parámetros que afectan la posición y ancho de la base.
- Bases sigmoidales: $\phi_i(x) = \vartheta\left(\frac{x-u_i}{s}\right)$, donde la función sigmoideal es $\vartheta(z) = \frac{1}{1+e^{-z}}$, y los parámetros u_i , S controlan la posición y la pendiente.
- Otras bases: Como, por ejemplo, se pueden utilizar funciones tangentes hiperbólicas, logarítmicas, trigonométricas, etc.

De este modo, una vez que se ha reemplazado los datos con las salidas de las bases no lineales, se podrá hallar los mejores parámetros ω de la misma forma como se realiza para la regresión lineal.

También, cabe mencionar que existen otras formas de optimización con algoritmos más sofisticados. Como, por ejemplo:

- Método del gradiente conjugado
- Algoritmo BFGS (Broyden – Fletcher – Goldfarb – Shanno)
- Algoritmo L – BFGS (BFGS de memoria limitada)

La ventaja de estos algoritmos es que no es necesario encontrar un valor α , y usualmente son más rápidos que el descenso del gradiente, son más complejos a nivel teórico. Pero, estos métodos siempre necesitan el valor de función de costo $J(\omega)$ y de su derivada parcial.

Un método de aplicación frecuente es el *Método del descenso más rápido* por el cual por cada patrón que recibe la red se determina el valor de la función de error $E(W)$, luego se busca el mínimo error local para determinar finalmente el mínimo error global. Este método también se conoce como el *Algoritmo de optimización del Método del Gradiente Descendente*, tal que dada, una función matemática este método halla automáticamente el punto mínimo de la función.

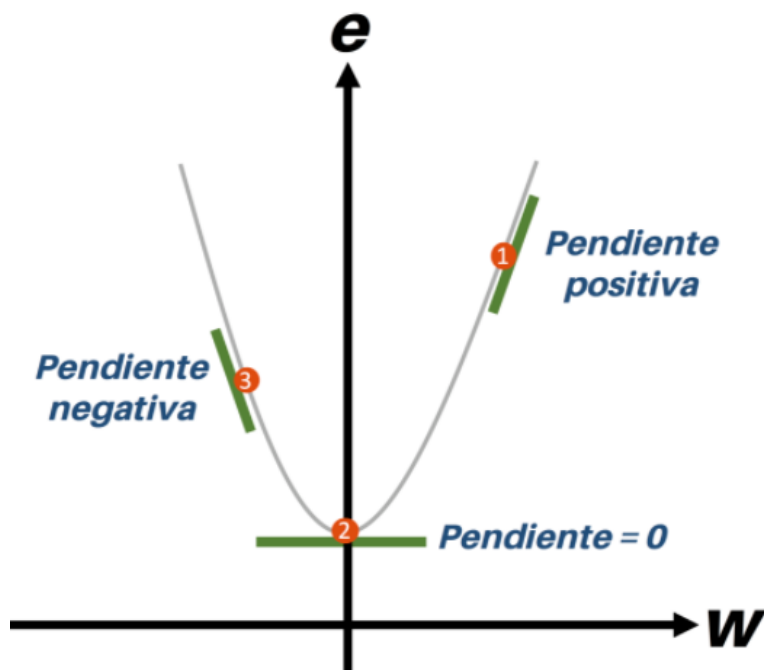
El procedimiento que sigue este algoritmo se ilustra en la Figura 7, para la función $e=w^2+1$ cuyo mínimo se da en el punto (2) de color rojo, que se alcanza para w igual a 0. Entonces, el mínimo es el punto $w=0, e=1$.

Vemos que automáticamente se ha obtenido $w=0$ utilizando el *algoritmo del gradiente descendente*. Para la mejor comprensión del funcionamiento del algoritmo, se analizará a continuación el concepto de gradiente.

El término *Gradiente* significa pendiente o inclinación, concepto que en la matemática se conoce como *derivada*. En la Figura 7 se presenta gráficamente la función antes descrita y se representa el gradiente en puntos con pendiente negativa positiva y cero.

Figura 7

Ilustración del gradiente




Grado de estabilidad de la red ante cambios aleatorios en los pesos

Cuando una red neuronal acepta cambios aleatorios en los pesos de sus interconexiones, se construyó para evaluar el efecto de esos cambios a partir de variables aleatorias asociadas a distribuciones de probabilidad (Jorge, 2001) indica al respecto que en el aprendizaje estocástico se suele hacer una analogía en términos termodinámicos asociando a la red neuronal con un sólido físico que tiene cierto estado energético. En el caso de la red, la energía representaría el grado de estabilidad de la red, de tal forma que el estado de mínima energía correspondería a una situación en la que los pesos de las conexiones consiguen que su funcionamiento sea el que más se ajusta al objetivo deseado. De acuerdo con lo anteriormente expuesto, el aprendizaje radicaría en hacer una modificación aleatoria de las ponderaciones o pesos y hallar la energía de la red (que habitualmente es una función de Liapunov). Si como consecuencia el valor de la energía disminuye, lo cual significa que el comportamiento de la red es más cercano al deseado, se acepta la modificación, pero, si la energía no disminuye, es posible aceptar la modificación asociada a una función de distribución de probabilidad definida previamente.

Función de activación

Del esquema mostrado,




una característica importante es que siempre en toda neurona está función de activación es no lineal.

Estudiaremos tres de las más importantes funciones de activación, que los expertos en optimización recomiendan, por sus ventajas y desventajas que presentan.

La función sigmoïdal

Figura 8

Función Sigmoïdal



Una característica importante de la función sigmoïdal, es que presenta un comportamiento no lineal. La dificultad que presenta la función sigmoïdal es que, para ciertos valores de entrada, si son negativos muy grandes, la función sigmoïdal presenta un proceso de saturación, es decir, se mantiene prácticamente en cero para ese rango de valores y lo mismo ocurre cuando los valores de entrada son positivos muy grandes produciéndose una saturación en el valor de 1. Esto hace que durante el entrenamiento no se observen muchos cambios en ese proceso de clasificación y recordemos que el método del gradiente descendente funciona o permite encontrar el mínimo de la función de error basado en esos cambios. Esto nos indica que cuando la función se satura los cambios son mínimos y el proceso de entrenamiento puede tomar


demasiado tiempo o puede ser que no converja al mínimo que estamos esperando. Esta es la gran dificultad de la función sigmoideal.

La Función tangente hiperbólica

Figura 9

Función Tangente Hiperbólica

$$f(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$




La función Tangente Hiperbólica es una alternativa a la función Sigmoideal. También es una función no lineal, tiene algún parecido a la función Sigmoideal, pero la diferencia es que el rango de salida está entre -1 a 1. Pero, aún así la función Tangente Hiperbólica tiene exactamente el mismo problema de la función Sigmoideal y es que se satura cuando los valores de entrada son muy negativos o muy positivos, esto es, se satura en -1 y 1. Esto implica un problema para el algoritmo del gradiente descendente porque no va a converger en forma rápida o no va a llegar al mínimo deseado.

Función Rectified Linear Unit (RELU) **(Unidad Lineal Rectificada)**

Figura 10

Función relu

$$f(z) = \text{Relu}(z) = \begin{cases} 0; & z < 0 \\ z; & z \geq 0 \end{cases}$$



La función relu es considerada una función no lineal, a pesar de su apariencia lineal, como se la presenta.

Lo que se observa con la función relu es que el problema de saturación que tenían la función sigmoideal y la función tangente hiperbólica, en este caso no aparece, esto es, no existe el problema de saturación, pues el rango de valores de salida puede estar entre cero y cualquier valor tan alto como deseáramos, dependiendo de cuánto

sea el valor de entrada Z. Esto es, la función relu no tiene limitaciones y por consiguiente cuando se usa el algoritmo del gradiente descendente para entrenar un modelo usando esta función de activación, usualmente convergen mucho más rápido. Este es la ventaja que tiene esta función relu.

En conclusión, podemos decir que cuando se implementan modelos de tipo Deep Neural Network, generalmente en las capas ocultas se recomienda, casi siempre usar este tipo de función de activación, la función relu y dejar la Tangente Hiperbólica o la Sigmoidal o la función Softmax (en el caso de regresión multiclase) dejarla únicamente para la capa de salida en el momento de hacer la clasificación.


A.1.3.3. Ejemplos de funcionamiento de las RNA.

Ejemplo 1: Construir una red neuronal perceptrón de una neurona con 2 entradas y una salida para el conectivo lógico NAND.

Tabla 1

Patrones de entrenamiento NAND

Valores entradas		Valores esperados
x1	x2	y
0	0	1
0	1	1
1	0	1
1	1	0

$$\varphi(v) = \begin{cases} 1 & ; v \geq 0 \\ 0 & ; v < 0 \end{cases}$$


1^{ra} iteración:

$$x = \begin{bmatrix} 0 \\ 0 \end{bmatrix} ; v = (0)(0) + (0)(0) = 0 , \varphi(v) = \varphi(0) = 1$$

$$x = \begin{bmatrix} 0 \\ 1 \end{bmatrix} ; v = (0)(0) + (1)(0) = 0 , \varphi(v) = \varphi(0) = 1$$

$$x = \begin{bmatrix} 1 \\ 0 \end{bmatrix} ; v = (1)(0) + (0)(0) = 0 , \varphi(v) = \varphi(0) = 1$$

$$x = \begin{bmatrix} 1 \\ 1 \end{bmatrix} ; v = (1)(0) + (1)(0) = 0 , \varphi(v) = \varphi(0) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

$$\text{Reestructuramos: } w_1 = w_0 + ex' ; B = B_0 + e \mid x' = \text{transpuesta}$$

$$w_1 = [0 \ 0] + (-1)[1 \] = [-1 \ -1] ; B_1 = [0] + [-1] = [-1]$$

2^{da} iteración:

$$x = \begin{bmatrix} 0 \\ 0 \end{bmatrix} ; v = (-1)(0) + (-1)(0) + (-1) = -1 , \varphi(v) = \varphi(-1) = 0$$

$$\text{Falló: } e = 1 - 0 = 1$$

$$\text{Reestructuramos: } w_2 = w_1 + ex' = [-1 \ -1] + (-1)[0 \ 0] = [-1 \ -1]$$

$$B_2 = B_1 + e = [-1] + [1] = [0]$$

$$x = \begin{bmatrix} 0 \\ 1 \end{bmatrix} ; v = (0)(-1) + (1)(-1) + (0) = -1 , \varphi(v) = \varphi(-1) = 0$$

$$\text{Falló: } e = 1 - 0 = 1$$

$$\text{Reestructuramos: } w_3 = w_2 + ex' = [-1 \ -1] + (1)[0 \ 1] = [-1 \ 0]$$

$$B_3 = B_2 + e = [0] + [1] = [1]$$

$$x = \begin{bmatrix} 1 \\ 0 \end{bmatrix} ; v = (1)(-1) + (0)(0) + (1) = [0] , \varphi(v) = \varphi(0) = 1 \quad \checkmark$$

$$x = \begin{bmatrix} 1 \\ 1 \end{bmatrix} ; v = (1)(-1) + (1)(0) + 1 = 0 , \varphi(v) = \varphi(0) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

Reestructuramos: $w_4 = w_3 + ex' = [-1 \ 0] + (-1)[1 \ 1] = [-2 \ -1]$
 $B_4 = B_3 + e = [1] + [-1] = [0]$

3^{ra} iteración:

$x = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$; $v = (0)(-2) + (0)(-1) + 0 = 0$, $\varphi(v) = \varphi(0) = 1$ ✓

$x = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$; $v = (0)(-2) + (1)(-1) + 0 = -1$, $\varphi(v) = \varphi(-1) = 0$

Falló: $e = 1 - 0 = 1$

Reestructuramos: $w_5 = w_4 + ex' = [-2 \ -1] + (1)[0 \ 1] = [-2 \ 0]$ $x = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$; $v =$
 $B_5 = B_4 + e = [0] + [1] = [1]$

$(1)(-2) + (0)(0) + 1 = -1$, $\varphi(v) = \varphi(-1) = 0$

Falló: $e = 1 - 0 = 1$

Reestructuramos: $w_6 = w_5 + ex' = [-2 \ 0] + (1)[1 \ 0] = [-1 \ 0]$
 $B_6 = B_5 + e = [1] + [1] = [2]$

$x = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$; $v = (1)(-1) + (1)(0) + 2 = 1$, $\varphi(v) = \varphi(1) = 1$

Falló: $e = 0 - 1 = -1$

Reestructuramos: $w_7 = w_6 + ex' = [-1 \ 0] + (-1)[1 \ 1] = [-2 \ -1]$
 $B_7 = B_6 + e = [2] + [-1] = [1]$

4^{ta} iteración:

$x = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$; $v = (0)(-2) + (0)(-1) + 1 = 1$, $\varphi(v) = \varphi(1) = 1$

$x = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$; $v = (0)(-2) + (1)(-1) + 1 = 0$, $\varphi(v) = \varphi(0) = 1$

$x = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$; $v = (1)(-2) + (0)(-1) + 1 = -1$, $\varphi(v) = \varphi(-1) = 0$

Falló: $e = 1 - 0 = 1$

Reestructuramos: $w_8 = w_7 + ex' = [-2 \ -1] + (1)[1 \ 0] = [-1 \ -1]$
 $B_8 = B_7 + e = [1] + [1] = [2]$

$x = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$; $v = (1)(-1) + (1)(-1) + 2 = 0$, $\varphi(v) = \varphi(0) = 1$

Falló: $e = 0 - 1 = -1$

Reestructuramos: $w_9 = w_8 + ex' = [-1 \ -1] + (-1)[1 \ 1] = [-2 \ -2]$
 $B_9 = B_8 + e = [2] + [-1] = [1]$

5^{ta} iteración:

$x = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$; $v = (0)(-2) + (0)(-2) + 1 = 1$, $\varphi(v) = \varphi(1) = 1$ ✓

$x = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$; $v = (0)(-2) + (1)(-2) + 1 = -1$, $\varphi(v) = \varphi(-1) = 0$

Falló: $e = 1 - 0 = 1$

Reestructuramos: $w_{10} = w_9 + ex' = [-2 \ -2] + (1)[0 \ 1] = [-2 \ -1]$
 $B_{10} = B_9 + e = [1] + [1] = [2]$

$x = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$; $v = (1)(-2) + (0)(-1) + 2 = 0$, $\varphi(v) = \varphi(0) = 1$ ✓

$x = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$; $v = (1)(-2) + (1)(-1) + 2 = -1$, $\varphi(v) = \varphi(-1) = 0$ ✓

6^{ta} iteración:

$x = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$; $v = (0)(-2) + (-1)(0) + 2 = 2$, $\varphi(v) = \varphi(2) = 1$ ✓

$x = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$; $v = (0)(-2) + (1)(-1) + 2 = 1$, $\varphi(v) = \varphi(1) = 1$ ✓

$x = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$; $v = (1)(-2) + (0)(-1) + 2 = 0$, $\varphi(v) = \varphi(0) = 1$ ✓

$$x = \begin{bmatrix} 1 \\ 1 \end{bmatrix} ; v = (1)(-2) + (1)(-1) + 2 = -1 , \varphi(v) = \varphi(-1) = 0 \quad \checkmark$$

$$\text{Conclusión: } w = \underbrace{[-2 \ -1]} ; \underbrace{B = [2]}$$

pesos bías

Tabla 2

Patrones de entrenamiento para aprobar el curso de matemática

N°	Promedio del Ciclo Anterior	Número de Cursos	Estado
1	12	5	Desaprobado
2	12	8	Desaprobado
3	17	5	Aprobado
4	17	6	Aprobado

Teorema de normalización:

$$x_N = \frac{x - v_{\text{mínimo}}}{v_{\text{máximo}} - v_{\text{mínimo}}}$$

Diseñar una red para predecir qué alumnos aprobarán o desaprobarán el curso de Matemática en el presente ciclo, teniendo en cuenta que se matricularon 10 alumnos y sus datos se indican en la Tabla 3.

Tabla 3*Patrones del estado de los cursos*

N°	Promedio del ciclo anterior	Número de cursos	Estado
1	08	6	¿?
2	10	5	¿?
3	11	8	¿?
4	12	8	¿?
5	13	3	¿?
6	14	7	¿?
7	15	8	¿?
8	16	3	¿?
9	17	2	¿?
10	18	4	¿?

Solución

- Hallando valores para la normalización: $x_N = ¿?$
 - i) Notas (Promedios del ciclo anterior y del presente ciclo)
 $v = \{12, 12, 17, 17, 08, 10, 11, 12, 13, 14, 15, 16, 17, 18\}$
 $v_{\text{mínimo}} = 08 ; v_{\text{máximo}} = 18$
 - ii) Cursos (número de cursos actuales)
 $v = \{5, 8, 5, 6, 6, 5, 8, 8, 3, 7, 8, 3, 2, 4\}$
 $v_{\text{mínimo}} = 2 ; v_{\text{máximo}} = 8$
- Tabla de entrenamiento (normalizando)
 - ii) Notas (promedio del ciclo anterior)

$$x_1 = \frac{12 - 8}{18 - 8} = \frac{4}{10} = 0,4 \quad x_3 = \frac{17 - 8}{18 - 8} = \frac{9}{10} = 0,9$$

$$x_2 = \frac{12 - 8}{18 - 8} = \frac{4}{10} = 0,4 \quad x_4 = \frac{17 - 8}{18 - 8} = \frac{9}{10} = 0,9$$

i) Cursos (número de cursos actuales)

$$x_1 = \frac{5 - 2}{8 - 2} = \frac{3}{6} = \frac{1}{2} = 0,5 \quad x_3 = \frac{5 - 2}{8 - 2} = \frac{1}{2} = 0,5$$

$$x_2 = \frac{8 - 2}{8 - 2} = \frac{6}{6} = 1 \quad x_4 = \frac{6 - 2}{8 - 2} = \frac{4}{6} = \frac{2}{3} = 0,66$$

Tabla 4

Datos normalizados

N°	Notas	Cursos	Estado
	x_1	x_2	y
1	0,4	0,5	0 (Desaprobado)
2	0,4	1	0 (Desaprobado)
3	0,9	0,5	1 (Aprobado)
4	0,9	0,66	1 (Aprobado)

- Iniciando entrenamiento

$$\varphi(v) = \begin{cases} 1 & ; v \geq 0 \\ 0 & ; v < 0 \end{cases}$$

$$w_1 = 0 ; w_2 = 0 ; b = 0$$

$$w_0 = [0 \ 0]$$

1^{ra} iteración:

$$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix} ; v = (0,4)(0) + (0,5)(0) + 0 = 0 , \varphi(v) = \varphi(0) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

$$\text{Reestructuramos: } w_1 = w_0 + ex' = [0 \ 0] + (-1)[0,4 \ 0,5] = [0 \ 0] + [-0,4 \ -0,5] \\ w_1 = [-0,4 \ -0,5] ; b_1 = b_0 + e = 0 + (-1) = -1$$

$$x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix} ; v = (0,4)(-0,4) + (1)(-0,5) + (-1) = -1,66 , \varphi(v) = \varphi(-1,66) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix} ; v = (0,9)(-0,4) + (0,5)(-0,5) + (-1) = -1,61 , \varphi(v) = \varphi(-1,61) = 0$$

$$\text{Falló: } e = 1 - 0 = 1$$

$$\text{Reestructuramos: } w_2 = w_1 + ex' = [-0,4 \ -0,5] + (1)[0,9 \ 0,5] \\ w_2 = [0,5 \ 0] ; b_2 = b_1 + e = -1 + 1 = 0$$

$$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix} ; v = (0,9)(0,5) + (0,66)(0) + 0 = 0,45 , \varphi(v) = \varphi(0,45) = 1 \quad \checkmark$$

2^{da} iteración:

$$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix} ; v = (0,4)(0,5) + (0,5)(0) + 0 = 0,20 , \varphi(v) = \varphi(0,20) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

$$\text{Reestructuramos: } w_3 = w_2 + ex' = [0,5 \ 0] + (-1)[0,4 \ 0,5] \\ w_3 = [0,1 \ -0,5] ; b_3 = b_2 + e = 0 + (-1) = -1$$

$$x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix} ; v = (0,4)(0,1) + (1)(-0,5) + (-1) = -1,46 , \varphi(v) = \varphi(-1,46) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix} ; v = (0,9)(0,1) + (0,5)(-0,5) + (-1) = -1,16 , \varphi(v) = \varphi(-1,16) = 0$$

$$\text{Falló: } e = 1 - 0 = 1$$

Reestructuramos: $w_4 = w_3 + ex' = [0,1 \ -0,5] + (1)[0,9 \ 0,5]$
 $w_4 = [1 \ 0]$; $b_4 = b_3 + e = -1 + 1 = 0$

$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix}$; $v = (0,9)(1) + (0,66)(0) + 0 = 0,9$, $\varphi(v) = \varphi(0,9) = 1$ ✓

3^{ra} iteración:

$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix}$; $v = (0,4)(1) + (0,5)(0) + 0 = 0,4$, $\varphi(v) = \varphi(0,4) = 1$

Falló: $e = 0 - 1 = -1$

Reestructuramos: $w_5 = w_4 + ex' = [1 \ 0] + (-1)[0,4 \ 0,5]$
 $w_5 = [0,6 \ -0,5]$; $b_5 = b_4 + e = 0 + (-1) = -1$

$x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix}$; $v = (0,4)(0,6) + (1)(-0,5) + (-1) = -1,26$, $\varphi(v) = \varphi(-1,26) = 0$ ✓

$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix}$; $v = (0,9)(0,6) + (0,5)(-0,5) + (-1) = -0,71$, $\varphi(v) = \varphi(-0,71) = 0$

Falló: $e = 1 - 0 = 1$

Reestructuramos: $w_6 = w_5 + ex' = [0,6 \ -0,5] + (1)[0,9 \ 0,5]$
 $w_6 = [1,5 \ 0]$; $b_6 = b_5 + e = -1 + 1 = 0$

$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix}$; $v = (0,9)(1,5) + (0,66)(0) + 0 = 1,35$, $\varphi(v) = \varphi(1,35) = 1$

4^{ta} iteración:

$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix}$; $v = (0,4)(1,5) + (0,5)(0) + 0 = 0,6$, $\varphi(v) = \varphi(0,6) = 1$

Falló: $e = 0 - 1 = -1$

Reestructuramos: $w_7 = w_6 + ex' = [1,5 \ 0] + (-1)[0,4 \ 0,5]$
 $w_7 = [1,1 \ -0,5]$; $b_7 = b_6 + e = 0 + (-1) = -1$

$$(0,4)(1,1) + (1)(-0,5) + (-1) = -1,06, \quad \varphi(v) = \varphi(-1,06) = 0 \quad \checkmark \quad x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix}; v =$$

$$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix}; v = (0,9)(1,1) + (0,5)(-0,5) + (-1) = -0,26, \quad \varphi(v) = \varphi(-0,26) = 0$$

$$\text{Falló: } e = 1 - 0 = 1$$

$$\text{Reestructuramos: } w_8 = w_7 + ex' = [1,1 \quad -0,5] + (1)[0,9 \quad 0,5]$$

$$w_8 = [0,2 \quad 0]; \quad b_8 = b_7 + e = -1 + 1 = 0$$

$$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix}; v = (0,9)(0,2) + (0,66)(0) + 0 = 0,18, \quad \varphi(v) = \varphi(0,18) = 1 \quad \checkmark$$

