

**APLICACIÓN DE REDES NEURONALES PARA LA CLASIFICACIÓN DE
LOS NIVELES DE TENSIÓN ARTERIAL EN PACIENTES DE
OCAÑA – NORTE DE SANTANDER**

**APPLICATION OF NEURAL NETWORKS FOR THE CLASSIFICATION
OF BLOOD PRESSURE LEVELS IN PATIENTS FROM
OCAÑA – NORTH OF SANTANDER**

 **MSc. Karla Yohana Sánchez-Mojica***,  **Ing. Ariel Fernández Gualdron***,
 **Ing. Ericson Suarez Gutierrez***,  **MSc. José Alejandro Neira Díaz***

* **Corporación Universitaria Iberoamericana**, Facultad de Ingeniería,
Software Engineering, Grupo de investigación y Gestión de
conocimiento en Ingeniería y Ciencias básicas. GIGCIC.
Calle 67 # 5 - 27, Bogotá, Colombia.
Tel.: +601 742 65 82
Email: {karla.sanchez; aferna12; esuare13; jose.neira} @ibero.edu.co

Cómo citar: Sánchez Mojica, K. Y., Fernández Gualdron, A., Suarez Gutierrez, E., & Neira Díaz, J. A. (2023). APLICACIÓN DE REDES NEURONALES PARA LA CLASIFICACIÓN DE LOS NIVELES DE TENSIÓN ARTERIAL EN PACIENTES DE OCAÑA – NORTE DE SANTANDER. REVISTA COLOMBIANA DE TECNOLOGÍAS DE AVANZADA (RCTA), 1(41), 36–41. Recuperado a partir de <https://ojs.unipamplona.edu.co/index.php/rcta/article/view/2415>

Derechos de autor 2023 Revista Colombiana de Tecnologías de Avanzada (RCTA).
Esta obra está bajo una licencia internacional [Creative Commons Atribución-NoComercial 4.0](https://creativecommons.org/licenses/by-nc/4.0/).



Resumen: El objetivo de esta investigación es modelar el comportamiento de la tensión arterial teniendo en cuenta dos factores como edad y género en pacientes de la ciudad de Ocaña – Norte de Santander. Para el desarrollo del proyecto se tienen en cuenta las etapas fundamentales del análisis de datos: adecuación de la base de datos, análisis exploratorio, comprobación de modelos de inteligencia artificial con redes neuronales clasificatorias; el carácter de la investigación es exploratoria con un enfoque cuantitativo y diseño no experimental. Se probaron varios modelos de redes neuronales con diferentes números de capas ocultas y cantidad de neuronas; se encontró que el modelo con mayor precisión era con dos capas ocultas de 100 neuronas cada una, lo que lograba una precisión de 87%. En conclusión, se pudo determinar un modelo de redes neuronales que, con las características de género y edad, más tensión diastólica y sistólica, puede clasificar al paciente en los niveles hipotensión, hipertensión, normal, optima, hipertensión sistólica o detectar alguna anomalía.

Palabras clave: Modelo, Neurona, Nivel, Red, Tensión.

Abstract: The objective of this research is to model the behavior of blood pressure taking into account two factors such as age and gender in patients from the city of Ocaña - Norte de Santander. For the development of the project, the fundamental stages of data analysis are taken into account: adaptation of the database, exploratory analysis, verification of artificial intelligence models with classifying neural networks; the nature of the research is exploratory

with a quantitative approach and non-experimental design. Various neural network models with different numbers of hidden layers and number of neurons were tested; it was found that the model with the highest precision was with two hidden layers of 100 neurons each, which achieved an accuracy of 87%. In conclusion, it was possible to determine a model of neural networks that, with the characteristics of gender and age, plus diastolic and systolic pressure, can classify the patient in the levels hypotension, hypertension, normal, optimal, systolic hypertension or detect any abnormality.

Keywords: Model, Neuron, Level, Network, Voltage.

