

Selección de los factores influyentes en la predicción de camas hospitalarias en una institución de salud de alto nivel de complejidad, mediante el uso de redes neuronales artificiales

Selection of the influential factors in the prediction of hospital beds in a health institution of high complexity level, through the use of artificial neural networks

Julián Alberto Uribe Gómez¹^{*}, Juan Guillermo Barrientos Gómez²

¹Instituto Tecnológico Metropolitano. Medellín, Colombia

²Universidad Pontificia Bolivariana. Medellín, Colombia

* **Dirigir correspondencia a:** julianuribe@itm.edu.co

RESUMEN

Introducción: En el contexto de cualquier institución hospitalaria, los administradores en salud centran sus esfuerzos en conocer el estado futuro de sus áreas, con el fin de minimizar los riesgos y tomar mejores decisiones. Actualmente, las organizaciones se han centrado en entender y dar valor a los datos generados al interior de sus procesos, mediante el uso de modelos de optimización y herramientas computacionales, con el fin de convertirlos en información valiosa y encontrar soluciones óptimas y competitivas. **Métodos:** Se analizaron 5 indicadores en institución de corte mensual. Estos se recopilaban a través de archivos obtenidos en formato Microsoft EXCEL-2016 desde enero-2004 hasta diciembre-2018, posterior, se modelaron 3 RNA perceptron multicapa con la ayuda del software IBM SPSS versión 19. **Resultados:** Se muestra mediante las RNA que los egresos es la variable más importante para la predicción de las camas hospitalarias, esto con una importancia de 63%, 45% y 51% para cada RNA. De igual manera, el modelo 1 se presenta con el más acertado. Por otro lado, el tiempo promedio de estancia es la variable menos importante para pronosticar. **Conclusiones:** A través de este estudio se logró mostrar que la institución debe dar mayor importancia a factores como son los egresos y el indicador de giro cama. Estos deben ser gestionados de manera constante dentro de la labor administrativa de la institución.

Palabras clave: Perceptron Multicapa; Modelos; Redes Neuronales Artificiales; Camas Hospitalarias

ABSTRACT

Background: In the context of any hospital institution, health administrators focus their efforts on knowing the future state of their areas, in order to minimize risks and make better decisions. Currently, organizations have focused on understanding and giving value to the data generated within their processes, through the use of optimization models and computational tools, in order to convert them into valuable information and find optimal and competitive solutions. **Methods:** 5 indicators were analyzed in a monthly institution. These were collected through files obtained in Microsoft EXCEL-2016 format from January 2004 to December 2018, later, 3 Multilayer Perceptron RNAs were modeled with the help of IBM SPSS version 19 software. **Results:** It is shown by the RNA that demand is the most important variable for the prediction of hospital beds, this with an importance of 63%, 45% and 51% for each RNA. Similarly, model 1 is presented with the most successful. On the other hand, the average length of stay is the least important variable to forecast. **Conclusions:** Through this study it was possible to show that the institution should give greater importance to factors such as demand and the bed spin indicator. These must be constantly managed within the administrative work of the institution.

Keywords: Multilayer Perceptron; Models; Artificial Neural Networks; Hospital Beds.

Proceso editorial

Recibido: 21 03 20

Aceptado: 18 04 20

Publicado: 20 06 20

[DOI 10.17081/innosa.79](https://doi.org/10.17081/innosa.79)

©Copyright 2020

Uribe Gómez¹ et al.



I. INTRODUCCIÓN

Las metodologías en la búsqueda de mejoras en los procesos y servicios hospitalarios, sumado a la importancia de los datos en la creciente economía y sociedad ha sido resumida bajo la siguiente declaración: el “Big Data es el nuevo petróleo” según el director ejecutivo de IBM. Crecientes y recientes estudios han demostrado el impacto y el poder de los datos en la vida moderna (1) y empresarial. A partir de esto muchas herramientas de minería de datos han servido para analizar las bases de datos generadas. Estas técnicas de minería de datos que han sido denominadas de dos maneras: supervisadas y no supervisadas, han servido para análisis predictivo, descriptivo y clasificatorio. Uno de los focos de mayor uso en el análisis descriptivo es la selección de factores de interés, el cual permite identificar variables que tienen mayor influencia sobre algún evento dependiente, en este caso son los factores que influyen en mayor medida sobre el número de camas hospitalarias estimadas en una institución de salud de alta complejidad.