5^{ta} iteración:

$$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix}; v = (0,4)(0,2) + (0,5)(0) + 0 = 0,08, \quad \varphi(v) = \varphi(0,08) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

$$\text{Reestructuramos: } w_9 = w_8 + ex' = [0,2 \quad 0] + (-1)[0,4 \quad 0,5]$$

$$w_9 = [-0,2 \quad -0,5]; \quad b_9 = b_8 + e = 0 - 1 = -1$$

$$x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix}; v = (0,4)(-0,2) + (1)(-0,5) + (-1) = -1,58, \quad \varphi(v) = \varphi(-1,58) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix}; v = (0,9)(-0,2) + (0,5)(-0,5) + (-1) = -1,43, \quad \varphi(v) = \varphi(-1,43) = 0$$

$$\text{Falló: } e = 1 - 0 = 1$$

$$\text{Reestructuramos: } w_{10} = w_9 + ex' = [-0,2 \quad -0,5] + (1)[0,9 \quad 0,5]$$

$$w_{10} = [0,7 \quad 0]; \quad b_{10} = b_9 + e = -1 + 1 = 0$$

$$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix}; v = (0,9)(0,7) + (0,66)(0) + 0 = 0,63, \quad \varphi(v) = \varphi(0,63) = 1 \quad \checkmark$$

6^{ta} iteración:

$$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix} ; v = (0,4)(0,7) + (0,5)(0) + 0 = 0,28 , \varphi(v) = \varphi(0,28) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

$$\text{Reestructuramos: } \begin{aligned} w_{11} &= w_{10} + ex' = [0,7 \ 0] + (-1)[0,4 \ 0,5] \\ w_{11} &= [0,3 \ -0,5]; \quad b_{11} = b_{10} + e = 0 + (-1) = -1 \end{aligned}$$

$$x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix} ; v = (0,4)(0,3) + (1)(-0,5) + (-1) = -1,38 , \varphi(v) = \varphi(-1,38) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix} ; v = (0,9)(0,3) + (0,5)(-0,5) + (-1) = -0,98 , \varphi(v) = \varphi(-0,98) = 0$$

$$\text{Falló: } e = 1 - 0 = 1$$

$$\text{Reestructuramos: } \begin{aligned} w_{12} &= w_{11} + ex' = [0,3 \ -0,5] + (1)[0,9 \ 0,5] \\ w_{12} &= [1,2 \ 0]; \quad b_{12} = b_{11} + e = (-1) + 1 = 0 \end{aligned}$$

$$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix} ; v = (0,9)(1,2) + (0,66)(0) + 0 = 1,08 , \varphi(v) = \varphi(1,08) = 1 \quad \checkmark$$

7^{ma} iteración:

$$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix} ; v = (0,4)(1,2) + (0,5)(0) + 0 = 0,48 , \varphi(v) = \varphi(0,48) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

$$\text{Reestructuramos: } \begin{aligned} w_{13} &= w_{12} + ex' = [1,2 \ 0] + (-1)[0,4 \ 0,5] \\ w_{13} &= [0,8 \ -0,5]; \quad b_{13} = b_{12} + e = 0 + (-1) = -1 \end{aligned}$$

$$x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix} ; v = (0,4)(0,8) + (1)(-0,5) + (-1) = -1,18 , \varphi(v) = \varphi(-1,18) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix} ; v = (0,9)(0,8) + (0,5)(-0,5) + (-1) = -0,53 , \varphi(v) = \varphi(-0,53) = 0$$

$$\text{Falló: } e = 1 - 0 = 1$$

$$\text{Reestructuramos: } \begin{aligned} w_{14} &= w_{13} + ex' = [0,8 \ -0,5] + (1)[0,9 \ 0,5] \\ w_{14} &= [1,7 \ 0]; \quad b_{14} = b_{13} + e = -1 + 1 = 0 \end{aligned}$$

$$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix} ; v = (0,9)(1,7) + (0,66)(0) + 0 = 1,53 , \varphi(v) = \varphi(1,53) = 1 \quad \checkmark$$

8^{va} iteración:

$$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix} ; v = (0,4)(1,7) + (0,5)(0) + 0 = 0,68 , \varphi(v) = \varphi(0,68) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

$$\text{Reestructuramos: } \begin{aligned} w_{15} &= w_{14} + ex' = [1,7 \ 0] + (-1)[0,4 \ 0,5] \\ w_{15} &= [1,3 \ -0,5] ; b_{15} = b_{14} + e = 0 + (-1) = -1 \end{aligned}$$

$$x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix} ; v = (0,4)(1,3) + (1)(-0,5) + (-1) = -0,98 , \varphi(v) = \varphi(-0,98) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix} ; v = (0,9)(1,3) + (0,5)(-0,5) + (-1) = -0,08 , \varphi(v) = \varphi(-0,08) = 0$$

$$\text{Falló: } e = 1 - 0 = 1$$

$$\text{Reestructuramos: } \begin{aligned} w_{16} &= w_{15} + ex' = [1,3 \ -0,5] + (1)[0,9 \ 0,5] \\ w_{16} &= [2,2 \ 0] ; b_{16} = b_{15} + e = (-1) + 1 = 0 \end{aligned}$$

$$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix} ; v = (0,9)(2,2) + (0,66)(0) + 0 = 1,98 , \varphi(v) = \varphi(1,98) = 1 \quad \checkmark$$

9^{na} iteración:

$$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix} ; v = (0,4)(2,2) + (0,5)(0) + 0 = 0,88 , \varphi(v) = \varphi(0,88) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

$$\text{Reestructuramos: } \begin{aligned} w_{17} &= w_{16} + ex' = [2,2 \ 0] + (-1)[0,4 \ 0,5] \\ w_{17} &= [1,8 \ -0,5] ; b_{17} = b_{16} + e = 0 + (-1) = -1 \end{aligned}$$

$$x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix} ; v = (0,4)(1,8) + (1)(-0,5) + (-1) = -0,78 , \varphi(v) = \varphi(-0,78) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix} ; v = (0,9)(1,8) + (0,5)(-0,5) + (-1) = 0,37 , \varphi(v) = \varphi(0,37) = 1$$

$$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix} ; v = (0,9)(1,8) + (0,66)(-0,5) + (-1) = 0,29 , \varphi(v) = \varphi(0,29) = 1 \quad \checkmark$$

10^{ma} iteración:

$$x = \begin{bmatrix} 0,4 \\ 0,5 \end{bmatrix} ; v = (0,4)(1,8) + (0,5)(-0,5) + (-1) = -0,53 , \varphi(v) = \varphi(-0,53) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,4 \\ 1 \end{bmatrix} ; v = (0,4)(1,8) + (1)(-0,5) + (-1) = -0,78 , \varphi(v) = \varphi(-0,78) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,9 \\ 0,5 \end{bmatrix} ; v = (0,9)(1,8) + (0,5)(-0,5) + (-1) = 0,37 , \varphi(v) = \varphi(0,37) = 0 \quad \checkmark$$

$$x = \begin{bmatrix} 0,9 \\ 0,66 \end{bmatrix} ; v = (0,9)(1,8) + (0,66)(-0,5) + (-1) = -0,29 , \varphi(v) = \varphi(0,29) = 1 \quad \checkmark$$

Pesos y vías obtenidos para realizar la evaluación a los 10 alumnos que aprobarán o desaprobarán el curso de Matemática

$$w = [1,8 \quad -0,5] ; b = -1$$

Tabla 5*Evaluación Normalizada*

N°	Notas	Cursos	Estado
	x_1	x_2	y
1	0	0,66	0
2	0,2	0,5	0
3	0,3	1	0
4	0,4	1	0
5	0,5	0,16	0
6	0,6	0,83	0
7	0,7	1	0
8	0,8	0,16	1
9	0,9	0	1
10	1	0,33	1

i) Nota (promedio del ciclo anterior)

$$x_1 = \frac{8-8}{18-8} = \frac{0}{10} = 0$$

$$x_2 = \frac{10-8}{18-8} = \frac{2}{10} = 0,2$$

$$x_3 = \frac{11-8}{18-8} = \frac{3}{10} = 0,3$$

$$x_4 = \frac{12-8}{18-8} = \frac{4}{10} = 0,4$$

$$x_5 = \frac{13-8}{18-8} = \frac{5}{10} = 0,5$$

$$x_6 = \frac{14-8}{18-8} = \frac{6}{10} = 0,6$$

$$x_7 = \frac{15-8}{18-8} = \frac{7}{10} = 0,7$$

$$x_8 = \frac{16-8}{18-8} = \frac{8}{10} = 0,8$$

$$x_9 = \frac{17-8}{18-8} = \frac{9}{10} = 0,9$$

$$x_{10} = \frac{18-8}{18-8} = 1$$

ii) **Cursos (números cursos actuales)**

$$x_1 = \frac{6-2}{8-2} = \frac{4}{6} = \frac{2}{3} = 0,66$$

$$x_2 = \frac{5-2}{8-2} = \frac{3}{6} = \frac{1}{2} = 0,5$$

$$x_3 = \frac{8-2}{8-2} = 1$$

$$x_4 = \frac{8-2}{8-2} = 1$$

$$x_5 = \frac{3-2}{8-2} = \frac{1}{6} = 0,1\hat{6} = 0,16$$

$$x_6 = \frac{7-2}{8-2} = \frac{5}{6} = 0,8\hat{3}$$

$$x_7 = \frac{8-2}{8-2} = 1$$

$$x_8 = \frac{3-2}{8-2} = \frac{1}{6} = 0,1\hat{6} = 0,16$$

$$x_9 = \frac{2-2}{8-2} = \frac{0}{6} = 0$$

$$x_{10} = \frac{4-2}{8-2} = \frac{2}{6} = \frac{1}{3} = 0,\hat{3}$$

iii) **Iniciando evaluación**

$$\begin{bmatrix} 0 \\ 0,66 \end{bmatrix} ; v = (0)(1,8) + (0,66)(-0,5) + (-1) = -1,33 , \varphi(v) = \varphi(-1,33) = 0$$

$$\begin{bmatrix} 0,2 \\ 0,5 \end{bmatrix} ; v = (0,2)(1,8) + (0,5)(-0,5) + (-1) = -0,89 , \varphi(v) = \varphi(-0,89) = 0$$

$$\begin{bmatrix} 0,3 \\ 1 \end{bmatrix} ; v = (0,3)(1,8) + (1)(-0,5) + (-1) = -0,96 , \varphi(v) = \varphi(-0,96) = 0$$

$$\begin{bmatrix} 0,4 \\ 1 \end{bmatrix} ; v = (0,4)(1,8) + (1)(-0,5) + (-1) = -0,78 , \varphi(v) = \varphi(-0,78) = 0$$

$$\begin{bmatrix} 0,5 \\ 0,16 \end{bmatrix} ; v = (0,5)(1,8) + (0,16)(-0,5) + (-1) = -0,18 , \varphi(v) = \varphi(-0,18) = 0$$

$$\begin{bmatrix} 0,6 \\ 0,83 \end{bmatrix} ; v = (0,6)(1,8) + (0,83)(-0,5) + (-1) = -0,335 , \varphi(v) = \varphi(-0,335) = 0$$

$$\begin{bmatrix} 0,7 \\ 0,1 \end{bmatrix} ; v = (0,7)(1,8) + (1)(-0,5) + (-1) = -0,24 , \varphi(v) = \varphi(-0,24) = 0$$

$$\begin{bmatrix} 0,8 \\ 0,16 \end{bmatrix} ; v = (0,8)(1,8) + (0,16)(-0,5) + (-1) = 0,36 , \varphi(v) = \varphi(0,36) = 1$$

$$\begin{bmatrix} 0,9 \\ 0 \end{bmatrix} ; v = (0,9)(1,8) + (0)(-0,5) + (-1) = 0,62 , \varphi(v) = \varphi(0,62) = 1$$

$$\begin{bmatrix} 1 \\ 0,33 \end{bmatrix} ; v = (1)(1,8) + (0,33)(-0,5) + (-1) = 0,635 , \varphi(v) = \varphi(0,635) = 1$$


Ejemplo 3: Construir una Red Neuronal perceptrón con dos entradas y una salida.

Tabla 6

Patrones de entrenamiento

x_1	x_2	Salida deseada = S_d
1	10	0
5	2	1
7	3	1

$$\varphi(v) = \begin{cases} 1 ; v \geq 0 \\ 0 ; v < 0 \end{cases}$$



1^{ra} iteración:

$$\begin{bmatrix} 1 \\ 10 \end{bmatrix} ; v = (1)(0) + (10)(0) + 0 = 0 , \varphi(v) = \varphi(0) = 1$$

$$\text{Falló: } e = 0 - 1 = -1$$

Reestructuramos:

$$w_1 = w_0 + ex' = [0 \ 0] + (-1)[1 \ 10] = [-1 \ -10] ; b_1 = b_0 + e = 0 + (-1) = -1$$

$$\begin{bmatrix} 5 \\ 2 \end{bmatrix} ; v = (5)(-1) + (2)(-10) + (-1) = -26 , \varphi(v) = \varphi(-26) = 1$$

$$\text{Falló: } e = 1 - 0 = 1$$

Reestructuramos:

$$w_2 = w_1 + ex' = [-1 \ -10] + (1)[5 \ 2] = [4 \ -8] ; b_2 = b_1 + e = -1 + 1 = 0$$

$$\begin{bmatrix} 7 \\ 3 \end{bmatrix} ; v = (7)(4) + (3)(-8) + 0 = 4 , \varphi(v) = \varphi(4) = 1 \quad \checkmark$$

2da iteración:

$$\begin{bmatrix} 1 \\ 10 \end{bmatrix} ; v = (1)(4) + (10)(-8) + 0 = -76 , \varphi(v) = \varphi(-76) = 0 \quad \checkmark$$

$$\begin{bmatrix} 5 \\ 2 \end{bmatrix} ; v = (5)(4) + (2)(-8) + 0 = 4 , \varphi(v) = \varphi(4) = 1 \quad \checkmark$$

$$\begin{bmatrix} 7 \\ 3 \end{bmatrix} ; v = (7)(4) + (3)(-8) + 0 = 4 , \varphi(v) = \varphi(4) = 1 \quad \checkmark$$

Conclusión: $w = [4 \ -8] ; b = 0$

Las redes neuronales todavía se encuentran dentro de un proceso de amplio desarrollo en el área de la investigación. Aún existe un amplio panorama futuro sobre el campo de acción en que las redes neuronales serán útiles y sobre su funcionamiento, sobre el tiempo que requiere una RNA para aprender una tarea determinada, la cantidad de neuronas que la deben constituir para realizar una tarea, entre muchos otros aspectos de interés. Debido a los éxitos obtenidos en la aproximación de funciones matemáticas utilizando las RNA tienen un amplio campo de posibilidades en la Ciencia Matemática. Los éxitos de Kolmogorov (1957) y luego los de Sprecher (1965), quien mejoró las representaciones de Kolmogorov, permitieron fundamentar matemáticamente la teoría de las redes neuronales. Pero, fue Robert Hecht Nielsen (1987) que, basándose en los resultados de Sprecher, demuestra que

existen RNA que representan o implementan funciones continuas ilustradas en el Anexo 3). Podríamos decir que la parte crucial en este trabajo de investigación fue la construcción de las redes neuronales usando el software MATLAB. Para ello, debíamos conocer la arquitectura de la red neuronal, el aprendizaje y entrenamiento de la red neuronal, la evaluación del desempeño de la red neuronal y, finalmente, pasar por el proceso de programación de la red neuronal en MATLAB.

A.2. Salud Pública

Desde marzo de 2020 el Perú, así como todos los países del mundo se enfrentan a un grave problema de salud pública ocasionado por la propagación del coronavirus, en la enfermedad de naturaleza pandémica denominada Covid-19, problema que ha evidenciado las falencias en el sistema de salud pública del país, mostradas en la escasa infraestructura para la atención adecuada de la salud, especialmente a las poblaciones más deprimidas económicamente.

El gobierno central, así como las autoridades de salud desarrollan grandes esfuerzos e invierten ingentes recursos para combatir esta enfermedad, sin embargo, el comportamiento social no va de la mano con los esfuerzos que se realizan para combatir esta grave enfermedad.

Se vivió en enero de 2021 un rebrote peligroso de la enfermedad, identificado como segunda ola tal que las cifras de contagio y muerte que ya venían disminuyendo significativamente, ante la apertura de las actividades económicas y la aparición de nuevas cepas del virus.

El desarrollo agresivo de esta enfermedad ha producido hasta finales de diciembre de 2020, aproximadamente algo más de un millón de contagios y también aproximadamente algo menos de cuarenta mil fallecidos, (Universidad John Hopkins, 2020).

Es importante resaltar que, ante el desarrollo de la vacunación masiva de la población, que al mes de octubre 2021 alcanzara al 50% de la población objetivo de vacunación, se redujo a un mínimo la cantidad de contagios y fallecimientos por la Covid-19.

La situación descrita motivó nuestro interés en estudiar los cambios demográficos de la población de Lima Metropolitana, influenciados de manera importante por el desarrollo de la enfermedad Covid-19 y por los nacimientos durante este período 2020, (Instituto Nacional de Estadística e Informática [INEI, 2020]). También, es nuestro interés proyectar esos cambios demográficos al período 2021-2025 así como analizar el impacto en las principales actividades socio económicas de Lima-Metropolitana.

A.3. Variación poblacional

La variación de una población está relacionada con la Demografía, la cual estudia estadísticamente a las poblaciones humanas, así como su estructura, dimensión, evolución y algunos procesos que van a determinar su formación, conservación y desaparición. La población varía como consecuencia de los nacimientos, muertes y migración.

A.3.1. Natalidad y Tasa de Natalidad

La *natalidad* es una variable que representa la cantidad de nacimientos producidos en un área y tiempo precisados. La natalidad se analiza por medio de la *tasa de natalidad*.

Como menciona Vallin (1994) la tasa de natalidad mide la capacidad de procrear nuevos individuos. Para hallar la tasa de natalidad se usa la siguiente expresión:

$$TN = (n / p) \times 100$$

TN: tasa de natalidad

n: cantidad total de nacidos vivos en un año

p: población total

A.3.2. Mortalidad y Tasa de Mortalidad

La *mortalidad* es empleada al expresar los fallecimientos ocurridos en una población. El fallecimiento está asociado a factores tales como la edad, la enfermedad, el tiempo en el que ocurre y la circunstancias por las que se produce. El análisis de la mortalidad se hace por medio de la *tasa de mortalidad*.

Vallin (1994), se refiere a la *tasa de mortalidad* como la propensión a perder individuos. Para hallar la *tasa de mortalidad* se utiliza la siguiente expresión:

$$TM = (f / p) \times 100$$

TM: tasa de mortalidad

f: cantidad total de fallecidos en un año

p: población total

A.3.3. Migración y Tasa de Migración

La migración o desplazamiento de personas al interior (inmigración) o al exterior de un área geográfica (emigración) es un fenómeno que influye en la dinámica poblacional, social y económica de un país o región. La migración puede estar impulsada por factores sociales, económicos, religiosos, de violencia e impacta en el

país o región que recibe al migrante. En la presente investigación no se toma en consideración este factor debido a que durante el año 2020 en que se desarrolló la pandemia no hubo migración o no fue resaltante durante ese período.

B. Investigaciones

Las investigaciones se han distribuido según el tema desarrollado relacionado a las variables de este trabajo de investigación. En cada documento se han revisado los objetivos, a continuación, se describe el desarrollo, la metodología de estudio y por último se presenta los resultados y/o conclusiones incluyendo los aportes a datos por los autores en cada investigación citada a continuación.

B.1. Investigaciones Sobre Redes Neuronales Artificiales.

B.1.1. Investigación n° 1

Ramírez y Chacón (2011). “Redes Neuronales Artificiales para el procesamiento de imágenes. Una revisión de la última década”. Revista de Ingeniería Eléctrica, Electrónica y Computación, Vol. 9 No. 1, julio 2011.

Objetivo

En esta investigación se revisa una amplia cantidad de artículos (200) en los que se presenta algoritmos con determinadas estructuras de redes neuronales. Se analizan trabajos hallados en la revisión y organizados de acuerdo con la naturaleza del procesamiento realizado por las RNA, finalmente se presentan las conclusiones del estudio de investigación.

Desarrollo

Se realiza el estudio y desarrollo de modelos de RNA dedicados a la clasificación en minería de datos. Se comprime un clasificador neuronal con alto desempeño utilizando un modelo de RNA: Se presentan, además, modelos de mayor

complejidad para la comprensión de arreglos de clasificadores de diversa complejidad y también aplicaciones reales de reconocimiento de patrones, en este caso de rostros. También, se realiza la propuesta de un clasificador neuronal aplicado a un problema real de I+D en la Literatura. Se modela mediante RNA las relaciones existentes entre series de tiempo de Bioinformática, probadas en conjuntos de datos artificiales.

En el trabajo de investigación se hace una revisión histórica de las RNA's. Refiere que, en el inicio, de acuerdo con las ideas de McCulloch y Pitts (1943), se consideró a las neuronas como dispositivos booleanos, lo cual permitió representar una neurona mediante un modelo de tipo lineal asociado a una función booleana. La función lineal representa el fenómeno de sinapsis que ocurre entre neuronas biológicas, es decir, la unión entre neuronas, así como la acumulación de la información. La función booleana representa la función de procesamiento que desarrolla una neurona. El siguiente es un modelo que representa lo indicado:

$$r = \sum_{i=1,n} x_i w_i + b$$

x_i , representa los datos de entrada

w , representa los pesos o ponderaciones sinápticas


b , representa un factor de polarización

r , es el resultado procesado por una función binaria que toma el valor uno o cero a la salida.

Se señala que el **Perceptrón** es el primer modelo de RNA que se usó, utiliza una red neuronal como la presentada en la Figura 11.

Figura 11

Modelo original Perceptrón de neurona artificial con salida binaria



Fuente propia

El modelo Perceptrón posee tres capas de neuronas y un algoritmo de aprendizaje. A partir de este se crearon otras redes neuronales binarias para detectar imágenes.

Así, existen las redes con función continua como las sigmoidales y las radiales, (Egmont-Petersen, Ridder y Handels, 2002) cuyos modelos son:


$$f(r) = 1/(1+\exp(-ar)), \text{ función sigmoideal}$$

$$f(x, c) = f(\|x - c\|), \text{ función de base radial}$$

α : inclinación de la función, c: punto centro

Figura 12


Esquema Sigmoidal de Egmont-Petersen



Fuente: Egmont-Petersen, Ridder y Handels, (2002)

Figura 13

Función de base radial



Fuente: Egmont-Petersen, Ridder y Handels, (2002)

En segundo lugar, se considera la Teoría de Resonancia Adaptativa, cuyo modelo de RNA funciona de manera similar a cómo el cerebro procesa la información.