1. INTRODUCCIÓN

El uso de Big Data es fundamental en el desarrollo de una aplicación de redes neuronales. Es innegable su importancia en los avances médicos a través de la recopilación masiva de datos clínicos, lo que permite alimentar la red neuronal con un conjunto diverso de datos. Estos datos ayudan a la red a aprender patrones, tendencias y características que facilitan la identificación de posibles enfermedades (Bukhari et al., 2021). Este proceso se lleva a cabo de manera interdisciplinaria para lograr avances significativos en la medicina, con el objetivo de impactar en la salud y el bienestar de las personas (Sarmiento-Ramos, 2020).

La presión arterial, también conocida como presión sanguínea, es la fuerza que ejerce la sangre contra las paredes de las arterias cuando el corazón la bombea. (Alghamdi et al., 2020) Los factores que pueden influir en la presión arterial incluyen:

- **Edad:** A medida que envejecemos, es más probable que experimentemos un aumento en la presión arterial. Esto se debe a que las arterias se vuelven menos flexibles con el tiempo.
- **Género:** Antes de la menopausia, las mujeres tienden a tener una presión arterial más baja que los hombres. Después de la menopausia, esta diferencia tiende a desaparecer, y las mujeres tienen un mayor riesgo de desarrollar hipertensión.
- **Genética:** Existe evidencia de que la predisposición genética puede influir en la presión arterial. Si tienes antecedentes familiares de hipertensión, podrías tener un mayor riesgo de desarrollarla.
- **Estilo de vida:** Factores como una dieta poco saludable, el consumo excesivo de sal, la falta

de actividad física, el uso de tabaco y el consumo de alcohol pueden aumentar el riesgo de desarrollar hipertensión.

- **Peso corporal:** El exceso de peso y la obesidad están asociados con un mayor riesgo de hipertensión. El tejido graso adicional requiere un mayor flujo sanguíneo, lo que puede ejercer presión sobre las arterias.
- **Niveles de actividad física:** La falta de actividad física puede contribuir al desarrollo de la hipertensión. El ejercicio regular ayuda a fortalecer el corazón y a mejorar la salud de los vasos sanguíneos.
- **Consumo de sal:** Una dieta alta en sodio puede aumentar la retención de líquidos y provocar un aumento en la presión arterial. Se recomienda limitar el consumo de sal a menos de 2.3 gramos al día.
- **Estrés:** El estrés crónico puede afectar la presión arterial. Durante los períodos de estrés, el cuerpo libera hormonas que pueden contraer los vasos sanguíneos y aumentar la presión arterial (Lopez-Martinez et al., 2020; Martinez-Rios et al., 2021).

Es importante tener en cuenta que estos factores pueden variar de una persona a otra y que la presión arterial alta puede ser el resultado de una combinación de ellos.

Las redes neuronales artificiales se han utilizado en numerosos estudios para predecir y analizar la presión arterial. Estas redes pueden aprender patrones y relaciones complejas a partir de conjuntos de datos y utilizar esa información para realizar predicciones o clasificar nuevos datos. (Ávila-Tomás et al., 2021).

En el ámbito médico, las redes neuronales se han empleado para predecir la presión arterial y diagnosticar enfermedades relacionadas con esta,

como la hipertensión. Se pueden usar diferentes tipos de datos para alimentar las redes neuronales, como las características clínicas de los pacientes, los datos de monitoreo ambulatorio de la presión arterial, datos de imágenes o datos genéticos. (Andía et al., 2019)

Además de la predicción de la presión arterial, las redes neuronales también se han utilizado para analizar los factores de riesgo asociados con la hipertensión y para identificar subgrupos de pacientes con perfiles específicos de presión arterial. Esto puede ayudar a los médicos a personalizar tratamientos y mejorar el manejo de la enfermedad.

Las redes neuronales podrían contribuir a realizar mediciones no invasivas en pacientes ingresados en la UCI, ya que requieren atención constante debido a su condición crítica, y el monitoreo de la presión arterial es de vital importancia para la toma de decisiones médicas. (Hill et al., 2021).