Esa forma de aprendizaje puede ser supervisada o no supervisada.

Otro modelo es la *Red Neuronal Celular*, basada en la Teoría de Autómatas Celulares, (Grossberg & Carpenter, 1998), este tipo de red permite la interrelación entre los vecinos de cada elemento de la red conformada por células en una cantidad predeterminada. Las células son sistemas no lineales, que evolucionan en el tiempo, las cuales codifican la información para conocer su actuación. También, cada célula se interrelaciona con varias entradas correspondientes a otras células. Estas redes sirven para el reconocimiento de bordes de formas, por ejemplo, siluetas de personas.

También existen las *Redes Perceptrón Multicapa y Backpropagation*, (Narashima et.al., 2008), las cuales son funciones de activación del tipo sigmoideal que aprenden mediante mecanismos del tipo Backpropagation. Estas redes se utilizan con frecuencia para validar el desarrollo de algoritmos de Optimización de Redes Neuronales.

Existen también las *Redes Neuronales Oscilatorias* que sirven para detectar características en un escenario visual con lo que se modelan redes oscilantes que se sincronizan sucesivamente según el patrón de entrada. Esa oscilación se genera a partir de la retroalimentación de un vecindario de elementos excitables y de un inhibidor del movimiento global. Con estas redes se segmentan objetos y texturas.

Además, existen *Redes Neuronales Pulso-Acopladas*, con una arquitectura de tres módulos: dendritas que reciben la información, el módulo de encadenamiento que la procesa y generador de pulsos. Estas redes se usan en procesamiento de imágenes, ruidos, detección de objetos, de personas.

Existen las *Redes Neuronales Recurrentes* que tienen conexiones formando un ciclo directo. Se usan en reconocimiento de formas, movimientos, clasificación y agrupación de datos y también en localización de objetos (Bianchini et al., 2006).

Las *Redes Neuronales con funciones de base radial* son funciones de activación gaussiana formadas por lo general por tres capas, la capa de entrada, la capa oculta con funciones de base radial y la capa de salida, se utilizan en segmentación de tejidos humanos para estudios médicos, inspección de calidad en procesos industriales, reconocimiento de rostros, categorización y recuperación de datos (Veera, 2010).

Existen las *Redes Neuronales Probabilísticas* que son de tres tipos: la red neuronal probabilística propiamente dicha, que es una red semi supervisada basada en las redes de decisión bayesiana, con cuatro capas, la primera de ellas tiene el vector de entradas, la segunda está constituida por neuronas unidas a la capa anterior, cuya función de activación es:

$$\Phi_{jk}(x) = (1/((2\pi\sigma)^d)) e^{(-1/2\sigma^2(x - m_{jk})^2)}$$

d, es el tamaño del vector

x es la entrada

m_{jk}^x es la media del j-ésimo vector

k es la clase

σ es un parámetro de suavización

La tercera capa es la capa de suma para la estimación de la probabilidad.

La cuarta capa clasifica la entrada según el proceso de decisión de Bayes.

Existe además el *Mapa Auto organizado de Kohonen* que es una red no supervisada con cada neurona sensitiva a las categorías de las entradas. Utiliza el

aprendizaje competitivo para que las neuronas se aproximen a la distribución de datos de entrada. Estas redes se usan en reconocimiento de patrones y de textos.

Tenemos también las Redes Pulsantes que se basan en el sistema nervioso de los animales generando una serie de potenciales de acción posibles de ser analizados como señales a través del tiempo.

Esas señales generan picos cuya frecuencia entre pulsos y forma contiene la información útil para la percepción y procesamiento de información.

A diferencia del modelo de McCulloch y Pitts la información que codifica una neurona no es una constante binaria. Así tenemos las funciones de activación continuas en estas RNA.

Casi todos estos modelos se establecen como *ecuaciones diferenciales* que definen la actividad de una neurona biológica como el modelo de Hodgkin-Huxley:

$$(dv/ dt) = 0.04v^2 + 5v + 140 - u + I$$

$$(du/dt) = a(bv - u)$$

El pico se replica cuando $v \geq 30\text{mV}$

$$v \leftarrow -65\text{mV}$$

$$u \leftarrow u + 2$$

u, v son variables dimensionales

a, b son parámetros dimensionales

t es el tiempo

Resultado

Se revisaron 167 artículos de investigación, pudiendo observarse que las redes neuronales artificiales tuvieron un uso frecuente en trabajos de segmentación de

formas, color, textura, movimiento, clasificación de datos, siendo la segmentación de formas la aplicación más común de varias arquitecturas de RNA para procesar imágenes que no tienen patrón repetible tales como tejidos biológicos, inspección de productos, patrones biométricos para identificación de personas, que pueden usarse, para reconocer y realizar el conteo de personas fallecidas como en casos de Covid-19.

B.1.2. Investigación n° 2

Rubiolo (2014). “Desarrollo de nuevos modelos y algoritmos basados en redes neuronales para tareas de minería de datos”,

En la investigación se construye y analiza modelos de RNA que realizan clasificaciones en minería de datos. Se utiliza las RNA para representar relaciones entre series temporales en la Bioinformática. Para probarlas se utilizaron datos reales y datos simulados.

Objetivo

El objetivo de la investigación es utilizar las RNA para construir modelos, herramientas computacionales y algoritmos para realizar análisis, clasificación y reconocimiento de patrones de comportamiento en registros de datos, cuyo tratamiento con otros métodos es inadecuado e insuficiente.

Desarrollo

En esta investigación se estudió y desarrolló nuevos modelos y algoritmos para mantener altas tasas de clasificación de datos. Se trabajó sobre modelos neuronales en diferentes campos de aplicación y tiempo. Se inició el abordaje de redes neuronales para minería de relaciones entre series temporales en problemas de Bioinformática. Se planteó el nuevo modelo Volterra-NN para comprimir un clasificador de datos en un menor número de parámetros y manteniendo las altas tasas de desempeño del

clasificado, lo cual se probó en problemas de Machine Learning. Se extendió ese modelo a problemas más complejos que involucran más clases y más variables, con un arreglo denominado aV-NN que permite tratar problemas de mayor complejidad y cantidad de clases. Este modelo se probó y validó en problemas clásicos de reconocimiento de patrones.

También se trabajó en un enfoque novedoso para solucionar un problema de interés en Bioinformática, que consiste en reconstruir una red de regulación de genes a partir de los datos de expresión de varios genes candidatos, lo cual se hizo mediante el modelado de la interacción entre cada par de genes utilizando una Red Neuronal Artificial.

Resultados

Los resultados mostraron que el modelo de clasificación usando una red neuronal artificial, que se pueden alcanzar altas tasas de clasificación, de aproximadamente el 80% en cada clase y en el promedio de todas las clases. Se verificó además que el enfoque de minería de relaciones fue capaz de descubrir todas las interacciones entre genes.

B.1.3. Investigación n° 3

Montaño (2002) en la tesis doctoral “Redes neuronales artificiales aplicadas al análisis de datos”, (2002) Tesis doctoral.

Se estudia RNA orientadas a realizar aplicaciones estadísticas, análisis de datos, análisis de sobrevivencia y al análisis de los efectos de las variables en una RNA perceptrón multicapa. Finalmente determina cuál es el método de evaluación más precisa de las variables de entrada sean discretas o continuas.

Objetivo

En la investigación se busca determinar cómo funciona una RNA del tipo Perceptrón multicapa con entrenamiento backpropagation con por lo menos una capa oculta que aprende el comportamiento de cualquier tipo de función continua que relacione las variables de entrada con las de salida.

Desarrollo

(2) Las RNA se utilizan para analizar el funcionamiento del sistema nervioso, los procesos para la adquisición de conocimiento, así como a resolver problemas como la predicción de funciones, aplicándose de este modo en la psicología, medicina, ingeniería, biología, economía (Arbib, 1995), con resultados apreciables respecto a modelos asociados con la estadística tradicional (Jang, 1998).

El cálculo paralelo, la memoria distribuida y la adaptabilidad al medio externo hacen de las RNA herramientas potentes para el aprendizaje de relaciones entre variables.

Es importante resaltar que la Teoría de Redes Neuronales Artificiales y la Estadística usan denominaciones diferenciadas para los mismos aspectos y al mismo tiempo consideran la semejanza entre las RNA y los modelos estadísticos (Sarle, 1994). En la tabla 7 se presenta la equivalencia de términos entre ambas áreas.

Tabla 7*Equivalencia entre términos estadísticos y de RNA*

TÉRMINOLOGÍA ESTADÍSTICA	TÉRMINOLOGÍA DE REDES NEURONALES
Análisis de Clúster	Aprendizaje Competitivo
Coeficientes	Pesos de Conexión
Constante	Peso Umbral
Error Aleatorio	Ruido
Estimación	Entrenamiento, Aprendizaje
Interacción	Conexión Funcional
Interpolación	Generalización
Modelo	Arquitectura
Muestra	Datos de Entrenamiento
Muestra de Validación	Datos de Validación, Test
Observación	Patrón
Reducción de Datos	Aprendizaje No Supervisado o Auto Asociación
Regresión y Análisis	Aprendizaje Supervisado o Hetero
Discriminante	Asociación
Residual	Error
Variable de Respuesta	Variable de Salida
Variables Explicativas	Variables de Entrada

En la tabla 8 se presenta la equivalencia entre modelos estadísticos y modelos de RNA, desarrollada en la investigación.

Tabla 8*Comparación entre modelos estadísticos y modelos RNA*

MODELOS ESTADÍSTICOS	MODELOS DE REDES NEURONALES
Análisis de Clústeres	Mapas Autoorganizados de Kohonen
Análisis de Componentes Principales	Regla de Oja, Perceptrón Multicapa Autoasociativa
Función Discriminante Lineal	Perceptrón Simple con Función Lineal
Función Discriminante No Lineal	Perceptrón Multicapa con Función Logística en la Salida
K Vecinos más Cercanos	Learning Vector Quantization (LVQ)
Regresión Kernel	Funciones de Base Radial (RBF)
Regresión Lineal Múltiple	Perceptrón simple con función lineal
Regresión logística	Percepción simple con función Perceptrón multicapa con
Regresión no lineal múltiple	función lineal en la salida

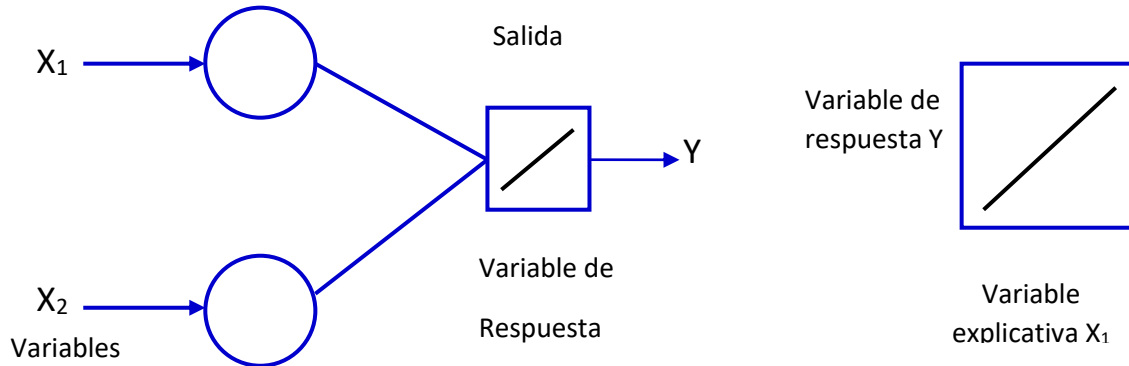
FUENTE: Autor: Sarle (1994)

De este modo queda establecido que las RNA que se aplican al análisis de datos tienen modelos estadísticos similares, sin embargo, las similitudes se limitan a las funciones predictivas, pero no a las explicativas.

A continuación, en la Figura 14 se presenta gráficamente y mediante la representación matemática, la red neuronal perceptrón simple con función lineal y el modelo estadístico equivalente.

Figura 14

Perceptrón simple con función lineal = Modelo de regresión lineal



Fuente: Sarle (1994)

(2) Matemáticamente se representa esta RNA de forma semejante al modelo estadístico de regresión lineal y es la siguiente:

$$Y_{ij} = \alpha_j + \sum_{k=1,n} W_{kj} \cdot X_{ik}$$

α_j , es el umbral de la neurona de salida j , cuyo rol es el mismo que la constante del modelo de regresión.

N , es el número de neuronas de entrada.

W_{kj} , es el peso o ponderación entre la neurona de entrada k y la neurona de salida j .

X_{ik} , es el valor de la neurona de entrada k para el patrón i

Cuando existen varias neuronas, la RNA es equivalente con un *modelo de regresión multivariado*.

De manera similar, es posible representar otras RNA gráficamente y asociarla según sus características a los modelos estadísticos correspondientes.

Resultados

En la tesis se describen tres líneas de investigación respecto al uso de las redes neuronales artificiales para analizar datos, en tres niveles diferentes. Se utilizó las redes neuronales artificiales para realizar predicciones en los comportamientos adictivos, luego, se han aplicado en el análisis de sobrevivencia para comparar modelos estadísticos tradicionalmente usados y se estudió las RNA para verificar cómo superan la dificultad de analizar cuán importantes son las variables de entrada en la red.

Se determina que las tres líneas de investigación son importantes en el análisis de datos. Además, se verifica que las RNA tienen capacidad de predecir el consumo de un tipo particular de droga. Se obtiene que existen redes neuronales artificiales del tipo jerárquico y secuencial que son superiores al modelo estadístico de Cox para el análisis de sobrevivencia y que las redes neuronales son importantes instrumentos de predicción poco usados en ese sentido.

B.1.4. Investigación N° 4

Pérez, J. En la tesis doctoral “Modelos predictivos basados en redes neuronales recurrentes de tiempo discreto”, (2002), analiza la aplicación de diferentes RNA de tiempo discreto para realizar predicciones. Determina que las RNA recurrentes desarrollan diferentes ciclos en la interconexión de sus unidades de procesamiento, gracias a lo cual trabajan con series temporales. La tesis se centra en la utilización de las RNA para predecir los sucesivos elementos de una secuencia numérica.

Objetivo

Mostrar el uso de las RNA para la predicción de los sucesivos elementos de las secuencias numéricas y mostrar la capacidad que tienen las redes recurrentes de predicción de los siguientes elementos de las secuencias.

Desarrollo

Las redes neuronales recurrentes son modelos computacionales más potentes que las RNA tradicionales debido a que tienen la capacidad de procesar secuencias temporales gracias a la capacidad que tienen de memorizar la historia de la secuencia a través de la definición de estados, lo cual no ocurre en las redes no recurrentes que procesan datos estáticos, esto indica que existe una relación cíclica entre las neuronas que conforman las redes recurrentes.

Las redes neuronales artificiales se clasifican respecto al tiempo en RNA de tiempo discreto y de tiempo continuo. En las RNA de tiempo discreto; por su naturaleza, los cálculos de acuerdo con saltos o pasos en el tiempo hallándose la salida de cada neurona a partir de su entrada. Cuando la RNA es de tiempo continuo tanto las entradas como las salidas son funciones de variables de tiempo continuo, en cuyo caso la actividad de las neuronas está definida por una ecuación diferencial.

Resultado

Se concluyó que las redes neuronales recurrentes simples o parcialmente recurrentes no tienen tanta capacidad de memorizar, especialmente cuando trabajan con secuencias más complejas. Además, para la mayoría de las redes neuronales recurrentes es difícil desarrollar eficientemente las predicciones cuando los tiempos se hacen más extensos.

B.1.5. Investigación N° 5

García, M., Rodríguez, Y., Ramón, A, Bello, B., Filiberto, Y., Rosete, A., Caballero, y. Bello, R. *Adquisición de conocimiento sobre la letalidad de la COVID-19 mediante técnicas de inteligencia artificial. Anales de la Academia de Ciencias de Cuba.*

Los autores desarrollaron una investigación orientada a enfrentar y atenuar los efectos de la Covid-19, haciendo uso de herramientas de Inteligencia Artificial (IA).

Objetivo

En esta investigación se presentan aplicaciones de IA utilizadas en la Ciencia de Datos y también el aprendizaje automático con la finalidad de predecir la letalidad de la Covid-19.

Desarrollo

Se desarrolló el análisis de datos sobre 9000 casos positivos de pacientes mexicanos de Covid-19 hasta el mes de abril de 2020, relacionados con dieciséis características físicas y clínicas. Setecientos de esos pacientes fallecieron por causa de esa enfermedad. La finalidad del estudio fue identificar patrones que permitan predecir que la enfermedad pudiera producir fallecimientos Para desarrollar el estudio se hizo uso de técnicas de visualización y preparación de datos, se selección rasgos y se indujo reglas empleando un algoritmo identificado como J48, teoría de conjuntos aproximados y las RNA

Resultado

Se encontró una sólida relación entre diferentes rasgos identificados en los pacientes en casos letales, estos fueron: la hipertensión, obesidad, edad, sistema inmunológico deprimido, diabetes, insuficiencia renal y males cardíacos.

Se considera que estos resultados contribuyen a comprender mejor la Covid-19 y a mostrar cómo la IA es una herramienta con altas capacidades técnicas para apoyar la actividad médica.

B.1.6. Investigación N° 6

Palmer, A., Montaña, J. *Redes Neuronales artificiales aplicadas al análisis de supervivencia: un estudio comparativo con el modelo de regresión de Cox en su aspecto predictivo*. Psicothema. 2002. Vol. 14, N° 3, pp. 630-636.

En la investigación se compara la capacidad de predicción entre las redes neuronales artificiales y el modelo de riesgos proporcionales de Cox para situaciones de análisis de supervivencia. Se realizaron las siguientes comparaciones: si el modelo de una RNA jerárquica predice con mayor precisión que el de Cox y si el modelo de una RNA secuencial predice con mayor precisión que el jerárquico.

Objetivo

El objetivo fue comprobar si el modelo de Cox es más eficiente que los modelos de RNA secuenciales y jerárquicas y comparar también la eficiencia de estas redes entre sí.

Desarrollo

Cuando la información es incompleta, o cuando las variables dependen del tiempo, los datos de supervivencia son difíciles de tratar con los métodos estadísticos comúnmente usados (Allison, 1995). El modelo de Cox, (Cox, 1972), se suele usar en estos casos, este modelo establece la relación entre la función de riesgo y las variables explicativas, mediante:

$$h(t, X) = h_0(t) e^{\beta X}$$

Para aplicar el modelo de Cox para realizar predicciones, se utiliza la expresión siguiente:

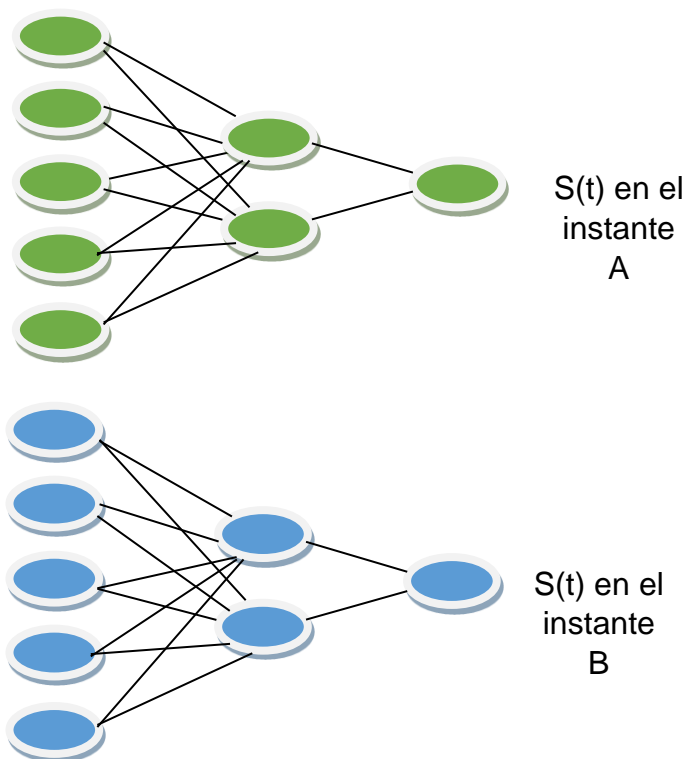
$$S(t, X) = S_0(t) e^{\beta X}$$

Por otro lado, con poca frecuencia se utilizan las RNA para el análisis de sobrevivencia, siendo los primeros trabajos los de (Ohno-Machado, Walker y Musen, 1995, 1997a, 1997b), que utilizan redes neuronales para el manejo de datos de sobrevivencia, sin condiciones iniciales, estas son el modelo de RNA jerárquicas y el modelo de RNA secuenciales.

La red neuronal jerárquica de Ohno-Machado et al. (1995) tiene una estructura jerárquica, perceptrón, multicapa, prediciendo la sobrevivencia paso a paso. Cada red da como resultado la probabilidad de sobrevivencia en un intervalo de tiempo dado y proporciona el modelo de sobrevivencia para el primer intervalo, al n-ésimo intervalo.

Figura 15

Modelo de red jerárquica



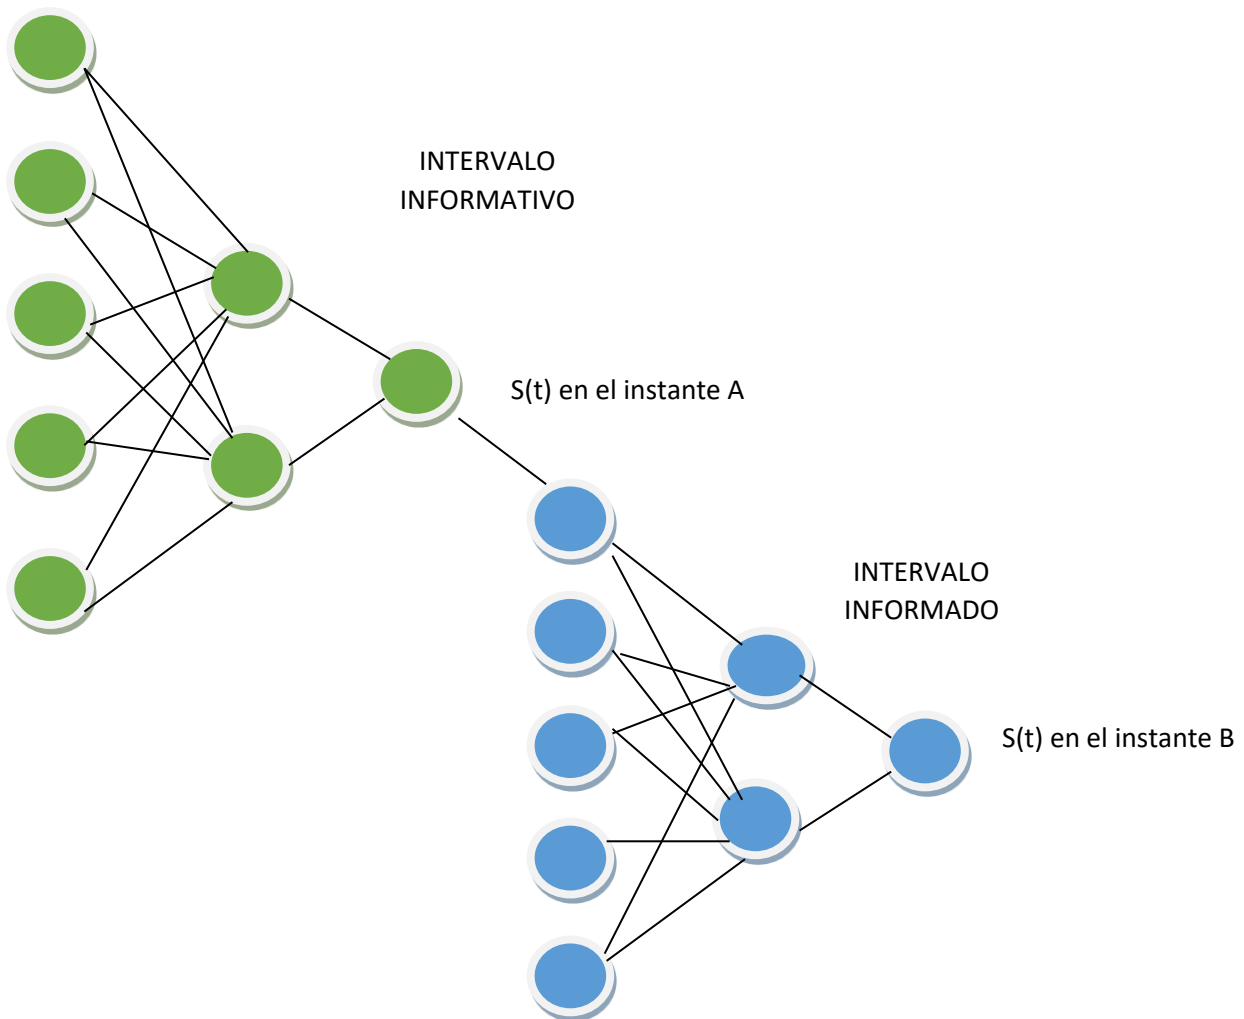
Estructura de una RED NEURONAL JERÁRQUICA, en los instantes A y B. Es un grafo especial identificado como un árbol.

Fuente: Adaptado de Ohno-Machado, Walker y Musen

El modelo de redes secuenciales de Ohno-Machado, Walker y Musen, (1997), amplía el modelo de redes jerárquicas. En este caso la RNA realiza la predicción en un intervalo de tiempo de tal manera que tal predicción cumple el rol de una variable de entrada a otra red o de una variable explicativa que predice los resultados para un intervalo anterior o posterior.

Figura 16

Modelo de Red Secuencial



Fuente: Adaptado de Ohno-Machado; Walker y Musen, (1997)

Resultado

El análisis comparativo entre el modelo de Cox y las RNA jerárquicas mostró como resultado que las RNA jerárquicas tienen mayor capacidad de predicción que el modelo de Cox. Por otra parte, el análisis comparativo entre las redes neuronales secuenciales y las redes jerárquicas mostró que ambas tienen similar capacidad de predicción. Eso lleva a concluir que los modelos de redes neuronales artificiales ofrecen predicciones más próximas a la realidad que el modelo de Cox.

B.2. Investigaciones Sobre Salud Pública.

B.2.1. Investigación N° 1

Rojas (2004). El componente social de la salud pública en el siglo XXI. Revista Cubana Salud Pública, Vol. 3, N03, Escuela Nacional de Salud Pública, Ciudad de La Habana, julio-septiembre 2004.

El autor orientó la investigación al análisis y propuesta de ideas sobre el adecuado diseño de políticas públicas de salud.

Objetivo

Se planteó analizar las ideas que sostienen que los sistemas de salud deben tener tanto el componente social como el cultural.

Desarrollo

El investigador realizó la revisión de publicaciones y al respecto manifiesta que las sociedades médicas se enfocan a atacar las enfermedades, sin embargo, ahora se discute la priorización de la prevención de las enfermedades y la promoción de la salud, por ello se dice que los sistemas de salud deben ser socioculturales (Lesky, 1984) y se deben diseñar estrategias para identificar esquemas promotores de la salud y estrategias para alcanzar a toda la población (Organización Panamericana de la Salud [OPS, 2000]).

Resultado

Las estrategias para la promoción de la salud deben alcanzar diversos aspectos que inciden en la salud (Cardona, 1998) tales como: la educación, el empleo, las condiciones de trabajo, el ingreso, las características biológicas, la genética, la evolución del niño sano, los servicios de salud, las redes de apoyo social (Health Canadá, OPS, 2000).

La mayor parte de los factores asociados a la salud no dependen de ese sector, es por ello que el enfoque debe ser intersectorial. Las estrategias (Health Canadá, OPS, 2000) para el establecimiento de políticas de salud deben considerar, además: la educación a la población sobre los factores que determinan la salud, la sólida comprensión de los determinantes de la salud y el desarrollo de iniciativas integrales, intersectoriales e interdisciplinarias de salud de la población.

B.2.2. Investigación N° 2

Barrutia, I., Silva, H., Sánchez, R. (2021). Consecuencias económicas y sociales de la inamovilidad humana bajo COVID-19: Caso de estudio Perú. *Lecturas de Economía*, No 94 Medellín, enero/febrero 2021

Se realizó el estudio del impacto de la Covid-a9 en la sociedad y en la economía peruanas entre marzo y agosto 2020.

Objetivo

El objetivo fue analizar el impacto de la pandemia Covid-19 sobre los factores socioeconómicos en el Perú y hacer recomendaciones para tomar medidas que permitan recuperar la economía y las condiciones sociales.

Desarrollo

Los autores, especifican que según Real Academia Española (RAE, 2020), la pandemia es una epidemia que afecta grandes espacios geográficos de diferentes países o a nivel global. Refieren que en nuestro planeta han existido a lo largo del tiempo muchas pandemias siendo la actual producida por la COVID-19 (Tisdell, 2020) que ha impactado seriamente en la economía y salud pública mundial (Dipaola 2020; Villamil, 2013).

Hacen referencia a que el gobierno peruano decretó en marzo 2020 el aislamiento social de la población lo cual evidenció las deficiencias significativas en el sistema de salud pública nacional. Las medidas establecían también cómo debería actuar la sociedad para enfrentar la pandemia (Maguiña, 2020). Habiendo sido afectada tan seriamente la economía del Perú se hace necesario realizar una gestión pública adecuada para recuperarla (Acevedo et al., 2019).

En la investigación se aplicó una metodología de observación de fuentes secundarias, portales web, artículos científicos y opiniones de expertos en salud pública y economía respecto al impacto de la Covid-19 en estos sectores.

De los datos del Banco Central de Reserva del Perú se obtuvo las estadísticas de los indicadores económicos, de empleo, PBI del año 2019, las cuales se analizaron estadísticamente.

De datos del Ministerio de Salud, se obtuvo las estadísticas de la evolución de la pandemia hasta agosto 2020, los casos de contagios y se verificó que la curva era exponencialmente creciente (Aragón & Cruz, 2020). En ese período se estancó la economía y el PBI bajó en 9.8 puntos en relación con agosto 2019.

Las exportaciones también disminuyeron, pero con la flexibilización se recuperaron. Las importaciones también descendieron y hacia agosto 2020 se reactivó esta actividad. Los puestos de trabajo se redujeron en 3326 mil y se incrementó la informalidad.

Se incrementó el índice de precios en el rubro de cuidado y conservación de la salud, pero también en ese período bajó el precio de los alimentos. Vega (2020), analiza las estimaciones realizadas por los organismos multinacionales respecto al impacto de la pandemia en los diferentes ámbitos de la economía: global, regional y local, considerando que no se tomaron en cuenta los efectos en los ámbitos social, cultural, político, ambiental, científico, tecnológico, de seguridad y en especial en el ámbito de la salud.

Finalmente, con la reactivación de la economía se han mejorado las condiciones económicas generales, pero ha empeorado el contagio y los fallecimientos.

Resultado

La Covid-19 ha impactado a todos los países, así como al Perú, pero este ya venía sufriendo deterioros en su economía desde algunos años atrás. Con las medidas de confinamiento los indicadores socioeconómicos cayeron abruptamente y con la flexibilización comenzaron a recuperarse, sin embargo, la enfermedad se acentuó, la tasa de informalidad aumentó. Se recomienda analizar más detalladamente y en todos los campos de acción impacto de la pandemia en los aspectos social y económico.

B.3. Investigaciones Sobre Variación Poblacional

B.3.1 Investigación N° 1

Zevallos, J., Uriol, C. (2020). Letalidad y la Mortalidad de Covid-18 en sesenta países afectados y su impacto en los aspectos demográficos, económico y de salud. Revista Médica Herediana. Vol 31, N0 4, Lima oct-dic 2020. Se realiza el análisis del impacto poblacional de la Covid-19.

Objetivo

Estudiar cuál es la relación que existe entre la mortalidad causada por la Covid-19 y las variables sociales, demográficas, económica y de salud.

Desarrollo

Se realizó un estudio descriptivo, transeccional y analítico en sesenta países de cuatro continentes, según su grado de afectación por la Covid-19. Se analizó la mortalidad y letalidad a través de las tasas respectivas. La mortalidad y letalidad se consideraron como dos estratos en la afectación de la población debido a la Covid-19.

$$TM = \text{FALLECIDOS/POBLACIÓN TOTAL}$$

y siendo la tasa de letalidad:

$$TL = \text{FALLECIDOS/POBLACIÓN AFECTADA}$$

Por tanto, $TM \leq TL$.

Para contrastar las variables de los países de la muestra se utilizó la comparación de medias mediante el método estadístico ANOVA con significancia estadística $p < 0.5$.

Del Banco Mundial se obtuvo las variables económicas estudiadas: económicas, turísticas, demográficas, sanitarias, de costumbres, de mortalidad y

sobre los indicadores de desarrollo humano y felicidad. Estas variables se contrastaron contra el volumen de fallecidos, mortalidad y letalidad por Covid-19 en búsqueda de la existencia de relación entre ellos.

Resultado

Como resultado del análisis correlacional se determinó que existe una alta correlación, con coeficiente de correlación $r = 0.7$ entre la mortalidad y la letalidad, también se determinó que existe una correlación limitada, con $r = 0.48$, entre la letalidad y los fallecimientos, alta correlación, con $r = 0.90$ entre el volumen de casos y los fallecimientos. Además, se halló que al inicio de la pandemia los países con mayor desarrollo económico respondieron mejor a los requerimientos de salud y tuvieron menor tasa de letalidad, sin embargo, al extenderse la vigencia de la enfermedad las tasas se uniformizaron. Esto llevó a la conclusión que ante una pandemia como la Covid-19, no hay recursos sanitarios suficientes para disminuir la letalidad, lo cual incide en los cambios poblacionales o demográficos de los países.

2.2. Marco conceptual

COVID-19: Es la denominación dada por la Organización Mundial de la Salud (OMS) a la enfermedad causada por el SARS CoV 2. Covid-19 proviene del término en inglés Coronavirus Disease o enfermedad del coronavirus originada el 2019, y ocasionó aproximadamente 996 mil muertes en la pandemia del año 2020, hasta la fecha de terminado este estudio de investigación.

Pandemia: Se conoce como pandemia a la expansión global de una enfermedad ante la cual la población mundial aún ha desarrollado inmunidad. La OMS especifica que las pandemias frecuentemente son producidas por virus gripales que enferman a los animales. Debido a la afectación de grandes masas poblacionales se requieren siendo necesarias disposiciones legales especiales para luchar contra ellas y evitar o reducir las muertes.

Estado de emergencia: Según el Artículo 137 de la Constitución política del Perú, es una eventualidad que se da en situación de catástrofe, la cual permite la restricción de ciertos derechos constitucionales de seguridad personal y libertad, entre los cuales se encuentran el derecho a la libertad de reunión y de tránsito.

Mortalidad: Es el número de personas que perecen en un ámbito geográfico y en un intervalo de tiempo determinado respecto a la población de ese ámbito.

Morbilidad: Cantidad de personas que se enferman en un ámbito geográfico y un período de tiempo determinado respecto a la población de ese ámbito.

Riesgo de vida por enfermedad: es la probabilidad de que una persona que está libre de una enfermedad, la adquiera y fallezca por ella.

CAPÍTULO III:
MARCO METODOLÓGICO

3.1. Fundamentos Teóricos de la Metodología

3.1.1. Hipótesis general

Mediante el uso de un modelo matemático de red neuronal supervisada es posible explicar los cambios demográficos en la población de Lima Metropolitana, durante el período 2020 de desarrollo de la pandemia Covid-19 y su proyección 2021-2025.

3.1.2. Hipótesis nula

Mediante el uso de un modelo matemático de red neuronal supervisada no es posible explicar los cambios demográficos en la población de Lima Metropolitana, durante el período 2020 de desarrollo de la pandemia Covid-19 y cuál es su proyección y efectos sobre la actividad socio económica en el período 2021-2025.

3.1.3 Hipótesis específicas

Mediante la aplicación de un modelo matemático de red neuronal supervisada es posible explicar los cambios que se produjeron en la natalidad de la población de Lima Metropolitana durante el período 2020 de desarrollo de la pandemia Covid-19 y cuál es su proyección para el período 2021-2025.

Haciendo uso de un modelo matemático de red neuronal supervisada es posible explicar los cambios que se produjeron en la mortalidad de la población de Lima Metropolitana durante el período 2020 de desarrollo de la pandemia Covid-19 y cuál es su proyección para el período 2021-2025.

Aplicando un modelo matemático de red neuronal supervisada es posible explicar cómo afectarán los cambios demográficos en la población de Lima Metropolitana ocurridos durante el período 2020 de desarrollo de la pandemia Covid-19 a las actividades socio económicas del período 2021-2025.

3.2. Variables e Indicadores de la Investigación

A. Variables de la investigación

- Variable independiente: Red Neuronal Supervisada.
- Variable dependiente: Variación de la población Fija.
- Variable interviniente: Covid-19

A.1. Variable independiente: Red neuronal supervisada

Se denomina red neuronal supervisada a aquella que realiza un aprendizaje supervisado que se caracteriza por el hecho de que el proceso de aprendizaje se lleva a cabo bajo el control de un agente externo denominado supervisor o maestro. El supervisor establece cuál es la respuesta que la RNA debería dar ante una entrada determinada. El rol del supervisor es ejercer un mecanismo de control de tal manera que compara la salida de la red con la salida deseada, si esos valores no coinciden el supervisor modifica los pesos de las conexiones buscando que la salida que obtenga la red se aproxime a la salida deseada (Jorge, 2001).

A.2. Variable dependiente: variación de la población fija.

El tamaño de la población que vive en un determinado territorio, observado durante un cierto período de tiempo, puede aumentar, permanecer igual o disminuir. Esto se debe a la relación entre el número de nacimientos, fallecimientos y de desplazamientos producidos en esa población (Hernández, 1998).

A.3. Indicadores de la Variable: Variación de la Población Fija

- *Número poblacional por día*, que para esta investigación indica el tamaño de la población de Lima Metropolitana por día.
- *Número de nacidos por día*, que registra el número de nacidos vivos por día en Lima Metropolitana.
- *Número de fallecidos por día*, que registrará el número de fallecidos por día por

dos causas: por Covid-19 y por otras causas.

B. Definición operacional

Tabla 9

Definición operacional

VARIABLES	DEFINICIÓN CONCEPTUAL	DIMENSIONES
RED NEURONAL SUPERVISADA	En una red neuronal, el aprendizaje supervisado se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor o maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor controla la salida de la red y si no coincide con la deseada, procede a modificar los pesos de las conexiones con el fin que la salida obtenida se aproxime a la deseada, (Damián, 2001).	<p>RNA supervisada, con aprendizaje por corrección de errores.</p> <p>RNA supervisada, con aprendizaje por refuerzo.</p> <p>RNA supervisada, con aprendizaje estocástico.</p>
VARIACIÓN DE LA POBLACIÓN FIJA	Una población humana asentada en determinado territorio, y observada durante un cierto lapso, puede aumentar, mantener igual o disminuir su número de integrantes, es decir, la cifra de su magnitud. Ello sucede en virtud de la relación que guarden entre sí el número de nacimientos, de defunciones y de desplazamientos ocurridos en relación a dicha población (Hernández, 1996).	<ul style="list-style-type: none"> •Nacimientos en Lima Metropolitana. •Fallecimientos por Covid-19 en Lima Metropolitana. •Fallecimientos por otras causas, en Lima Metropolitana.

C. INDICADORES

Tabla 10

Indicadores

VARIABLE	DIMENSIONES	INDICADORES
RED NEURONAL SUPERVISADA	RNA supervisada, con aprendizaje por corrección de errores.	<ul style="list-style-type: none"> • Resultado esperado • Error • Error mínimo cuadrático
	RNA supervisada, con aprendizaje por refuerzo.	<ul style="list-style-type: none"> • Resultado esperado • Error • Error mínimo cuadrático
	RNA supervisada, con aprendizaje estocástico.	<ul style="list-style-type: none"> • Resultado esperado • Error • Error mínimo cuadrático
VARIACIÓN DE LA POBLACIÓN FIJA	• Nacimientos por día en Lima Metropolitana.	• Número de nacimientos por día en Lima Metropolitana.
	• Fallecimientos por día por Covid-19 en Lima Metropolitana.	• Número de fallecimientos por día en Lima Metropolitana.
	• Fallecimientos por día por otras causas, en Lima Metropolitana.	• Número de fallecimientos por día por otras causas en Lima Metropolitana.

3.3. Métodos de la Investigación

Se utilizan los métodos explicativo y predictivo.

Es explicativo porque analizará las causas y efectos en el fenómeno durante el período de estudio.

Es predictivo porque realiza un estudio para determinar los efectos posibles sobre el período 2021-2025.

3.4. Diseño o Esquema de la Investigación

El diseño es no experimental debido a que no se efectúa ningún cambio o manipulación sobre la variable independiente.

3.4.1. Nivel de investigación

Esta investigación es de nivel explicativo porque, además de describir el problema y acercarnos a él, intentaremos hallar los efectos o cambios y analizar las consecuencias de este.

3.4.2. Diseño

El estudio no realiza modificaciones sobre la variable independiente. Es un diseño longitudinal de tendencia porque se analizan los cambios para un período futuro 2021-2025, también se analizan los cambios durante el período marzo-diciembre 2020.

Es explicativo porque analizará las causas y efectos en el fenómeno durante el período en estudio.

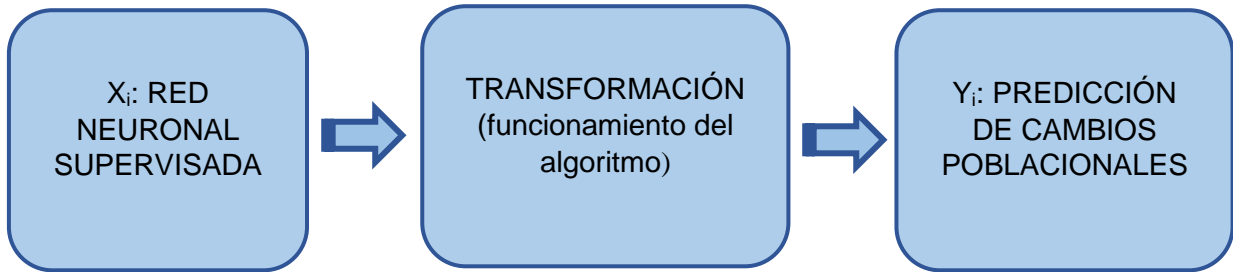
Es predictivo porque realiza un estudio para determinar los efectos posibles sobre el período 2021-2025.

3.4.3. Enfoque

El enfoque es cuantitativo porque este estudio busca analizar de manera objetiva y tiene una perspectiva externa, basándose en su totalidad en análisis numéricos y estadísticas puntuales.

Figura 17

Modelo de investigación



Fuente propia

3.5. Población y Muestra

3.5.1. Población

La población la conforman todos los pobladores de Lima Metropolitana al inicio del período de estudio.

3.5.2. Muestra

La muestra está determinada para poblaciones grandes o infinitas

Se usa la fórmula para la determinación del tamaño de la muestra para poblaciones cuya varianza se desconoce y se desea trabajar con la media poblacional, con un nivel de confianza del 97%:

$$n = (Z^2 p \cdot q) / e^2$$

n: tamaño de la muestra

Z = 1.88 para un nivel de confianza del 97%

e: error 3%

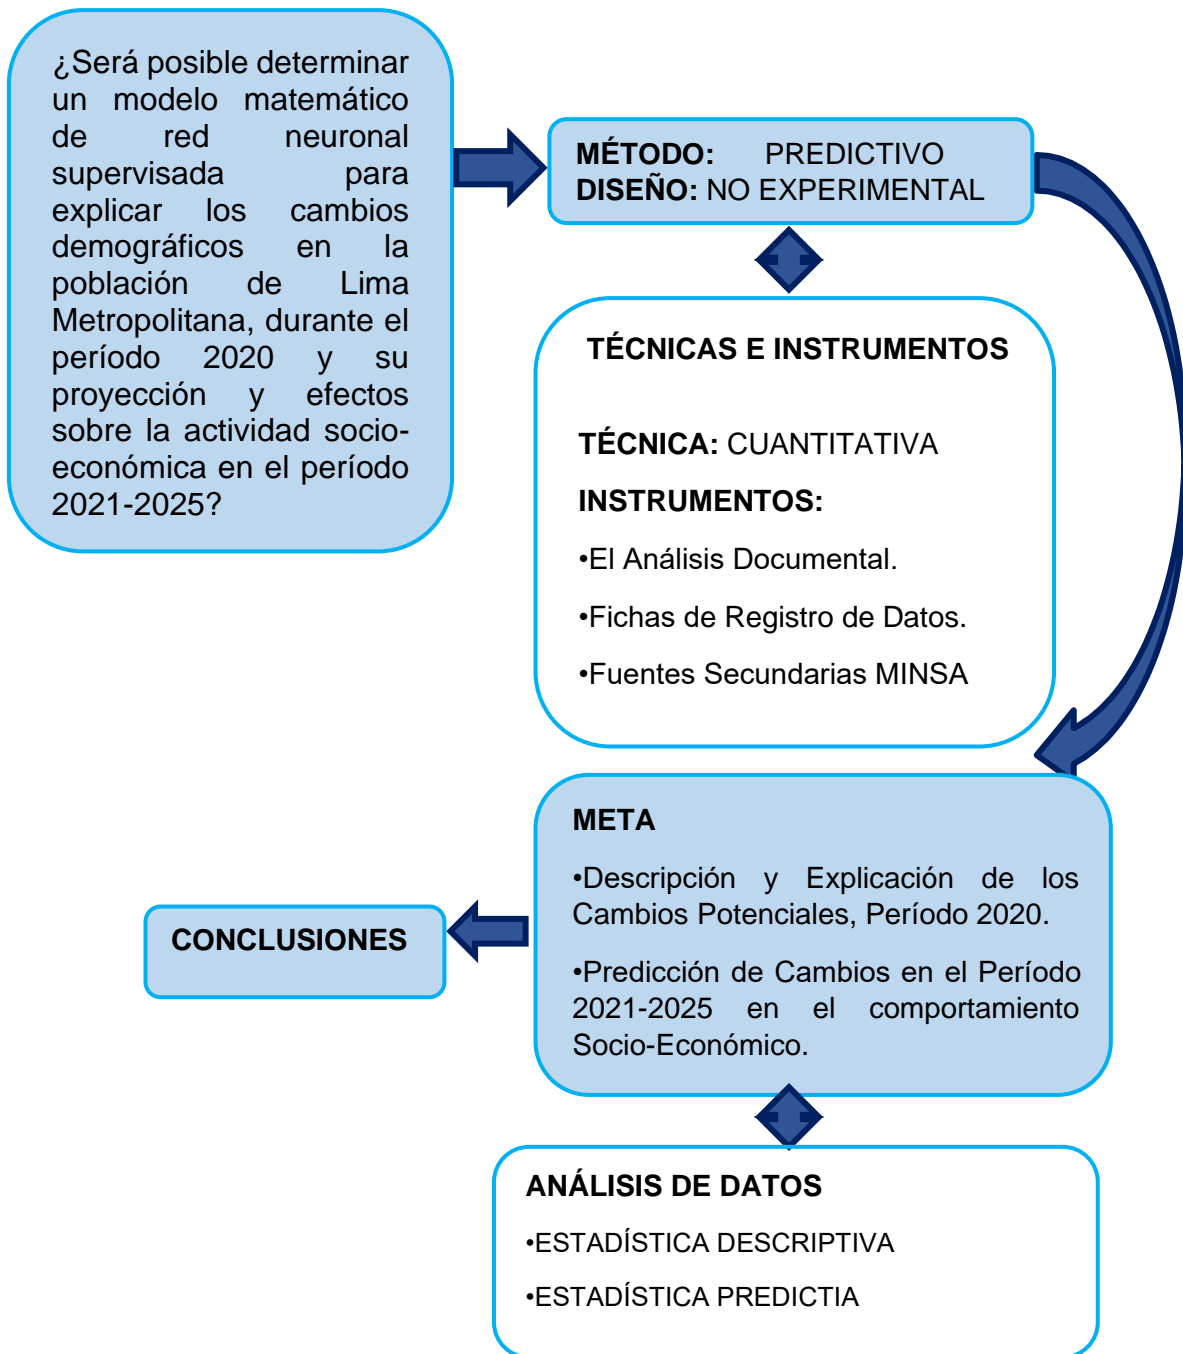
Entonces: n = 982 personas, es el tamaño de la muestra.