2. METODOLOGÍA

Las redes neuronales pueden utilizarse para clasificar los niveles de presión arterial en diferentes categorías. Este enfoque se conoce como clasificación multiclase, donde se asigna una etiqueta a cada nivel de presión arterial. A continuación, se describe el paso a paso de cómo se utilizaron las redes neuronales para clasificar los niveles de presión arterial en cinco categorías: hipotensión, normal, óptima, prehipertensión e hipertensión (Delgado Karina et al., 2019).

- **Recolección de datos:** Se recopilan datos de los pacientes, incluyendo características relevantes como la edad, el género y sus niveles de presión arterial.
- **Preparación de datos:** Los datos recopilados se dividen en conjuntos de entrenamiento, validación y prueba. Además, los datos se normalizan para garantizar que todas las características tengan una escala similar y evitar que una característica domine sobre las demás.
- **Diseño de la red neuronal:** Se elige la arquitectura de la red neuronal. En este caso, se utiliza una red neuronal de tipo feedforward, pero se prueban varios modelos con diferentes capas y cantidades de neuronas para determinar cuál funciona mejor.

- **Entrenamiento de la red neuronal:** Se utiliza el conjunto de entrenamiento para entrenar la red neuronal. Durante este proceso, la red ajusta los pesos y sesgos de sus conexiones para minimizar el error entre las salidas predichas y las salidas reales. Esto se realiza mediante algoritmos de optimización, como el descenso por gradiente.
- **Validación de la red neuronal:** Se emplea el conjunto de validación para evaluar el rendimiento de la red neuronal durante el entrenamiento de cada modelo. Esto ayuda a ajustar los hiperparámetros de la red neuronal y a evitar el sobreajuste.
- **Prueba de la red neuronal:** Una vez que la red neuronal ha sido entrenada y validada, se utiliza el conjunto de prueba para evaluar su rendimiento final. Se evalúa la precisión de la clasificación y se comparan las predicciones de los diferentes modelos con los niveles reales de presión arterial. (Esmalpoor et al., 2020).

La herramienta utilizada para generar los modelos de redes neuronales es Visual Studio Code, empleando el lenguaje de programación Python. Del mismo modo, se realiza un análisis exploratorio con el mismo lenguaje y un análisis ANOVA con R-Studio para estimar las respuestas y analizar los resultados de los modelos.

Los datos utilizados en esta investigación son proporcionados por un prestador de servicios de salud y corresponden a pacientes atendidos en consultas generales durante 6 meses. Contienen dos de los factores que, según los antecedentes, afectan directamente la presión arterial de los individuos; estas variables son la edad y el género, junto con las mediciones de presión sistólica y diastólica.

3. RESULTADOS

Una exploración de los datos revela que la edad promedio de los pacientes registrados es de 65 años, con una ligera mayoría de género femenino. Las presiones promedio son de 123 para la sistólica y 73 para la diastólica. La edad máxima registrada es de 97 años.

Considerando los factores identificados, los antecedentes indican que la edad es uno de los determinantes del comportamiento de la presión arterial. La Figura 1 permite sospechar que los datos reflejan la importancia de este factor. De

manera similar, el género tiende a no afectar el comportamiento de la presión sistólica y diastólica (Figura 2).

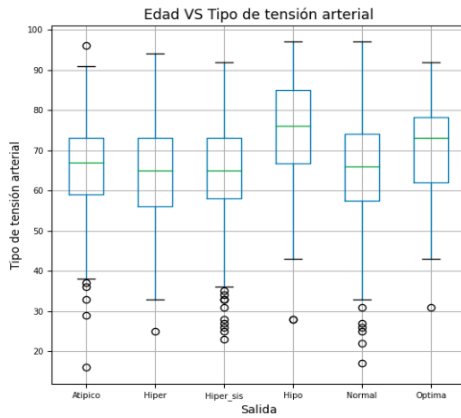




Fig. 1. Gráfica del comportamiento de la edad en relación con el comportamiento de la presión arterial.