Se usará un procedimiento aleatorio para elegir los elementos de la muestra, optándose por el muestreo sistemático.

3.6. Actividades e Instrumentos de la Investigación

Figura 18

Actividades del proceso investigativo



Para alcanzar el objetivo de la investigación:

Establecer qué cambios se produjeron en la natalidad de la población de Lima Metropolitana en el año 2020 de desarrollo de la pandemia Covid-19 y cuál es su proyección para el período 2021-2025 y absolver la pregunta de investigación, se propone las siguientes actividades:

Se consultó las bases de datos del Ministerio de Salud y otros organismos oficiales que han registrado los nacidos vivos durante el año 2020.

Se importó los datos obtenidos a una base de datos propia para el trabajo de investigación.

Se eligió un software de procesamiento de redes neuronales.

Se desarrolló el aprendizaje supervisado de la red de interés haciendo uso del software elegido, hasta la obtención de los resultados esperados.

Se interpretó los resultados relacionados con los cambios poblacionales afectados por los nacimientos.

3.7. Técnicas e Instrumentos de la Investigación

Técnica: Cuantitativa

Instrumentos:

Análisis Documental.

Fichas de Registros de datos.

Consulta de Fuentes Secundarias MINSA.

Pruebas iteradas.

3.8. Procedimientos para la Recolección de Datos

En la recolección de datos, en esta investigación se trabajó con base en los datos publicados por el Ministerio de Salud y también se buscó los datos de otros organismos oficiales que registran los nacimientos y fallecimientos en el Perú, específicamente en Lima Metropolitana. Las tablas 03 a 08 presentan un conjunto de datos relacionados con los nacimientos y muertes, por zona de Lima Metropolitana, para los años 2020 al 2022.

Tabla 11

Fallecidos por Covid-19 año 2020 Lima Metropolitana

		2020										
	DISTRITOS	SEXO	MAR	ABR	MAY	JUN	JUL	AG	SET	OCT	NOV	DIC
LIMA CENTRO	BREÑA	M	1	22	66	76	59	47	49	13	14	19
		F	1	1	21	39	45	48	34	14	5	12
	JESÚS MARÍA	M	3	20	86	79	60	79	40	18	14	15
		F	0	7	38	42	37	68	41	35	13	11
	LA VICTORIA	M	0	103	261	154	142	121	61	41	18	27
		F	2	34	93	98	100	89	53	29	9	13
	RÍMAC	M	3	68	204	165	99	103	45	28	13	19
		F	0	24	69	91	54	60	31	20	12	11
	LIMA	M	9	142	575	528	411	385	205	102	45	76
		F	4	79	252	289	268	273	143	66	32	44
	LINCE	M	0	9	37	44	40	29	19	15	5	7
		F	0	2	18	21	28	47	22	9	7	7
	MADGALENA DEL MAR	M	0	6	18	28	21	28	16	7	12	8
		F	0	0	15	7	21	21	11	4	5	4
	MIRAFLORES	M	1	10	40	38	39	29	21	11	6	11
		F	0	8	17	24	23	37	19	10	11	6
	PUEBLO LIBRE	M	3	14	36	41	40	36	21	14	8	7
		F	0	4	19	19	33	26	24	10	5	4
	SAN BORJA	M	1	14	24	38	23	34	18	9	13	10
		F	0	9	14	9	19	20	12	8	4	7
	SAN ISIDRO	M	3	7	18	18	18	14	8	6	4	7
		F	0	2	8	14	11	15	7	5	2	3
	BARRANCO	M	0	6	21	19	18	14	16	10	2	3
		F	0	3	11	8	14	12	10	9	1	2
	SAN MIGUEL	M	0	21	63	64	65	62	30	16	16	12
		F	1	14	21	39	34	27	25	10	14	2
	SANTIAGO DE SURCO	M	2	34	85	116	102	100	63	28	18	16
		F	0	20	40	56	57	72	50	20	18	13
	SURQUILLO	M	1	16	47	49	45	57	22	17	8	11
		F	1	9	15	18	23	34	25	8	6	3

		2020										
	DISTRITOS	SEXO	MAR	ABR	MAY	JUN	JUL	AG	SET	OCT	NOV	DIC
LIMA NORTE	ANCÓN	M	1	13	21	18	30	18	5	3	5	2
		F	0	1	4	10	14	12	4	4	0	0
	CARABAYLLO	M	0	30	86	127	114	105	51	26	13	14
		F	0	9	38	60	60	78	35	13	10	13
	COMAS	M	0	121	346	426	388	331	157	69	45	50
		F	0	39	129	160	185	202	96	43	31	35
	INDEPENDENCIA	M	1	34	176	166	131	122	60	18	24	17
		F	0	15	77	96	57	59	39	17	10	8
	LOS OLIVOS	M	0	43	169	189	180	188	85	34	23	33
		F	1	19	75	99	76	91	36	24	15	12
	PUENTE PIEDRA	M	2	40	99	166	132	121	49	33	18	20
		F	0	16	43	60	63	68	38	16	6	12
	SAN MARTÍN DE PORRES	M	6	139	427	471	348	315	184	78	59	50
		F	0	53	186	206	209	180	99	64	41	37
	SANTA ROSA	M	0	2	5	4	8	7	1	2	0	0
		F	0	0	2	0	2	2	1	1	1	1
	ATE	M	1	109	269	243	213	205	93	55	36	51
		F	0	53	129	128	181	176	86	36	22	32
CHACLACAYO	M	0	9	6	15	17	19	7	2	2	5	
	F	0	2	3	7	12	12	9	3	2	1	
CIENEGUILLA	M	0	3	3	2	1	7	4	1	1	1	
	F	0	0	2	3	7	5	2	4	1	0	
EL AGUSTINO	M	2	85	217	122	109	95	51	16	16	19	
	F	0	35	105	69	45	58	31	22	10	10	
LIMA ESTE	LA MOLINA	M	1	8	18	38	47	46	32	13	8	8
		F	0	6	13	21	14	35	14	13	5	8
LURIGANCHO	M	0	13	30	53	61	64	27	13	9	10	
	F	0	10	19	28	40	39	20	9	6	8	
SAN JUAN DE LURIGANCHO	M	3	167	553	582	522	443	187	96	52	72	
	F	3	75	247	318	292	284	127	70	24	52	
SAN LUIS	M	0	13	39	27	17	23	19	5	3	3	
	F	1	5	10	16	17	16	6	4	2	3	
SANTA ANITA	M	0	61	150	120	107	106	42	23	11	22	
	F	1	19	65	80	46	63	31	18	8	13	

2020												
	DISTRITOS	SEXO	MAR	ABR	MAY	JUN	JUL	AG	SET	OCT	NOV	DIC
LIMA SUR	CHORRILLOS	M	2	36	167	168	125	113	52	20	12	14
		F	0	16	59	71	61	91	41	23	16	12
	LURÍN	M	0	9	41	31	24	16	10	4	4	2
		F	0	4	17	18	11	13	10	7	2	5
	PACHACÁMAC	M	2	8	17	15	27	22	5	8	4	7
		F	1	3	9	11	12	12	17	2	2	2
	PUCUSANA	M	0	2	5	6	7	4	3	1	0	1
		F	0	2	3	3	3	4	2	1	1	2
	PUNTA HERMOSA	M	0	1	0	3	3	2	0	0	1	0
		F	0	1	0	0	1	0	3	1	0	0
	PUNTA NEGRA	M	0	1	1	1	2	1	0	0	0	0
		F	0	0	1	0	1	2	0	0	1	1
	SAN BARTOLO	M	0	1	3	3	0	3	1	0	0	2
		F	0	0	0	1	0	0	0	0	0	0
	SAN JUAN DE MIRAFLORES	M	1	79	206	173	150	155	77	37	20	26
		F	0	40	101	76	96	111	49	23	23	16
	SANTA MARÍA DEL MAR	M	0	0	1	1	1	0	0	0	0	0
		F	0	0	0	0	0	0	1	0	1	0
	VILLA EL SALVADOR	M	4	130	334	293	296	207	122	68	42	44
		F	9	50	161	145	118	139	65	28	19	18
VILLA MARÍA DEL TRIUNFO	M	2	82	221	217	243	209	99	56	21	33	
	F	1	31	78	106	105	116	55	31	19	22	
TOTAL MENSUAL			81	2451	7418	7703	6980	6802	3481	1750	1047	1219
TOTAL ANUAL			38 932									

FUENTE: MINSA (Ministerio de Salud)

Tabla 12

Fallecidos por Covid-19 año 2021 Lima Metropolitana

		2021												
	DISTRITOS	SEXO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AG	SET	OCT	NOV	DIC
LIMA CENTRO	BREÑA	M	46	88	119	72	46	14	11	2	5	8	0	5
		F	33	57	62	56	28	12	4	3	3	2	3	5
	JESÚS MARÍA	M	81	136	178	171	122	47	17	1	5	8	5	9
		F	40	79	83	86	65	19	9	1	1	1	3	5
	LA VICTORIA	M	103	179	180	138	75	28	11	1	6	8	6	6
		F	62	112	111	104	53	17	8	2	4	5	3	2
	RÍMAC	M	68	119	134	153	65	19	9	0	6	4	6	3
		F	40	65	91	74	48	12	8	1	4	2	8	6
	LIMA	M	289	533	570	677	393	145	74	5	8	11	24	15
		F	173	316	349	378	216	72	28	5	9	13	7	7
	LINCE	M	33	64	57	66	38	9	4	0	3	6	1	3
		F	22	38	44	57	27	6	3	1	1	0	2	4
	MADGALENA DEL MAR	M	25	46	43	49	31	11	3	0	3	4	1	2
		F	18	25	26	30	20	11	2	0	0	2	1	2
	MIRAFLORES	M	36	62	82	69	43	13	6	5	4	2	5	5
		F	19	48	53	48	29	9	7	3	8	2	5	3
	PUEBLO LIBRE	M	25	54	75	47	32	14	7	0	3	5	0	1
		F	24	40	45	35	23	13	3	0	3	2	4	4
	SAN BORJA	M	33	60	59	61	35	10	7	1	5	6	3	6
		F	18	29	31	39	18	7	2	2	6	0	2	3
	SAN ISIDRO	M	21	28	31	36	24	8	7	1	2	2	1	3
		F	11	22	23	22	16	4	2	2	3	0	2	2
	BARRANCO	M	17	34	30	40	25	2	3	0	1	2	3	1
		F	16	17	17	25	14	4	3	0	1	1	0	1
	SAN MIGUEL	M	57	117	99	126	70	27	16	1	9	6	3	5
		F	31	70	58	59	42	9	7	1	6	3	6	5
	SANTIAGO DE SURCO	M	87	162	198	174	123	36	19	1	9	9	5	2
		F	70	97	116	105	65	31	8	6	10	4	6	9
	SURQUILLO	M	37	73	82	76	48	18	12	1	1	4	4	5
		F	20	54	54	36	22	9	8	1	0	2	2	2

2021

DISTRITOS		SEXO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AG	SET	OCT	NOV	DIC
LIMA NORTE	ANCÓN	M	15	26	30	22	15	11	3	0	1	1	3	3
		F	2	21	7	12	11	3	2	0	0	0	1	1
	CARABAYLLO	M	62	139	149	152	92	29	24	1	2	7	5	11
		F	37	71	75	86	45	18	10	1	7	2	8	5
	COMAS	M	216	385	470	362	213	76	38	1	10	14	14	21
		F	131	218	257	206	84	44	13	2	9	8	7	17
	INDEPENDENCIA	M	55	119	149	120	61	19	8	3	6	4	7	6
		F	31	74	71	75	38	15	7	1	2	3	6	5
	LOS OLIVOS	M	106	231	272	242	131	41	22	0	5	12	7	9
		F	63	139	154	128	63	21	10	0	2	5	7	8
	PUENTE PIEDRA	M	74	120	175	155	75	29	28	1	6	6	4	11
		F	28	70	102	77	45	24	5	1	2	9	9	6
	SAN MARTÍN DE PORRES	M	221	466	525	445	228	86	38	5	11	11	12	22
		F	109	245	296	255	131	47	26	0	6	12	10	10
	SANTA ROSA	M	4	3	6	7	3	1	0	0	1	1	1	1
		F	1	2	4	6	1	1	0	0	0	0	1	1
	ATE	M	176	363	419	383	179	69	30	4	7	8	4	17
		F	83	186	248	218	101	33	23	3	6	5	5	11
CHACLACAYO	M	12	30	47	21	12	5	2	0	0	1	0	2	
	F	8	19	36	17	8	0	2	0	2	1	0	5	
CIENEGUILLA	M	5	8	6	9	9	3	1	0	0	1	1	0	
	F	6	2	7	5	5	1	0	0	0	0	0	0	
EL AGUSTINO	M	63	138	128	135	59	31	9	0	2	3	2	9	
	F	54	78	96	81	32	12	2	0	3	6	3	3	
LA MOLINA	M	29	93	90	87	47	16	3	0	0	3	3	10	
	F	21	35	57	40	21	7	6	2	1	1	2	0	
LURIGANCHO	M	26	64	97	121	64	26	10	3	3	3	2	4	
	F	17	34	59	49	34	8	5	1	0	4	1	2	
SAN JUAN DE LURIGANCHO	M	336	643	678	492	259	96	37	2	15	20	17	23	
	F	185	395	360	284	148	38	11	2	9	8	8	10	
SAN LUIS	M	23	31	35	45	17	9	4	0	2	2	4	3	
	F	11	17	27	34	8	2	0	0	1	1	0	0	
SANTA ANITA	M	70	149	200	127	75	27	15	0	4	5	6	7	
	F	35	70	94	81	30	16	7	0	1	2	4	3	

		2021												
	DISTRITOS	SEXO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AG	SET	OCT	NOV	DIC
LIMA SUR	CHORRILLOS	M	83	169	210	193	114	27	7	2	6	7	5	9
		F	51	94	111	110	50	23	10	1	2	2	4	2
	LURÍN	M	25	42	42	45	28	6	1	0	2	3	4	1
		F	8	12	28	37	22	3	1	0	1	0	2	1
	PACHACÁMAC	M	16	34	62	48	22	9	4	0	2	0	2	3
		F	12	15	25	28	14	7	2	0	1	3	1	0
	PUCUSANA	M	3	8	4	11	3	1	0	0	0	0	0	0
		F	4	0	4	4	2	0	1	0	0	1	0	0
	PUNTA HERMOSA	M	4	5	4	3	3	1	1	0	0	0	0	0
		F	1	1	0	3	5	0	0	0	0	0	0	0
	PUNTA NEGRA	M	3	6	3	7	1	1	0	0	1	1	0	0
		F	3	2	3	0	0	2	0	0	0	0	0	0
	SAN BARTOLO	M	4	6	1	6	2	1	1	0	0	1	0	0
		F	5	4	4	1	2	0	0	0	0	0	0	0
	SAN JUAN DE MIRAFLORES	M	108	221	278	281	137	52	27	1	15	6	10	0
		F	65	136	190	119	79	15	7	1	11	6	7	2
	SANTA MARÍA DEL MAR	M	1	1	2	1	1	0	0	0	0	0	0	0
		F	0	0	0	0	0	0	0	0	0	0	0	0
	VILLA EL SALVADOR	M	123	270	329	270	139	59	27	2	14	8	8	6
		F	77	133	191	179	74	32	9	0	3	8	8	7
VILLA MARÍA DEL TRIUNFO	M	111	244	313	292	134	48	23	2	9	10	12	11	
	F	59	141	194	190	86	23	12	0	6	2	4	6	
TOTAL MENSUAL			4636	9052	10524	9516	5118	1810	842	89	328	351	352	425
TOTAL ANUAL			43043											

FUENTE: MINSA (Ministerio de Salud)

Tabla 13

Fallecidos por Covid-19 año 2022 Lima Metropolitana

		2022								
	DISTRITOS	SEXO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AG
LIMA CENTRO	BREÑA	M	12	11	5	2	1	2	3	1
		F	10	8	4	1	3	0	2	2
	JESÚS MARÍA	M	13	15	9	4	3	2	4	6
		F	11	9	5	4	2	2	6	4
	LA VICTORIA	M	42	21	8	8	1	1	7	3
		F	28	11	6	1	3	1	3	2
	RÍMAC	M	28	15	11	4	2	5	4	6
		F	17	17	3	2	2	2	1	4
	LIMA	M	63	45	19	6	2	4	18	10
		F	39	34	6	2	2	1	8	9
	LINCE	M	16	9	4	3	0	2	2	3
		F	11	10	2	1	1	0	3	1
	MADGALENA DEL MAR	M	11	3	2	3	0	0	1	4
		F	7	6	1	1	1	2	0	2
	MIRAFLORES	M	10	16	6	5	4	5	8	3
		F	14	7	3	3	3	2	6	3
	PUEBLO LIBRE	M	13	4	1	2	3	2	6	5
		F	10	9	5	1	5	2	3	4
	SAN BORJA	M	11	11	4	2	3	3	9	3
		F	9	4	8	1	0	4	5	5
	SAN ISIDRO	M	5	8	5	1	1	1	6	3
		F	4	3	2	2	0	4	3	1
	BARRANCO	M	6	7	1	1	0	0	1	1
		F	6	3	0	0	0	0	1	1
	SAN MIGUEL	M	18	12	6	4	4	4	2	3
		F	11	18	6	3	3	1	3	8
	SANTIAGO DE SURCO	M	19	27	14	1	8	7	10	9
		F	24	16	10	5	9	4	8	5
	SURQUILLO	M	15	4	7	2	2	1	3	0
		F	9	8	5	0	0	1	2	3

		2022								
	DISTRITOS	SEXO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AG
LIMA NORTE	ANCÓN	M	3	7	0	0	0	0	1	0
		F	2	1	1	0	1	0	0	1
	CARABAYLLO	M	24	22	5	0	4	1	3	3
		F	19	13	3	2	2	1	2	0
	COMAS	M	56	42	8	4	6	5	7	11
		F	35	32	6	2	6	2	8	9
	INDEPENDENCIA	M	22	19	6	0	1	2	2	1
		F	18	10	2	2	1	1	2	1
	LOS OLIVOS	M	32	19	6	1	2	2	3	2
		F	24	16	9	2	2	3	6	4
	PUENTE PIEDRA	M	25	18	2	1	0	3	3	1
		F	18	9	4	2	1	0	2	0
	SAN MARTÍN DE PORRES	M	53	44	17	3	6	6	8	7
		F	38	35	9	6	2	4	7	11
	SANTA ROSA	M	0	2	0	0	1	0	0	0
		F	2	0	0	0	1	0	0	0
	ATE	M	43	33	7	7	1	6	6	1
		F	26	22	4	2	4	3	8	0
CHACLACAYO	M	4	0	4	1	0	1	0	0	
	F	6	0	0	1	1	0	0	0	
CIENEGUILLA	M	2	3	0	0	1	1	0	1	
	F	0	1	0	0	0	1	0	0	
EL AGUSTINO	M	20	10	5	2	2	0	2	2	
	F	15	11	4	1	2	2	1	1	
LIMA ESTE	LA MOLINA	M	14	7	7	5	4	4	11	3
		F	12	11	4	1	1	1	2	5
LURIGANCHO	M	13	11	5	2	2	0	2	2	
	F	14	8	1	1	0	2	4	0	
SAN JUAN DE LURIGANCHO	M	69	59	18	8	10	7	6	9	
	F	48	34	21	7	8	1	4	8	
SAN LUIS	M	3	2	1	2	1	0	0	3	
	F	2	2	1	0	1	0	1	3	
SANTA ANITA	M	14	12	4	1	2	1	6	2	
	F	13	9	5	5	1	0	1	6	

2022											
	DISTRITOS	SEXO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AG	
LIMA SUR	CHORRILLOS	M	26	22	10	4	2	3	4	5	
		F	15	15	8	1	1	3	7	4	
	LURÍN	M	4	7	2	2	0	2	1	1	
		F	7	2	1	0	0	0	1	0	
	PACHACÁMAC	M	6	4	0	1	0	1	0	2	
		F	3	5	0	0	2	0	0	1	
	PUCUSANA	M	0	1	0	0	0	1	1	0	
		F	0	0	0	0	0	0	0	0	
	PUNTA HERMOSA	M	0	0	1	0	0	0	0	0	
		F	0	1	0	0	1	0	0	0	
	PUNTA NEGRA	M	1	0	1	0	0	0	0	0	
		F	0	2	0	0	0	0	0	0	
	SAN BARTOLO	M	1	0	0	0	0	0	0	0	
		F	0	0	0	0	0	0	0	0	
	SAN JUAN DE MIRAFLORES	M	25	31	13	4	1	4	6	5	
		F	22	18	10	4	1	3	1	3	
	SANTA MARÍA DEL MAR	M	0	0	0	0	0	0	0	0	
		F	0	1	0	0	0	0	0	0	
	VILLA EL SALVADOR	M	27	20	9	1	2	0	2	4	
		F	26	13	7	1	1	0	5	3	
	VILLA MARÍA DEL TRIUNFO	M	29	32	11	3	5	4	2	6	
		F	31	24	7	0	4	2	7	2	
	TOTAL MENSUAL			1404	1093	417	167	165	148	283	247
	TOTAL ANUAL						3924				

FUENTE: MINSA (Ministerio de Salud)

Tabla 14*Nacidos año 2020 Lima Metropolitana*

		2020									
		MAR	ABR	MAY	JUN	JUL	AG	SET	OCT	NOV	DIC
LIMA CENTRO		6325	5989	5654	5175	5229	5137	5366	5133	4804	4055
LIMA NORTE		2416	2476	2630	2445	2418	2252	2383	2280	2085	1814
LIMA ESTE		1644	1509	1576	1534	1565	1510	1398	1427	1520	1248
LIMA SUR		1970	1833	2031	1943	1898	1872	1895	1865	1717	1495
TOTAL MENSUAL		12355	11807	11891	11097	11110	10771	11042	10705	10126	8612
TOTAL ANUAL		109516									

FUENTE: MINSA (Ministerio de Salud)

Tabla 15*Nacidos año 2021 Lima Metropolitana*

		2021											
		ENE	FEB	MAR	ABR	MAY	JUN	JUL	AG	SET	OCT	NOV	DIC
LIMA CENTRO		3957	3985	4730	4833	5093	4951	5058	5070	5130	4649	4337	4668
LIMA NORTE		1823	1884	2232	2250	2268	2199	2207	2105	2346	2074	1924	2074
LIMA ESTE		1232	1171	1344	1359	1384	1268	1386	1348	1351	1236	1229	1314
LIMA SUR		1353	1400	1628	1745	1731	1733	1705	1610	1735	1628	1599	1635
TOTAL MENSUAL		8365	8440	9934	10187	10476	10151	10356	10133	10562	9587	9089	9691
TOTAL ANUAL		116971											

FUENTE: MINSA (Ministerio de Salud)

Tabla 16*Nacidos año 2022 Lima Metropolitana*

	2022							
	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AG
LIMA CENTRO	5050	4788	5371	4918	4813	4636	4874	972
LIMA NORTE	2243	2188	2431	2246	2340	2165	2154	442
LIMA ESTE	1466	1402	1544	1506	1485	1341	1403	284
LIMA SUR	1647	1597	1839	1658	1719	1663	1665	328
TOTAL MENSUAL	10406	9975	11185	10328	10357	9805	10096	2026
TOTAL ANUAL	74178							

FUENTE: MINSA (Ministerio de Salud)

El análisis documental, nos permite identificar y describir la variable de investigación.

3.9. Técnicas de Procesamiento y Análisis de los Datos

El procesamiento de la información se realizó mediante pruebas iterativas aplicadas a las redes neuronales, para desarrollar el aprendizaje supervisado, verificar las respuestas, su cercanía a las respuestas deseadas y retroalimentar para realizar las modificaciones en los casos necesarios, hasta encontrar los resultados óptimos o deseados finales.

El análisis de los datos se realizó mediante el uso de herramientas de Estadística descriptiva y mediante el análisis de las proyecciones realizadas por el uso de las redes neuronales.

CAPÍTULO IV:
RESULTADOS Y DISCUSIÓN

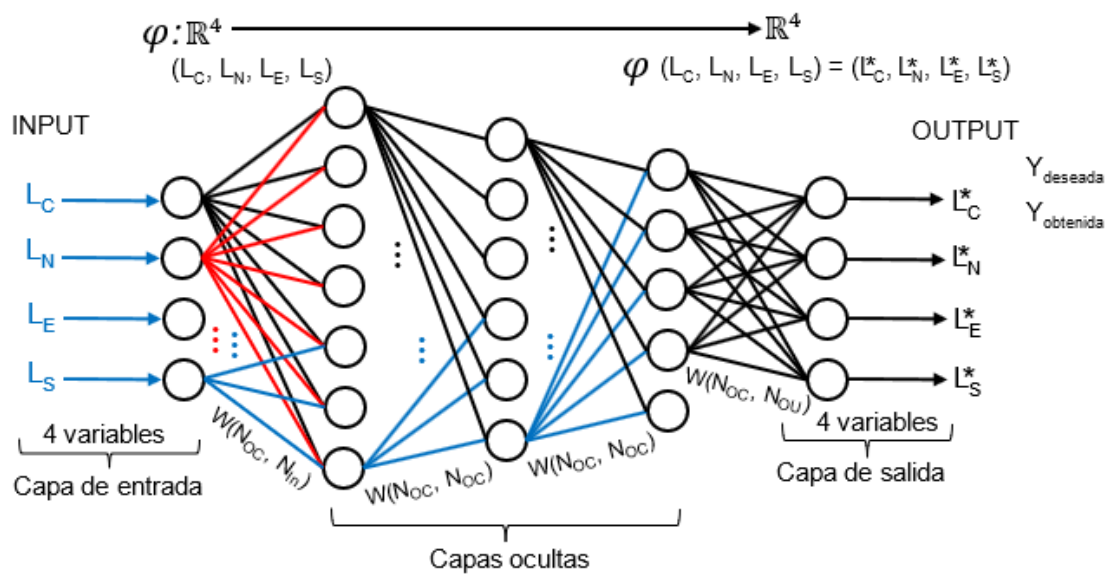
4.1. Resultados

En el presente trabajo de investigación se presenta el desarrollo de redes neuronales artificiales para la estimación y/o predicción de la cantidad de fallecidos por COVID 19 en Lima Metropolitana en una proyección hasta el 2025; así como también el número de nacimientos en Lima Metropolitana en una proyección hasta el 2025 considerándose como variables influyentes el número de fallecidos por COVID 19 y el número de nacimientos en Lima Centro, Norte, Este y Sur.

Se tiene una función y el esquema de la red neuronal que se ilustra en la Figura 19.

Figura 19

Esquema de la Red Neuronal



Fuente propia

Las redes neuronales artificiales se utilizan exitosamente para hallar los valores de los parámetros en diferentes problemas de ingeniería y estadística en los cuales las variables tienen una fuerte relación no lineal y es muy difícil modelar el problema mediante una función matemática fácilmente deducible.

4.1.1. Análisis de la Estructura de la Red Neuronal Artificial

Según el teorema de Kolmogorov es posible analizar cualquier función continua creciente en n variables aplicando sumas lineales más una función no-lineal continua y creciente en una variable. Según esto el conjunto de RNA a partir de tres capas, que son la de entrada, oculta y salida, es un conjunto denso en el espacio de las funciones continuas en n variables, y por ello, una red multicapa con una sola capa oculta permite realizar la aproximación hasta el nivel que se desee de cualquier función continua en un intervalo, siendo apropiadoras universales de funciones.

La RNA del tipo feedforward con aprendizaje backpropagation, definida por Rumelhart, tiene estructura de computación paralela según la cual una alta cantidad de unidades pequeñas de cálculo denominadas neuronas están todas interconectadas con la capa anterior de la cual reciben información y con la capa posterior hacia donde envían la información.

Estas redes están conformadas por la primera capa de entrada con variables elegidas que son neuronas receptoras o de entrada que intervienen en el resultado del problema. La capa de entrada se conecta a una o más capas ocultas en las cuales se realizan los cálculos. Por último, la información transformada llega a la capa de salida que proporciona los resultados, que corresponden a las variables de salida o neuronas de salida que interpretan el comportamiento del problema de acuerdo con las variables de entrada. Las capas ocultas están dotadas de una función de activación que limita la salida a un rango cercano, en la capa de salida se producen todos los valores de estimación. La salida de cada capa se expresa mediante:

$$Y_{\{N \times 1\}} = f(W_{N \times M} X_{M \times 1} + b_{N \times 1}) \dots (1)$$

Y : vector que contiene la salida de las N neuronas de una capa dada.

W: matriz de pesos sinápticos (importancias) para cada una de las M salidas para las N neuronas,

X: vector de entradas,

b: vector de sesgos o bases.

f es la función de activación.

Para la RNA la función de activación no-lineal es una función tangente hiperbólica de la forma:

$$f(Z) = \frac{1 - e^{-2Z}}{1 + e^{-2Z}}$$

Siendo Z la expresión contenida dentro del paréntesis de la ecuación (1).

4.1.2. Aprendizaje y Entrenamiento de la Red Neuronal Artificial

El aprendizaje backpropagation es una técnica que consiste en desarrollar una optimización basada en derivadas, tal que el error es derivable tanto en función de los pesos de la capa de salida como de los pesos de la capa oculta.

Para ello se aplica la regla de la cadena con la finalidad de minimizar el tamaño del error de entrenamiento de la red neuronal que consiste en la diferencia entre los valores calculados por la RNA con un conjunto determinado de pesos y los valores originales.

Luego, tanto el error como las correcciones realizadas a los pesos se envían desde la capa de salida hacia atrás a la capa de entrada, lo cual justifica su denominación de *propagación hacia atrás*. En este caso, se eligió como forma de

entrenamiento el *método de descenso por gradiente*, correspondiente al gradiente conjugado con escalamiento SCG (Scale Conjugate Gradient).

4.1.3. Evaluación del Desempeño de la Red Neuronal Artificial.

El desempeño de una RNA durante el entrenamiento y la validación se evalúa mediante el error promedio cuadrado RMSE (RootMean Square Error), el total de los cuadrados de los errores SSE (Sum of Squares of Error), el error relativo promedio MER (Mean Error Ratio), el error promedio cuadrado MSE (Mean Square Error), el factor de correlación R2 (R2 Correlación Factor).

$$MSE = \sum_{t=1}^N \left(\frac{Y_t - O_t}{T} \right)^2$$
$$RMSE = \sqrt{\frac{1}{T} \left[\sum_{t=1}^N \left(\frac{Y_t - O_t}{T} \right)^2 \right]}$$

donde, Y_t es la salida deseada, O_t es la salida obtenida, T es el número de registros en la base de datos, y N es el número de neuronas en la capa oculta.

4.1.4. Programación de la Red Neuronal en MATLAB

En este trabajo se realiza la construcción de dos redes neuronales desde el software Matlab, usamos como primera base de datos el archivo Muertos COVID-19 Lima Metropolitana 2022, y como segunda base de datos Nacidos Lima Metropolitana 2022, de los cuales el 90 % será usado como base de datos y el 10 % como fase de validación, utilizamos las herramientas que ofrece Matlab para el armado de la red, e implementamos un código para la manipulación de datos y los resultados que nos ofrece esta red neuronal.

Primera red Neuronal (Fallecidos por COVID 19)

Datos de entrada

Fallecidos por COVID 19 en Centro de Lima.

Fallecidos por COVID 19 en Norte de Lima.

Fallecidos por COVID 19 en Este de Lima.

Fallecidos por COVID 19 en Sur de Lima.

Datos de Salida

Fallecidos por COVID 19 en Centro de Lima al día siguiente.

Fallecidos por COVID 19 en Norte de Lima al día siguiente.

Fallecidos por COVID 19 en Este de Lima al día siguiente.

Fallecidos por COVID 19 en Sur de Lima al día siguiente.

Segunda red Neuronal (Nacimientos en Lima Metropolitana)

Datos de entrada

Nacimientos en Centro de Lima.

Nacimientos en Norte de Lima.

Nacimientos en Este de Lima.

Nacimientos en Sur de Lima

Datos de Salida

Nacimientos en Centro de Lima al día siguiente.

Nacimientos en Norte de Lima al día siguiente.

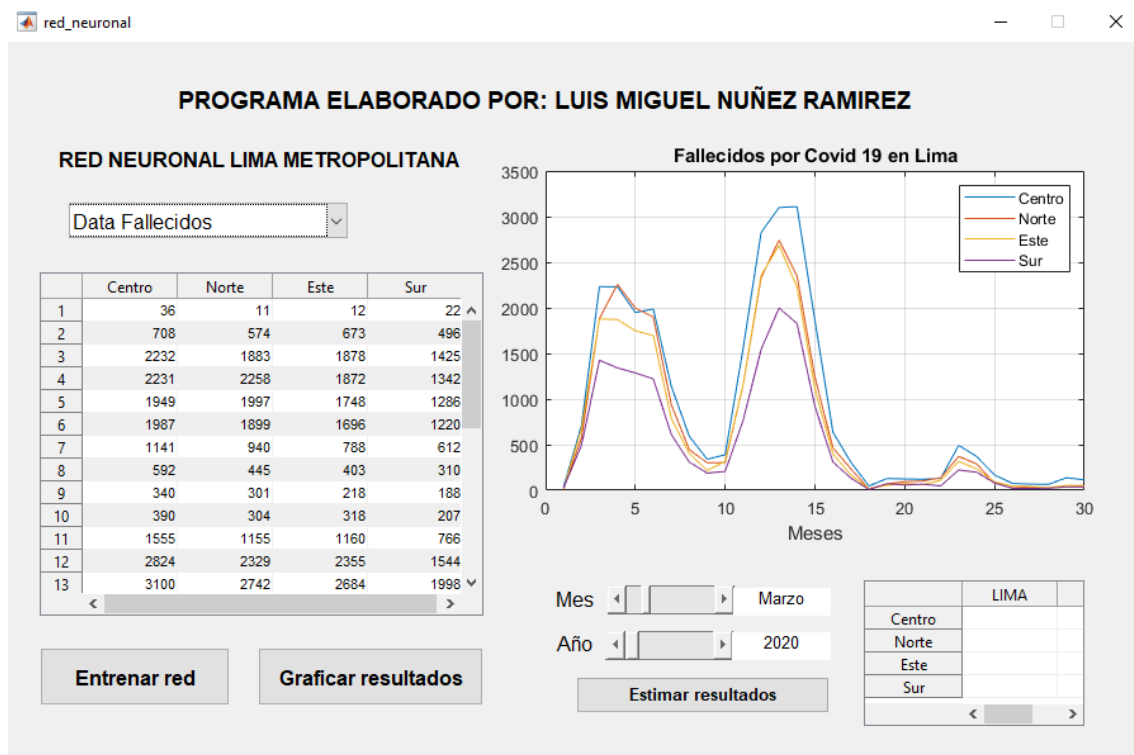
Nacimientos en Este de Lima al día siguiente.

Nacimientos en Sur de Lima al día siguiente.

4.1.5. Análisis de Resultados

Figura 20

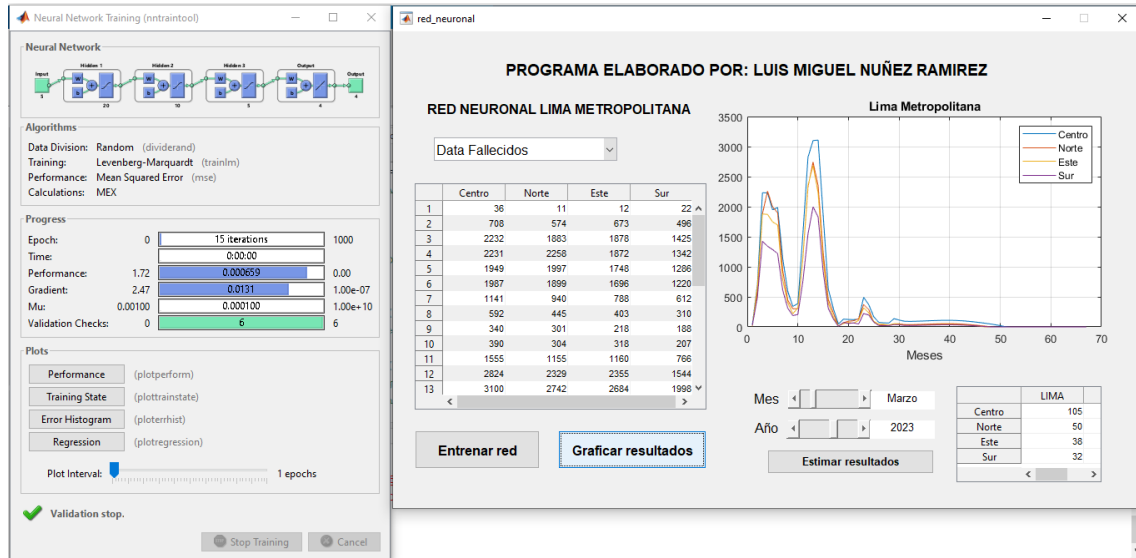
Data de Fallecidos por COVID 19 en Lima Metropolitana sin entrenar



Se procede a construir la red neuronal para estimar la cantidad de fallecidos en Lima metropolitana por COVID 19 con una proyección hasta el 2025.

Figura 21

Data de Fallecidos por COVID 19 en Lima Metropolitana entrenadas



Los componentes de la interfaz gráfica están dados por:

- Tabla de datos: En esta tabla se muestra la cantidad de fallecidos en Lima Centro, Norte, Este y Sur por COVID 19 mes a mes.
- Gráfica: La gráfica representa la cantidad de fallecidos vs la cantidad de meses desde el inicio de la Pandemia hasta el 2025.
- Red Neuronal: La ventana que está al lado izquierdo muestra los componentes de la red neuronal, así como también su performance.
- Predictor: En la parte inferior derecha de la ventana derecha se puede elegir la fecha para mostrar los resultados que nos proporciona la red.

En la Figura 20, puede apreciarse tres picos o máximos, esto hace referencia a las tres primeras olas que se obtuvo por la pandemia hasta Julio de 2022 (observar datos en el Excel)

La red neuronal se encarga de entrenar la base de datos, sujeto a las variables de entrada y salida ya mencionadas, razón por la cual la red ya es capaz de predecir la cantidad de fallecidos hasta el año 2025.

Los resultados que ofrece la red neuronal pueden apreciarse en la nueva gráfica, se observa la presencia de una cuarta ola, pero es muy pequeña, esto se debe a la efectividad de las vacunas y a la inmunidad de rebaño generada por los contagios masivos.

La proyección generada por la red neuronal indica que el año 2025, la cantidad de fallecidos por COVID será nula, puesto que se habrá generado inmunidad en el individuo para esta enfermedad.

Figura 22

Data de Nacimientos en Lima Metropolitana sin entrenar


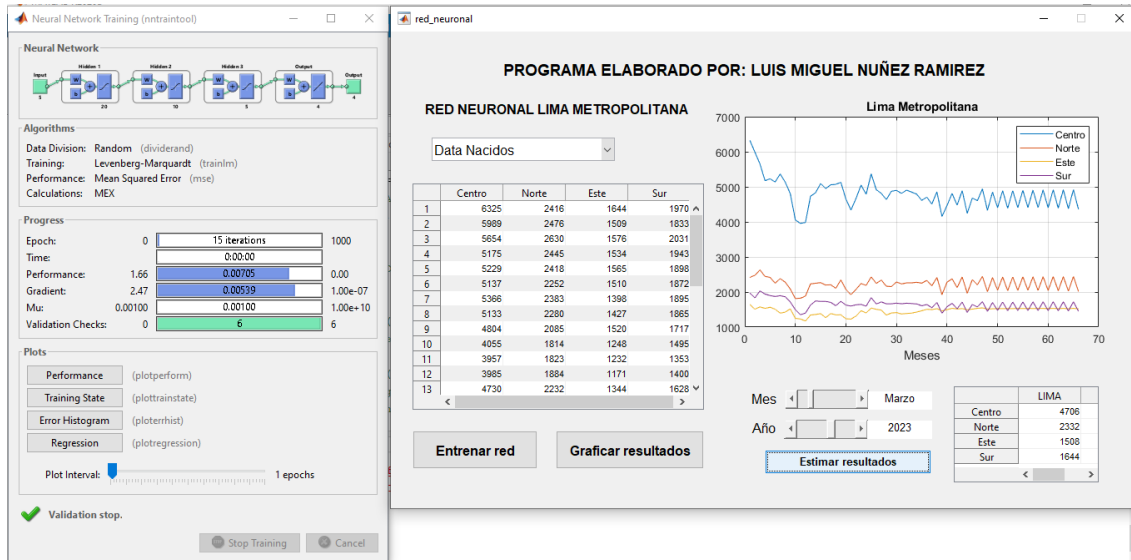


Figura 23

Data de Nacimientos en Lima Metropolitana entrenadas



Las componentes de la interfaz gráfica están dadas por:

- Tabla de datos: En esta tabla se muestra la cantidad de Nacimientos en Lima Centro, Norte, Este y Sur desde inicios de la pandemia mes a mes.
- Gráfica: La gráfica representa la cantidad de Nacimientos vs la cantidad de meses desde el inicio de la Pandemia hasta el 2025.
- Red Neuronal: La ventana que está al lado izquierdo muestra los componentes de la red neuronal, así como también su performance.
- Predictor: En la parte inferior derecha de la ventana derecha se puede elegir la fecha para mostrar los resultados que nos proporciona la red.

En la Figura 22, puede apreciarse que Lima centro se vio afectada a inicios de la pandemia puesto que disminuyó su tasa de nacimientos de manera radical en primer año.

Las restricciones que se impusieron durante la pandemia como estado de emergencia, generaron incertidumbre en los ciudadanos, la economía se vio afectada drásticamente, se generó desempleo y la opción de tener hijos en época de crisis deja de serlo hasta que se regule la economía del país.

La red neuronal se encarga de entrenar la base de datos, sujeto a las variables de entrada y salida ya mencionadas, razón por la cual la red ya es capaz de predecir la cantidad de nacimientos hasta el año 2025.

Una vez puestas en marcha las vacunas y con la inmunidad generada en el individuo observamos que la tasa de nacimiento vuelve aumentar en toda Lima Metropolitana, pero aumenta lentamente, puesto que aún se mantiene la incertidumbre.