(b)

Fig. 2 Gráfica del comportamiento de la presión sistólica y diastólica con respecto al género: (a) femenino y (b) masculino.

En el análisis de correlación, se puede identificar el mismo comportamiento de los factores de edad y género con respecto a la presión arterial:

Tabla 1: Correlación de variables

	Edad	Género	Sistólica	Diastólica
Edd	1	-0.083	0.62	0.54
Género		1	0.043	0.038
Sistólica			1	0.64
Diastólica				1

Fuente: Elaboración propia.

En cuanto al análisis de varianza, este confirma que la edad es un factor que afecta el comportamiento de la presión arterial, mientras que el género no tiene influencia (valor mayor a 0.05) y una posible interacción entre edad y género, siendo esta última no significativa.

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Age	74	201	2.7149	1.314	0.0403 *
Gender	1	0	0.3674	0.178	0.6734
Age: Gender	62	160	2.5734	1.245	0.0971 .
Residuals	1847	3817	2.0669		

Fig. 3. Análisis de varianza para los factores de edad, género e interacción con respecto a la presión arterial.

Se evalúan cuatro modelos con diferentes números de neuronas y capas ocultas para el desarrollo de la red neuronal, como se muestra en la siguiente tabla:






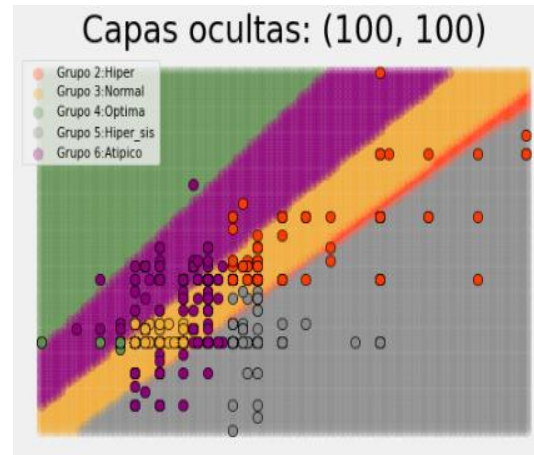

Fig. 4. representación de los datos

Tabla 2: Modelos de clasificación ejecutados

Modelo	Capas ocultas	# de neuronas	Tasa de aprendizaje	Resolutor	Max_iter
M1	1	10	0.01	lbfgs	1000
M2	2	50	0.01	lbfgs	5000
M3	2	100	0.01	lbfgs	5000
M4	3	200	0.01	lbfgs	7000

Fuente: Elaboración propia

Como resultado de los modelos de clasificación, se obtienen los siguientes resultados:

*Fig. 5. Predicciones del modelo propuesto 1.**Fig. 6. Predicciones del modelo propuesto 2.**Fig. 7. Predicciones del modelo propuesto 3.**Fig. 8. Predicciones del modelo propuesto 4.*

Se puede observar que, de los modelos, el que mejor se ajusta al comportamiento de los datos es el modelo 3, con dos capas ocultas y 100 neuronas en cada una; los modelos 1 y 2 tienden a dejar grupos de presión arterial sin clasificar. El modelo 4, con tres capas ocultas y 200 neuronas, no muestra una gran mejora en la clasificación respecto al modelo 3 y consume más recursos para su ejecución, así como un mayor tiempo de clasificación; este último modelo tiene una precisión del 87%.

4. CONCLUSIONES

En conclusión, las redes neuronales aplicadas a la clasificación de los niveles de presión arterial son una herramienta prometedora y efectiva para ayudar en el diagnóstico y monitoreo de la presión arterial. Estas redes neuronales básicas, que son modelos matemáticos inspirados en el funcionamiento del cerebro humano, podrían llegar a ser capaces de procesar grandes cantidades de

datos y extraer patrones complejos, como datos atípicos que se muestran para un monitoreo directo por parte de los médicos, lo que permite respuestas rápidas a los pacientes, convirtiéndolas en una opción viable para abordar la clasificación de los niveles de presión arterial.