Figura 24

Gráfica de fallecidos del 2020



Figura 25

Gráfica de fallecidos del 2021

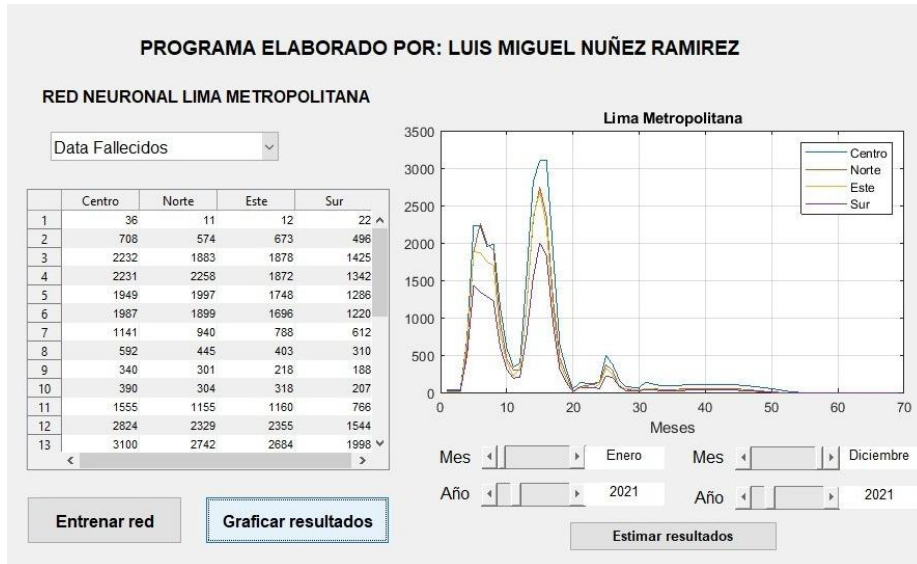


Figura 26

Gráfica de fallecidos del 2022

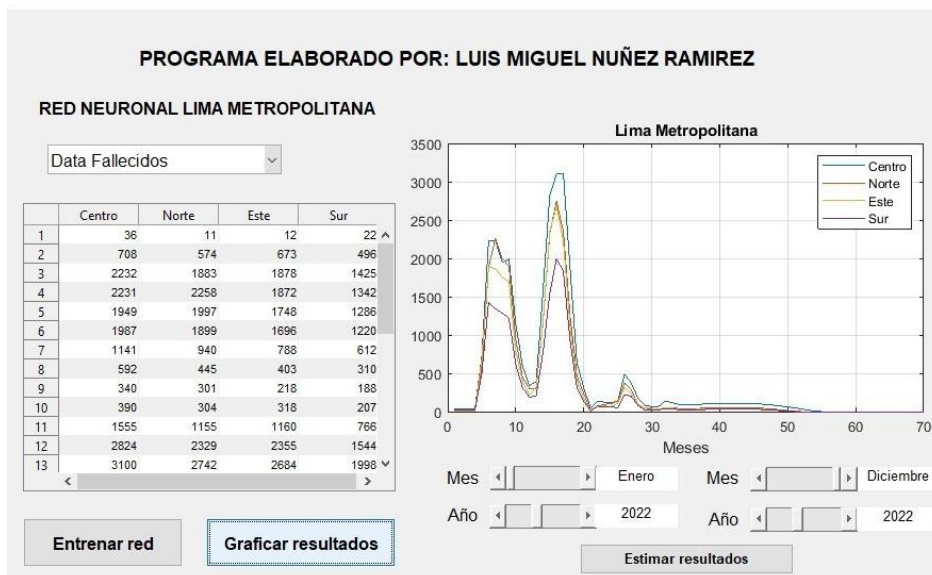


Figura 27

Gráfica de fallecidos del 2023

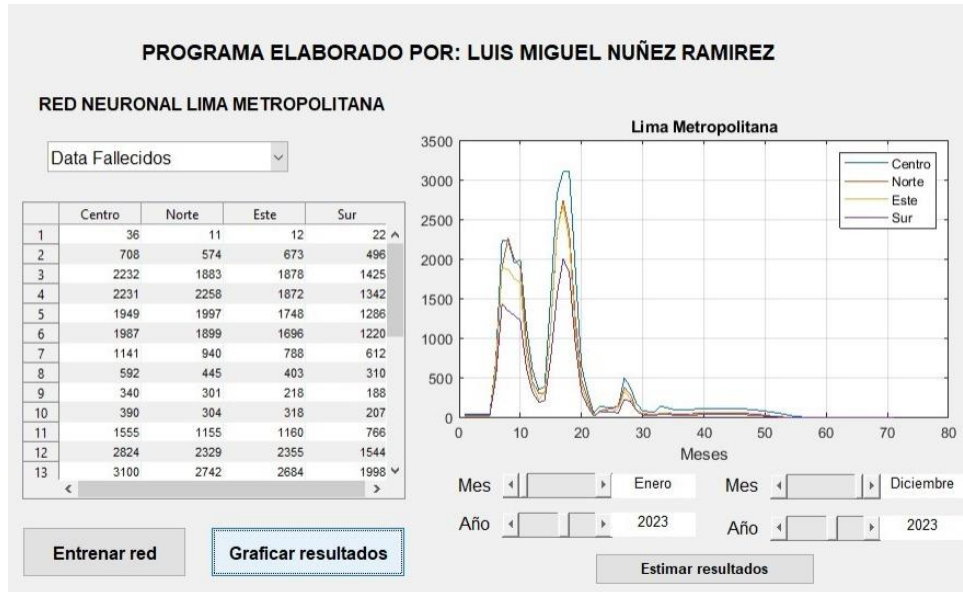


Figura 28

Gráfica de fallecidos del 2024

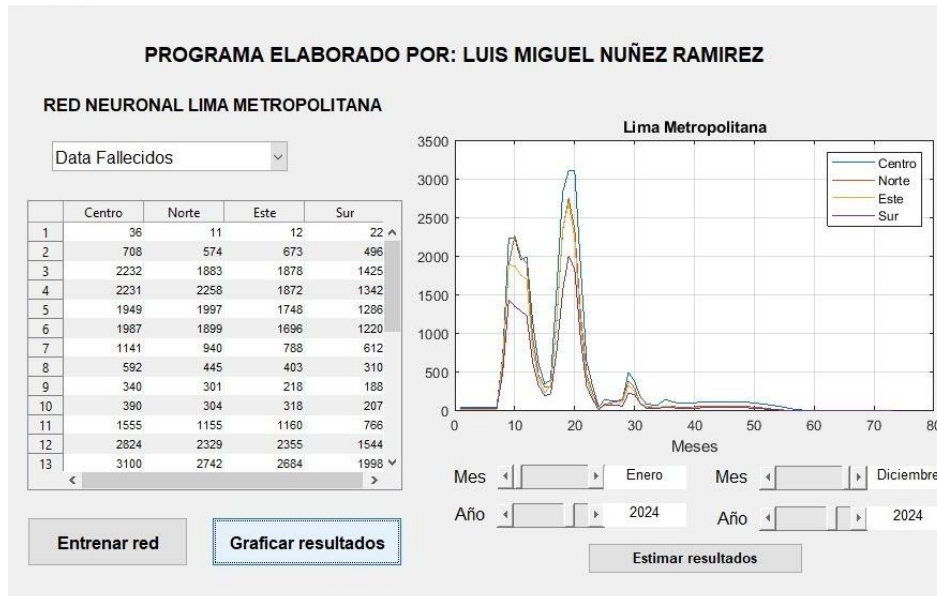


Figura 29

Gráfica de fallecidos del 2025

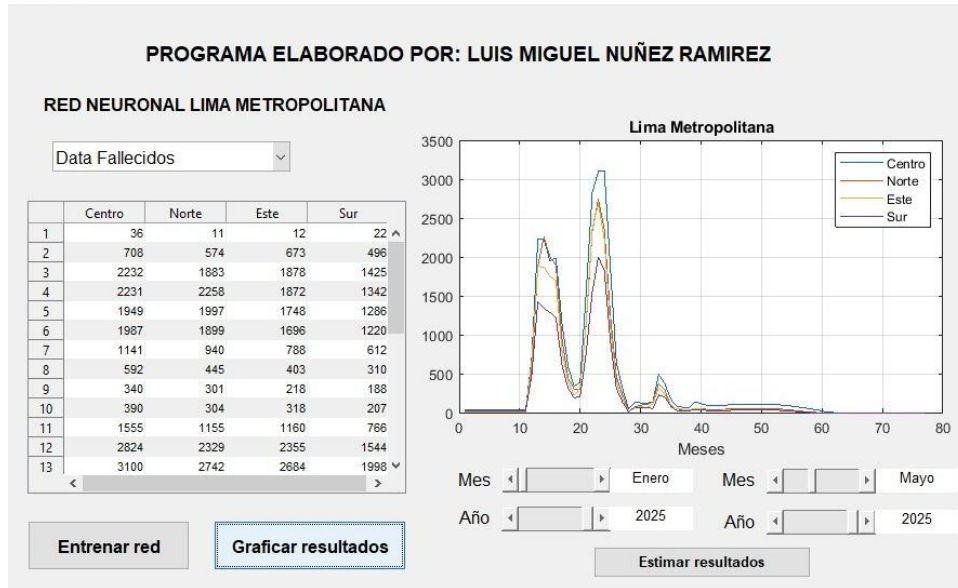


Figura 30

Gráfica de nacidos del 2020




Figura 31

Gráfica de nacidos del 2021




Figura 32

Gráfica de nacidos del 2022




Figura 33

Gráfica de nacidos del 2023




Figura 34

Gráfica de nacidos del 2024





Figura 35

Gráfica de nacidos del 2025



4.2. Discusión

Las redes neuronales pueden emplearse en cualquier campo de la ingeniería y estadística, es una herramienta poderosa para la predicción de datos a partir de un conjunto de datos.

NUESTRA HIPÓTESIS GENERAL: Mediante el uso de un modelo matemático de red neuronal supervisada es posible explicar los cambios demográficos en la población de Lima Metropolitana durante el periodo 2020 de desarrollo de la pandemia del COVID-19 y su proyección 2021-2025, se confirma, debido a que en el presente trabajo de investigación la parte importante es la elaboración y construcción de las redes neuronales supervisadas usando el software MATLAB, que nos permitieron realizar las estimaciones y/o predicciones, tanto de la cantidad de fallecidos por COVID-19, como del número de nacimientos en Lima Metropolitana durante el periodo

2020 (quincena de marzo) de desarrollo de la pandemia del COVID-19 y sus proyecciones para el periodo 2021-2025. Para ello, trabajamos con la data de fallecidos y nacidos (ver Tablas 11, 12, 13, 14, 15 y 16), considerando como variables influyentes el número de fallecidos por COVID-19 y el número de nacidos en Lima Centro, Norte, Este y Sur.

Por ello, la construcción de las redes neuronales usando MATLAB permitió que se genere la interfaz gráfica cuyas componentes son: tabla de datos, gráficas, red neuronal y el modelo predictor. Esto es, entrenada la red neuronal nos permite estimar resultados obteniendo gráficas y diagramas de barras, por ejemplo, ver Figuras 27 y 39.

Así, por ejemplo, la proyección generada de los diagramas de barras (ver Figura 41) nos permite decir que, en el año 2025, la cantidad de fallecidos por COVID-19 será nula, debido a que se habrá generado inmunidad en las personas debido a la aplicación y efectividad de las diversas vacunas que se compraron y, muy probablemente, a la llamada inmunidad de rebaño generada por los contagios masivos que tuvo que soportar la población peruana y, en particular, Lima Metropolitana con sus cuatro conos.

De la misma manera, la proyección generada de los diagramas de barras (ver Figura 47) nos permite decir que, en el año 2025, la tasa de nacimientos vuelve a aumentar, pero muy lentamente, en toda Lima Metropolitana, puesto que aún se mantiene la desconfianza e incertidumbre ocasionada por la pandemia.

Este resultado tiene una similitud con las conclusiones de Sosa, M., Ortiz, E., Cabello, A. Impacto del rezago social en el número de muertes y contagios por COVID-19 en México, análisis con redes neuronales artificiales empleando información a nivel municipal. Vol. 65, N.º 5, 2020, donde manifiesta que el brote de la pandemia COVID-19, como en otros países de América Latina, hizo noticia en México la vulnerabilidad de algunas regiones debido a las carencias en los servicios de salud, vivienda y

servicios básicos como electricidad, agua y alcantarillado. El análisis de investigación se realizó aplicando redes neuronales artificiales haciendo uso de datos oficiales municipales sobre muertes y contagios acumulados. Con la diferencia, que en nuestro trabajo de investigación hemos usado redes neuronales aplicando el entorno MATLAB y la data del MINSAs.

Con respecto a nuestra primera *hipótesis específica*: Mediante la aplicación de un modelo matemático de red neuronal supervisada es posible explicar los cambios que se produjeron en la natalidad de la población de Lima Metropolitana durante el periodo 2020 de desarrollo de la pandemia del COVID-19 y cuál es su proyección para el periodo 2021-2025, se confirma, puesto que los resultados que nos ofrece la red neuronal entrenada pueden apreciarse en las diversas gráficas y diagramas de barras que se pueden obtener estimando resultados mensuales, trimestrales o anuales, por lo cual la red neuronal entrenada es capaz de predecir la cantidad de nacidos hasta el año 2025 (ver Figuras 30 al 35).

Este resultado tiene alguna afinidad con las conclusiones de García, M., Rodríguez, Y., Ramón, A., Bello, R. (2020), quienes realizaron una investigación orientada a enfrentar y contener los efectos devastadores del COVID-19, haciendo uso de herramientas de inteligencia artificial para obtener conocimiento útil en la predicción de la letalidad de la COVID-19. Con la salvedad, que en nuestra investigación utilizamos el lenguaje de programación MATLAB y el algoritmo BACKPROPAGATION para la predicción y/o proyección de la natalidad hasta el año 2025.

En relación a nuestra segunda hipótesis específica, haciendo uso de un modelo matemático de red neuronal supervisada será posible definir qué cambios se produjeron en la mortalidad de la población de Lima Metropolitana durante el periodo 2020 de desarrollo de la pandemia del COVID-19 y cuál es su proyección para el periodo 2021-2025, se confirma, debido a que los resultados que nos da la red neuronal entrenada pueden apreciarse en las diversas gráficas y diagramas de barras que nos ofrecen otra alternativa de apreciar el comportamiento de la cantidad de

fallecidos en los cuatro conos que tiene Lima Metropolitana, estimando resultados mensuales, trimestrales o anuales, siendo capaz de predecir la cantidad de fallecidos hasta el año 2025 (ver Figuras 36 al 41).

Este resultado tiene alguna afinidad con las investigaciones de Bietta, Morini, Kamber, Cozzolino (2020) quienes analizaron la relación del nuevo virus COVID-19 con el cambio ocasionado en la tasa de mortalidad de la región de Umbria en Italia. Con la diferencia, que en nuestra investigación, hemos utilizado redes neuronales empleando el programa MATLAB para la predicción y/o proyección de la mortalidad en Lima Metropolitana hasta el año 2025.

Asimismo, con respecto a nuestra tercera hipótesis específica, aplicando un modelo matemático de red neuronal supervisada es posible explicar cómo afectarán los cambios demográficos en la población de Lima Metropolitana ocurridos durante el periodo 2020 de desarrollo de la pandemia COVID-19 a las actividades socioeconómicas del periodo 2021-2025, se confirma, puesto que las proyecciones de las tasas de natalidad y mortalidad que nos dieron las redes neuronales usando el software matemático MATLAB, nos indican que, tendríamos un buen panorama de recuperación socioeconómico, aunque sería un proceso lento. Las restricciones rígidas que se impusieron durante la pandemia del COVID-19, como el estado de emergencia, originaron desconcierto e incertidumbre en la ciudadanía, desnudándose la fragilidad de nuestro precario sistema de salud, la economía se vio afectada en forma drástica, generándose desempleo, el sector educación se vio afectada y la opción de tener hijos en esta época de pandemia deja de ser una prioridad hasta que se supere la crisis socioeconómica de país, que debe ser un proceso lento y seguro.

Esta hipótesis tiene cierta afinidad en la investigación de Barrutia, I., Silva, H., Sánchez, R. (2021) quienes afirmaron que las medidas de aislamiento social que decretó el gobierno peruano en marzo de 2020 mostraron las grandes falencias del sistema de salud y recomendaron cómo debería actuar la sociedad para enfrentar la pandemia (Maguiña, 2020).

Figura 36

Diagrama de barra de fallecidos del 2020




Figura 37

Diagrama de barra de fallecidos del 2021




Figura 38

Diagrama de barra de fallecidos del 2022




Figura 39

Diagrama de barra de fallecidos del 2023




Figura 40

Diagrama de barra de fallecidos del 2024

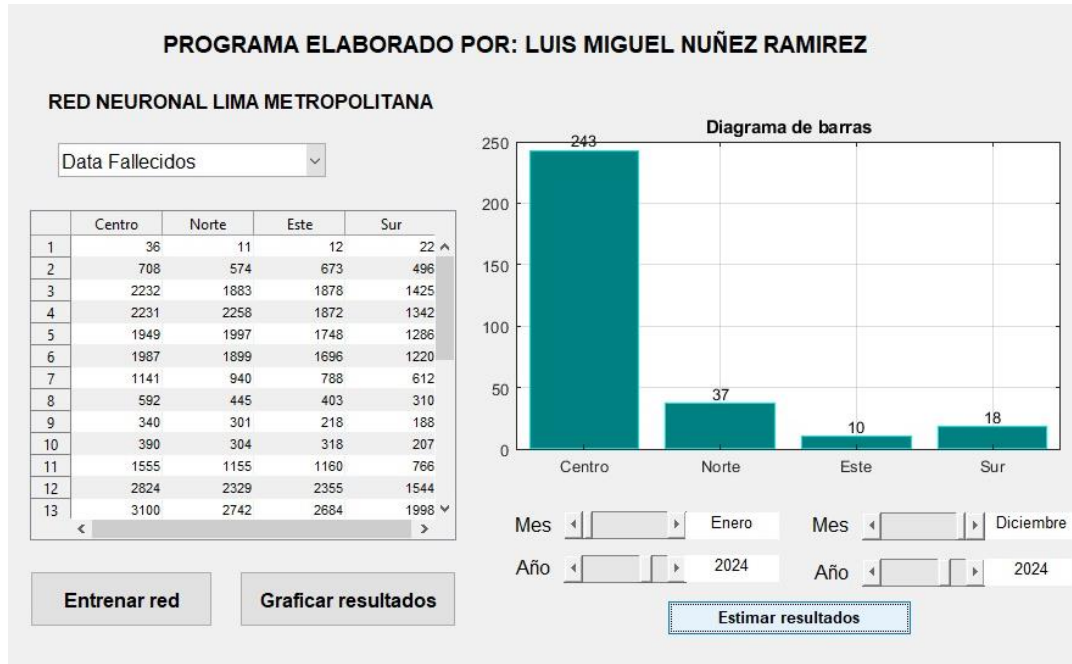


Figura 41

Diagrama de barra de fallecidos del 2025

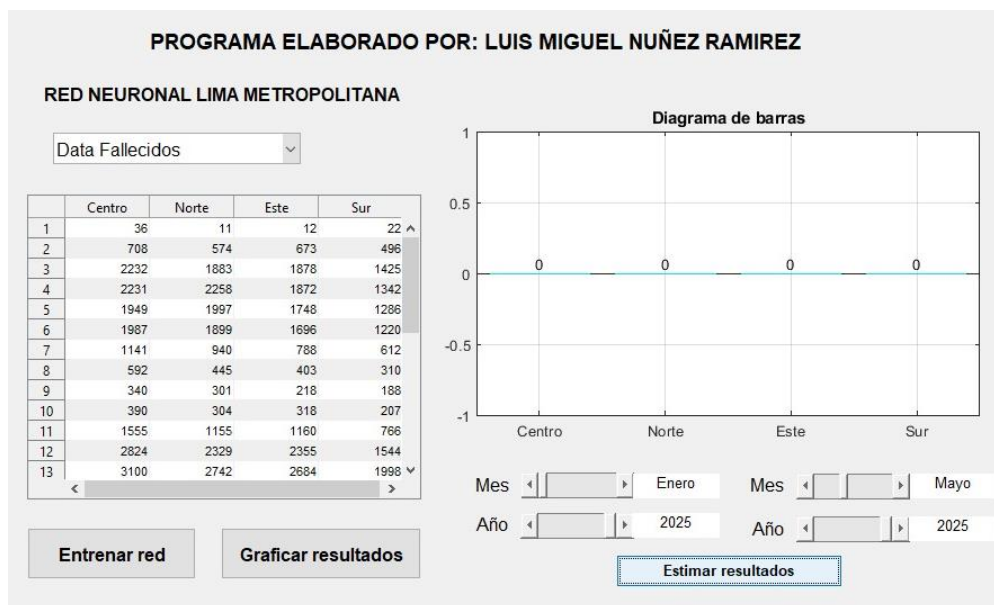


Figura 42

Diagrama de barra de nacidos del 2020




Figura 43

Diagrama de barra de nacidos del 2021




Figura 44

Diagrama de barra de nacidos del 2022




Figura 45

Diagrama de barra de nacidos del 2023




Figura 46

Diagrama de barras de nacidos del 2024





Figura 47

Diagrama de barra de nacidos del 2025



CAPÍTULO V: CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

La presente investigación nos permitió explicar, haciendo uso de un modelo matemático de red neuronal supervisada, que a partir de la quincena de marzo de 2020 se originaron cambios demográficos en la población de Lima Metropolitana por la desproporcionada cantidad de fallecidos durante todo el año 2020 y gran parte del año 2021, como se puede ver en las figuras 36 y 37. Las proyecciones que nos dan las redes neuronales hasta el año 2025, con respecto a las tasas de natalidad y mortalidad son positivas, la cual nos indicaría que el proceso de recuperación socioeconómico será factible siempre y cuando la política de turno, promueva nuevas formas de gestión pública reactivadoras y dinámicas en los diversos sectores económicos y sociales.

También fue posible explicar, aplicando el modelo matemático de red neuronal supervisada, que la tasa de natalidad de alguna forma se vio afectada durante el desarrollo de la pandemia, especialmente en los años 2020 y 2021, como se puede ver en las figuras 42 y 43. La proyección generada por la red neuronal indicaría que, hasta el año 2025, la cantidad de nacimientos en Lima Metropolitana irá en aumento, pero de manera progresiva como se puede ver en las figuras 45,46 y 47.

Del mismo modo, usando el modelo matemático de red neuronal supervisada, fue posible explicar que la tasa de mortalidad de Lima Metropolitana se vio afectada drásticamente en los años 2020 y 2021 del desarrollo de la pandemia, como se puede ver en las figuras 36 y 37. La proyección generada por la red neuronal indicaría que en el año 2025, la cantidad de fallecidos por COVID-19 será nula, como se puede ver en la figura 41.

Podemos concluir, aplicando el modelo matemático de red neuronal supervisada que, después de haber sido afectada la población de Lima Metropolitana, muy fuertemente por la pandemia del COVID-19, en los dos

primeros años de su desarrollo, 2020 y 2021, las proyecciones generadas por la red neuronal hasta el año 2025, referentes a las tasas de natalidad y mortalidad, como se puede observar en las figuras 36 hasta la figura 47, nos estarían dando un buen panorama de recuperación socioeconómica. Todo dependerá de la estabilidad política del gobierno de turno.

5.2. Recomendaciones

Para el desarrollo de proyectos de investigación, como el realizado en esta investigación, el uso del MATLAB es una alternativa de solución para la construcción de una red neuronal, porque dispone de un amplio bagaje de programas de apoyo especializados que extienden de manera significativa la cantidad de funciones incorporadas en el programa principal.