Las redes neuronales se entrenan utilizando conjuntos de datos que contienen información sobre los niveles de presión arterial de una variedad de individuos. Estos datos incluyen características como la edad y el género en el caso de estudio. Una vez entrenadas, las redes neuronales son capaces de analizar nuevos conjuntos de datos y clasificar los niveles de presión arterial en categorías como normal, óptima, hipertensión, hipotensión e hipertensión sistólica.

Al utilizar redes neuronales para la clasificación de los niveles de presión arterial, se pueden obtener varios beneficios. En primer lugar, estas redes pueden ayudar a los profesionales de la salud a realizar diagnósticos más rápidos y precisos. Al analizar múltiples características y patrones, las redes neuronales pueden detectar sutilezas que podrían pasar desapercibidas con los métodos tradicionales de clasificación. Esto puede permitir una intervención temprana y un mejor manejo de la presión arterial, lo que a su vez puede reducir el riesgo de enfermedades cardiovasculares y otras complicaciones asociadas.

5. REFERENCIAS

- Alghamdi, A. S., Polat, K., Alghoson, A., Alshdadi, A. A., & Abd El-Latif, A. A. (2020). A novel blood pressure estimation method based on the classification of oscillometric waveforms using machine-learning methods. *Applied Acoustics*, 164. <https://doi.org/10.1016/j.apacoust.2020.107279>
- Andía, M. E., Arrieta, C., & Sing Long, C. A. (2019). A conceptual guide to use and understand Big Data in clinical research. En *Revista Medica Clinica Las Condes* (Vol. 30, Número 1, pp. 83–94). Ediciones Doyma, S.L. <https://doi.org/10.1016/j.rmclc.2018.11.003>
- Ávila-Tomás, J. F., Mayer-Pujadas, M. A., & Quesada-Varela, V. J. (2021). Artificial intelligence and its applications in medicine II: Current importance and practical applications. *Atencion Primaria*, 53(1), 81–88. <https://doi.org/10.1016/j.aprim.2020.04.014>
- Bukhari, M. M., Alkhamees, B. F., Hussain, S., Gumaei, A., Assiri, A., & Ullah, S. S. (2021). An Improved Artificial Neural Network Model for Effective Diabetes Prediction. *Complexity*, 2021. <https://doi.org/10.1155/2021/5525271>
- Delgado Karina, Ledesma Sergio, & Rostro Horacio. (2019). Análisis de electroencefalograma usando redes neuronales artificiales. *Multidisciplinary Science Journal*, 29, 1–24.
- Esmaelpoor, J., Moradi, M. H., & Kadkhodamohammadi, A. (2020). A multistage deep neural network model for blood pressure estimation using photoplethysmogram signals. *Computers in Biology and Medicine*, 120. <https://doi.org/10.1016/j.compbiomed.2020.103719>
- Hill, B. L., Rakocz, N., Rudas, Á., Chiang, J. N., Wang, S., Hofer, I., Cannesson, M., & Halperin, E. (2021). Imputation of the continuous arterial line blood pressure waveform from non-invasive measurements using deep learning. *Scientific Reports*, 11(1). <https://doi.org/10.1038/s41598-021-94913-y>
- López-Martínez, F., Núñez-Valdez, E. R., Crespo, R. G., & García-Díaz, V. (2020). An artificial neural network approach for predicting hypertension using NHANES data. *Scientific Reports*, 10(1). <https://doi.org/10.1038/s41598-020-67640-z>
- Martínez-Ríos, E., Montesinos, L., Alfaro-Ponce, M., & Pecchia, L. (2021). A review of machine learning in hypertension detection and blood pressure estimation based on clinical and physiological data. En *Biomedical Signal Processing and Control* (Vol. 68). Elsevier Ltd. <https://doi.org/10.1016/j.bspc.2021.102813>
- Sarmiento-Ramos, J. L. (2020). Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. *Revista UIS Ingenierías*, 19(4), 1–18. <https://doi.org/10.18273/revuin.v19n4-2020001>