En nuestro trabajo de investigación se realizó la simulación de dos redes neuronales teniendo como base cuatro variables influyentes en el entorno MATLAB, entrenándola mediante el algoritmo de aprendizaje BACK PROPAGATION. Por ello, sería recomendable darles a las variables influyentes, más características de análisis, como, por ejemplo, edades, géneros, condición económica, etc., con lo cual se enriquecería mucho más el análisis de futuros proyectos.

Asimismo, se optó por la construcción de redes neuronales en MATLAB, pero algunos especialistas e investigadores recomiendan para la construcción de redes neuronales el programa PHYTON, puesto que en dicho programa existen múltiples librerías que permiten crear modelos basados en redes neuronales.

REFERENCIA BIBLIOGRÁFICA Y VIRTUAL

Acevedo, S. I., Barrutia, I., Urquizzo, J. A., & Venero, R. (2019). La administración pública y sentido de bienestar para el progreso. Religación. *Revista de ciencias sociales y humanidades*, 4(17), 116-123.

Allison, P.D. (1985). *Event history analysis. Regression for longitudinal event data*. Sag Pub.

Aragón, J. & Cruz, M. (2020). *Datos y tendencias del Avance del COVID19 en Perú después de 70 días del primer caso reportado y de 60 días de cuarentena* [Reporte]. Escuela de gobierno y políticas públicas, PUCP.

Arbib, M. (1995). *The handbook of brain theory and neural networks*. Editorial Advisor y Board.

<https://doc.lagout.org/science/Artificial%20Intelligence/Neural%20networks/The%20Handbook%20Of%20Brain%20Theory%20And%20Neural%20Networks%20Nd%20Ed%20-%20Michael%20A%20Arbib.pdf>

Barrutia-Barreto, I., Sánchez-Sánchez, R. M. & Silva-Marchan, H. A. (2021). Consecuencias económicas y sociales de la inamovilidad humana bajo COVID-19 caso de estudio Perú. *Lecturas de Economía*, 94, 285-303.

Bianchini, M., Maggini, M., Sarti, L., & Scarselli, F. (2005). Recursive neural networks learn to localize faces. *Pattern Recognition Letters*, 26(12), 1885–1895. <https://www.sciencedirect.com/science/article/abs/pii/S0167865505000656>

Bietta, C., Morini, M., Zaidi, A. K., Cozzolino, F., & Dehgani-Mobaraki, P. (2020). *Impact of COVID-19 on the mortality rates for the resident population of the Umbria region in Italy*. MedRxiv.

<https://www.medrxiv.org/content/10.1101/2020.09.24.20200667v1.full>

Cardona, J. (1998). La Salud pública en período de crisis. *Revista Cubana de medicina general integral*, 14(3), 286-294.

http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0864-21251998000300015

Cox, D.R. (1972). Regression models and life-tables. *Journal of the Royal Statistical Society. Series Bm*, 34(2), 187-202.

http://www.medicine.mcgill.ca/epidemiology/hanley/c626/cox_jrssB_1972_hi_res.pdf

Dipaola, E. (2020). Individualismo y pandemia: consecuencias y riesgos globales. *Reflexiones marginales*, 8(5).

Egmont-Petersen, M., De Ridder, D., & Handels, H. (2002). Image processing with neural networks - a review. *Pattern recognition*, 35(10), 2279-2301.
<https://www.sciencedirect.com/science/article/abs/pii/S0031320301001789>

El Peruano (8 de mayo de 2023). *Fortalecer el primer nivel de atención en salud*.
<https://elperuano.pe/noticia/174731-fortalecer-el-primer-nivel-de-atencion-en%20salud>

Foladori, G., & Delgado, R. (2020). Para comprender el impacto disruptivo del covid-19, un análisis desde la crítica de la economía política. *Revista Migración y Desarrollo*, 18(34), 139-156.

<https://estudiosdeldesarrollo.mx/migracionydesarrollo/wp-content/uploads/2020/08/34-6.pdf>

García, M., Rodríguez, Y., Ramón, A, Bello, B., Filiberto, Y., Rosete, A., Caballero, Y., & Bello, R. (2020). Adquisición de conocimiento sobre la letalidad de la COVID-

19 mediante técnicas de inteligencia artificial. *Anales de la Academia de Ciencias de Cuba*, 10(3).

<http://www.revistaccuba.cu/index.php/revacc/article/view/891/912>

Grossberg, S., & Carpenter G. (1998). Adaptive Resonance Theory. *The Handbook of Brain Theory and Neural Networks*, (2), 1-12.

Hernández, A. (1998). El estudio del crecimiento de las poblaciones humanas. *Papeles de Población*, 10, 17-20.

Instituto Nacional de Estadística e Informática (2020). *La población de Lima supera los nueve millones y medio de habitantes*. <https://m.inei.gob.pe/prensa/noticias/la-poblacion-de-lima-supera-los-nueve-millones-y-medio-de-habitantes-12031/>

Jang, J. (1998). *Comparative analysis of statistical methods and neural networks for predicting life insurers' insolvency (bankruptcy)* [Tesis doctoral, The University of Texas at Austin]. Repositorio institucional de la University of Texas at Austin.

John Hopkins University. (2020). *Coronavirus Research Center*.

Jorge, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Universidad Tecnológica Nacional. <https://www.studocu.com/pe/document/universidad-san-ignacio-de-loyola/historia-del-pensamiento-politico/matich-redesneuronales/25358068>

Kolmogorov, A. (1957). On the representation of continuous functions of many variables by superposition of continuous functions of one variable and addition. *Doklady Akademii Nauk SSRR*, 114, 953-956.

Lesky E. (1984). *Medicina Social. Estudios y testimonios históricos*. Ministerio de Sanidad y Consumo.

- Maguiña, Ciro. (2020). Pandemia de la Covid19 y su impacto en el sistema de salud peruano. *Revista Peruana de Medicina Integrativ*, 5(3), 93-94.
<https://rpmi.pe/index.php/rpmi/article/view/255/255>
- Márquez, J. (2020). Inteligencia Artificial y Big Data como soluciones frente a la Covid-19. *Revista Bioética y Derecho*, (50), 315-331.
https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1886-58872020000300019
- Mathivet, V. (2018). *Inteligencia Artificial para desarrolladores*. Eni.
- McCulloch, W., & Pitts, W. (1943). A logical calculus of ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115–133.
- Ministerio de Salud (2021). *Data Set de Fallecidos por COVID-19 - [Ministerio de Salud - MINSA]*. <https://www.datosabiertos.gob.pe/dataset/fallecidos-por-covid-19-ministerio-de-salud-minsa/resource/4b7636f3-5f0c-4404-8526>
- Ministerio de Salud (2021). *Fallecidos por COVID-19 - [Ministerio de Salud - MINSA]*. <https://www.datosabiertos.gob.pe/dataset/fallecidos-por-covid-19-ministerio-de-salud-minsa>
- Ministerio de Salud (2021). *Nacimientos según establecimientos de salud*. https://www.minsa.gob.pe/reunis/data/tablero_cnv.asp
- Montaño, J. (2002). *Redes Neuronales Artificiales aplicadas al Análisis de Datos* [Tesis doctoral, Universitat De Les Illes Balears]. Repositorio institucional de la Universitat De Les Illes Balears.
<https://www.tdx.cat/bitstream/handle/10803/9441/tjjmm1de1.pdf?sequence=1&isAllowed=y>

Montgomery, D. C., Peck, E. A. & Vining, G. G. (2012). *Introducción al análisis de regresión lineal*. Cengage Learning.

https://www.academia.edu/42811449/Introduccion_al_Analisis_de_Regresion_Lineal_Tercera_Edicion_Montgomery_Peck_Vining

Narasimha, P., Delashmit, W., & Manry, M. (2008). An integrated growing-pruning method for feedforward network training. *Neurocomputing*, 71, 2831- 2847. <https://www.sciencedirect.com/science/article/abs/pii/S0925231207003086?via%3Dihub>

Ohno-Machado, L., Walker, M. y Musen, M. (1995). Hierarchical neural networks for survival analysis. *Medinfo*, 8(1), 828-832.

Organización Mundial de la Salud (2021). *Coronavirus*. https://www.who.int/es/health-topics/coronavirus#tab=tab_1

Organización Panamericana de la Salud (2000). *Salud de la población. Conceptos y estrategias para las políticas públicas saludables: la perspectiva canadiense*.

Organización Panamericana de la Salud (2021). *Enfermedad por el Coronavirus (COVID-19)*. <https://www.paho.org/es/enfermedad-por-coronavirus-covid-19>

Otoya-Tono, A., García-Chabur, M., Jaramillo-Moncayo, M. & Campos, A. (2020). COVID-19: generalidades, comportamiento epidemiológico y medidas adoptadas en medio de la pandemia en Colombia. *Acta de Otorrinolaringología & Cirugía de Cabeza y Cuello*, 48(1), 79-92.

<https://revista.acorl.org.co/index.php/acorl/article/view/519/430>

Palmer, A., & Montañó, J. (2002). Redes Neuronales artificiales aplicadas al análisis de supervivencia: un estudio comparativo con el modelo de regresión de Cox en su aspecto predictivo. *Psicothema*, 14(3), 630-636.

<https://pesquisa.bvsalud.org/portal/resource/pt/ibc-17601>

Pérez, J., (2002). *Modelos predictivos basados en redes neuronales recurrentes de tiempo discreto* [Tesis doctoral, Universidad de Alicante]. Repositorio institucional de la Universidad de Alicante.

Pernalet, J., & Odor, Y. (2021). Modelo espacio-temporal y red neuronal de Kohonen en la estimación del Producto Interno Bruto, Exportaciones e Importaciones post Covid-19. *Ciencia Latina Revista Científica Multidisciplinar*, 5(2), 2108-2133. https://doi.org/10.37811/cl_rcm.v5i2.422

Pighi, P. (2020). *Coronavirus en Perú: 5 factores que explican por qué es el país con la mayor tasa de mortalidad entre los más afectados por la pandemia*. *BBC News Mundo*. <https://www.bbc.com/mundo/noticias-america-latina-53940042>

Ramírez, J., & Chacón, M. (2011). Redes Neuronales Artificiales para el procesamiento de imágenes. Una revisión de la última década. *Revista de Ingeniería Eléctrica, Electrónica y Computación*, 9(1), 7-16.

https://www.itson.mx/publicaciones/rieeyc/Documents/v9/art2vf_redes_neuronales_artificiales_para_el_procesamiento_de_imagenes-una_revision_de_la_ultima_decada.pdf

Real Academia Española - RAE. (2020). *Pandemia*. *Real Academia Española*. <https://dle.rae.es/pandemia?m=form>

Rojas, F. (2004). El componente social de la salud pública en el siglo XXI. *Revista Cubana Salud Pública*, 3(3).

http://scielo.sld.cu/scielo.php?script=sci_abstract&pid=S0864-34662004000300008&lng=es&nrm=iso&tlng=en

- Rubiolo, M. (2014). *Desarrollo de nuevos modelos y algoritmos basados en redes neuronales para tareas de minería de datos* [Tesis doctoral, Universidad Tecnológica Nacional]. Repositorio institucional de la Universidad Tecnológica Nacional. http://sinc.unl.edu.ar/sinc-publications/2014/Rub14/sinc_Rub14.pdf
- Russell, S., & Norvig, P. (2010). *Artificial Intelligence, A Modern Approach*. Pearson. https://people.engr.tamu.edu/guni/csce421/files/AI_Russell_Norvig.pdf
- Sarle, W.S. (1994). *Neural networks and statistical models*. [Conference]. Proceedings of the 19th Annual SAS Group conference.
- Sosa, M., Ortiz, E., & Cabello, A. (2020). Impacto del rezago social en el número de muertes y contagios por COVID-19 en México análisis con redes neuronales artificiales empleando información a nivel municipal. *Contaduría y administración*, 65(5), 1-17.
- <http://www.cya.unam.mx/index.php/cya/article/view/3020/1585>
- Tisdell, C. A. (2020). Economic, social and political issues raised by the COVID-19 pandemic. *Economic Analysis and Policy*, 68, 17-28.
- <https://pubmed.ncbi.nlm.nih.gov/32843816/>
- Universidad Johns Hopkins. (2020). *Coronavirus Resource Center: Análisis de mortalidad*. <https://coronavirus.jhu.edu/data/mortality>
- Vallin, J. (1994). *La demografía*. La Découverte.
- <https://repositorio.cepal.org/handle/11362/8862>
- Veera, M. (2010). Research Study of Neural Networks for image categorization and retrieval. *IEEE Computer and Automation Engineering International Conference, Singapore*, 2, 686-690.

Vega, E. (2020). *Aproximación sociológica para la comprensión de los desacuerdos entre las medidas gubernamentales y la respuesta social frente a la pandemia de Covid-19 en Perú desde un análisis macro-estructural*. CLCSO.- Consejo Latinoamericano de Ciencias Sociales.

Villamil, L. C. (2013). Epidemias y pandemias: una realidad para el siglo XXI. Un mundo y una salud. *Revista Lasallista de Investigación* 10(1), 7-8.

Zevallos, J., & Uriolo, C. (2020). Letalidad y la Mortalidad de Covid-19 en sesenta países afectados y su impacto en los aspectos demográficos, económico y de salud. *Revista Médica Herediana*, 31(4), 214-221.
http://www.scielo.org.pe/scielo.php?pid=S1018-130X2020000400214&script=sci_abstract

ANEXOS

Anexo 1

A continuación, se presenta el código base que modela el problema y donde se constituye la red neuronal que predice la cantidad de fallecidos por COVID 19.

```
clear; close all; clc;
A = xlsread('Muertos por COVID-19 en Lima Metropolitana','D4:AG33');
B = xlsread('Muertos por COVID-19 en Lima Metropolitana','D34:AG49');
C = xlsread('Muertos por COVID-19 en Lima Metropolitana','D50:AG67');
D = xlsread('Muertos por COVID-19 en Lima Metropolitana','D68:AG89');
N = 1:length(sum(A));
X = [N' sum(A)' sum(B)' sum(C)' sum(D)'];
plot(X(:,1),X(:,2:5))
title('Fallecidos por Covid 19 en Lima')
xlabel('Meses')
ylabel('Casos')
grid on
legend('Centro','Norte','Este','Sur')
Input = X(1:end-1,:);
Output = X(2:end,2:5);
B = [Input Output];
% Transformacion de los datos en [-1 a 1] <-- (p.ej. tansig)
[prel,PS] = mapminmax(B.',-1,1);    %% Lo transforma en puntos dentro del intervalo
[-1,1] en una sola fila
B_tt = mapminmax('apply',B',PS);    %% Se hace la transpuesta a 1 sola columna
% Se toma una muestra aleatoria
s = RandStream('mlfg6331_64');
Y_train = datasample(s,B_tt,length(B),2,'Replace',false);
Y_test = datasample(s,B_tt,5,2,'Replace',false);
% clasificando variables
T = Y_train(1:5,:); % Variables de Entradas
P = Y_train(6:9,:); % Variables de Salida
% Control de generacion de numeros aleatorios
rng(0,'v5uniform')
%=====
% Fase de entrenamiento (train)
%=====
% Creacion de la estructura del modelo RNA
net = feedforwardnet([20 10 5],'trainlm');%
Entrenamiento del modelo RNA
net = train(net,T,P);
```

```

% Evaluacion del modelo RNA con datos de entrenamiento
train_val = sim(net,T);
%=====
% Fase de validacion (tests)
%=====
% Entradas(xt) y salida(tt) para el testeo del RNA
testT = Y_test(1:5,:);
testP = Y_test(6:9,:);
% Evaluacion del modelo RNA con datos de testeo
test_val = sim(net,testT);
% Revertiendo la transformacion
data_real = mapminmax('reverse',[testT; testP],PS)';
data_test = mapminmax('reverse',[testT; test_val],PS)';
% Prediccion
v = [22 Output(end,:) 0 0 0 0];
xx = mapminmax('apply',v',PS);    %% Se hace la transpuesta a 1 sola columna
yy = sim(net,xx(1:5));
xy = [xx(1:5)' yy'];
sol = mapminmax('reverse',xy',PS)';
disp('Fallecidos en Lima: ')
fprintf('Lima centro: %f\n',sol(6));
fprintf('Lima norte: %f\n',sol(7));
fprintf('Lima este: %f\n',sol(8));
fprintf('Lima sur: %f\n',sol(9));
% Prediccion
for i = 1:36
v = [i+29 Output(end,:) 0 0 0 0];
xx = mapminmax('apply',v',PS);    %% Se hace la transpuesta a 1 sola columna
yy = sim(net,xx(1:5));
xy = [xx(1:5)' yy'];
sol = mapminmax('reverse',xy',PS)';
A = sol(6:9);
A(A <= 0) = 0;
Output(end+1,:) = A;
end
Output = [Input(1,2:5); Output];
M = 1:length(Output);
figure(2)
plot(M',Output)
title('Fallecidos por Covid 19 en Lima')
xlabel('Meses')
ylabel('Casos')
grid on
legend('Centro','Norte','Este','Sur')

```


Anexo 2

A continuación, se presenta el código base que modela el problema y donde se constituye la red neuronal que predice la cantidad de nacimientos en Lima Metropolitana.

```
clear; close all; clc;
A = xlsread('Nacidos en Lima Metropolitana','B4:AE7');
N = 1:length(A');
X = [N' A'];
plot(X(1:end-1,1),X(1:end-1,2:5))
title('Nacidos en Lima Metropolitana')
xlabel('Meses')
ylabel('Cantidad')
grid on
legend('Centro','Norte','Este','Sur')
Input = X(1:end-2,:);
Output = X(2:end-1,2:5);
B = [Input Output];
% Transformacion de los datos en [-1 a 1] <-- (p.ej. tansig)
[prel,PS] = mapminmax(B.',-1,1);    %% Lo transforma en puntos dentro del intervalo
[-1,1] en una sola fila
B_tt = mapminmax('apply',B',PS);    %% Se hace la transpuesta a 1 sola columna
% Se toma una muestra aleatoria
s = RandStream('mlfg6331_64');
Y_train = datasample(s,B_tt,length(B),2,'Replace',false);
Y_test = datasample(s,B_tt,5,2,'Replace',false);
% clasificando variables
T = Y_train(1:5,:); % Variables de Entradas
P = Y_train(6:9,:); % Variables de Salida
% Control de generacion de numeros aleatorios
rng(0,'v5uniform')
%=====
% Fase de entrenamiento (train)
%=====
% Creacion de la estructura del modelo RNA
net = feedforwardnet([24 12 6],'trainlm');
% Entrenamiento del modelo RNA
net = train(net,T,P);
% Evaluacion del modelo RNA con datos de entrenamiento
train_val = sim(net,T);
%=====
% Fase de validacion (tests)
%=====
% Entradas(xt) y salida(tt) para el testeo del RNA
```

```

testT = Y_test(1:5,:);
testP = Y_test(6:9,:);
% Evaluacion del modelo RNA con datos de testeo
test_val = sim(net,testT);
% Revertiendo la transformacion
data_real = mapminmax('reverse',[testT; testP],PS);
data_test = mapminmax('reverse',[testT; test_val],PS);
% Prediccion
v = [22 Output(end,:) 0 0 0 0];
xx = mapminmax('apply',v',PS);    %% Se hace la transpuesta a 1 sola columna
yy = sim(net,xx(1:5));
xy = [xx(1:5)' yy'];
sol = mapminmax('reverse',xy',PS);
disp('Fallecidos en Lima: ')
fprintf('Lima centro: %f\n',sol(6));
fprintf('Lima norte: %f\n',sol(7));
fprintf('Lima este: %f\n',sol(8));
fprintf('Lima sur: %f\n',sol(9));
% Prediccion
for i = 1:37
v = [i+28 Output(end,:) 0 0 0 0];
xx = mapminmax('apply',v',PS);    %% Se hace la transpuesta a 1 sola columna
yy = sim(net,xx(1:5));
xy = [xx(1:5)' yy'];
sol = mapminmax('reverse',xy',PS);
A = sol(6:9);
A(A <= 0) = 0;
Output(end+1,:) = A;
end
Output = [Input(1,2:5); Output];
M = 1:length(Output);
figure(2)
plot(M',Output)
title('Nacidos en Lima Metropolitana')
xlabel('Meses')
ylabel('Cantidad')
grid on
legend('Centro','Norte','Este','Sur')

```

Anexo 3

TEOREMA (KOLMOGOROV - 1957)

Para cada entero $n \geq 2$ existen $n(2n + 1)$ funciones monótonas crecientes $\psi_{pq}, p = 1, 2, \dots, n$ y $q = 1, 2, \dots, 2n + 1$ con la siguiente propiedad:

Para cada función continua de valor real, $f: I^n \rightarrow \mathbb{R}$ existen funciones continuas $\phi_q, q = 1, 2, \dots, 2n + 1$, tales que

$$f(x_1, x_2, \dots, x_n) = \sum_{q=1}^{2n+1} \phi_q \left[\sum_{p=1}^n \psi_{pq}(x_p) \right]$$

Las funciones ψ_{pq} son universales, esto es, no dependen de f .

Las funciones ϕ_q son continuas, de una sola variable y dependen de f .

En otros términos, Kolmogorov mostró que una función continua de valor real definida en el cubo n -dimensional $I^n, I = [0,1]$, puede representarse como sumas y composiciones de funciones de una sola variable.

Sin embargo, Sprecher (1965) mejoró la representación de Kolmogorov mostrando que las funciones ψ_{pq} pueden ser reemplazadas por funciones de la forma $\lambda^p \psi$, donde λ es una constante y ψ es una función monótona creciente que satisface una condición de Lipschitz $(|f(x) - f(y)| \leq c|x - y|^\alpha, \alpha = \frac{Ln2}{Ln(2n+2)}, c \text{ constante})$.

TEOREMA (HECHT NIELSEN - 1987)

Dada una función continua $f: I^n \rightarrow \mathbb{R}^m$, f puede ser implementada por una red neuronal de tres capas con n unidades en la capa de entrada, $2n + 1$ unidades en la capa oculta, m nodos en la capa de salida.

El valor de salida de los nodos de la capa oculta está dado por:

$$z_k = \sum_{j=1}^n \lambda^k \psi(x_j + ck) + k$$

Donde λ es constante, ψ es una función real monótona creciente, λ y ψ son independientes de f (aunque dependen de n), ε es un número racional, $0 < \varepsilon \leq \delta$, δ es una constante positiva arbitraria y ψ satisface una condición de Lipschitz, $|\psi(x) - \psi(y)| \leq c|x - y|^\alpha, 0 < \alpha \leq 1$.

Los m elementos de la capa de salida tienen la siguiente función de activación o transferencia:

$$y_i = \sum_{k=1}^{2n+1} \psi_i(z_k)$$

Donde las funciones ψ_i , $i = 1, 2, \dots, m$ son reales y continuas y dependen de f y ε .

Sin embargo, Sprecher (1993) consiguió dar una versión más general de su teorema donde la función ψ no depende de n .

Este resultado se traslada de manera natural al teorema de existencia de redes neuronales que representan funciones continuas.

* I^n es llamado cubo n-dimensional, $I = [0,1]$.