Existen diversas técnicas para realizar un análisis descriptivo para la selección de los factores, entre los que se encuentran los métodos probabilísticos, los evolutivos y las redes neuronales artificiales (de ahora en adelante RNA). La preferencia de las RNA sobre otro tipo de técnicas radica en que ellas constituyen una de las herramientas más poderosas para la clasificación de patrones, planeamiento, predicción, control y optimización (2) debido a sus propiedades de aprendizaje adaptativo no lineal y no paramétrico (3), por otro lado, constituyen un paradigma computacional que provee una gran variedad de modelos matemáticos no lineales, utilizado para estudiar un rango considerable de problemas estadísticos (3), finalmente las RNA no están alejadas de los métodos estadísticos y probabilísticos, de hecho, puede ser consideradas como una técnica de regresión y han sido aplicadas a problemas de tradición estadística (4), los cuales están representados por una alta no linealidad entre el conjunto de variables dependientes e independientes (5).

La justificación para el uso y la preferencia de las RNA como técnica de análisis de datos, radica en sus principios fundamentados en el concepto de neurona y en el cerebro humano, esto significa la modelación de la neurofisiología del cerebro (6), los cuales tienen varias características deseadas por cualquier sistema computacional como por ejemplo el trabajo en paralelo que realizan las neuronas (7), esta razón ha incrementado la investigación y el campo de aplicación sobre el funcionamiento de las RNA. Dichas redes aprenden de su entorno haciendo uso de la información disponible (2), por lo tanto, ellas no son programadas, sino entrenadas, como resultado, ellas pueden entregar buenos resultados en el corto plazo (8), principalmente, los atributos encontrados en este tipo de técnicas son las siguientes: aprendizaje desde la experiencia, generalización desde ejemplos, desarrollo rápido de soluciones, eficiencia computacional y no linealidad.

Las RNA contienen varios tipos de algoritmos de entrenamiento como son: Perceptron multicapa, propagación hacia atrás y hacia adelante, Madaline, Redes de base radial, entre otras. El perceptron multicapa es la RNA más comúnmente utilizada en casos de negocio (3) y en una gran variedad de disciplinas como la contabilidad, las finanzas y la banca, en general, para aspectos como clasificación y predicción. El perceptron multicapa pertenece a las redes neuronales supervisadas (9), esto quiere decir que es necesario proveer al modelo con algunas variables de entrada o independientes y una salida deseada o variable dependiente (10).

Las RNA son técnicas analíticas y matemáticas que han sido inspiradas en las redes neuronales biológicas, su motivación viene de los campos de la inteligencia artificial y la neurociencia, este tipo de integración comenzó en los años 1940 (7). En las RNA, la unidad básica es la neurona o nodo, estas están organizadas por capa de entrada, capas ocultas y capa de salida. Una red neuronal es la red constituida por una simple unidad de procesamiento llamada nodo, cada nodo está vinculado a n-unidades de entrada a través de n-conexiones dirigidas. La representación más simple de las RNA es la red de capa simple. Cada nodo está caracterizado por un valor límite, una función de activación univariable y un vector de pesos (11). Los modelos de redes neuronales aceptan gran cantidad de entradas, sumándolas de manera ponderada. Usualmente se aplican funciones no lineales para generar los resultados (12) y transmitirla a otra neurona, dichos resultados como futuras entradas (13).

Así como las neuronas biológicas, uno de los principales atractivos de las redes neuronales es su posibilidad de aprender y ajustarse a las condiciones de las capas de entrada y salida, por lo tanto, a través de un algoritmo de aprendizaje, las redes neuronales artificiales ajustan su arquitectura y parámetros de manera que permite minimizar la función de error que indique el grado de ajuste de los datos (13). El número de capas o nodos ocultos determina la complejidad del modelo final (3), por lo tanto, mientras mayor número de capas, mayor es el complejidad de la red, a este evento complejo se le conoce como aprendizaje profundo o Deep Learning (14).

Dentro de los modelos de RNA, el perceptron multicapa con algoritmo de retropropagación del error es el modelo más popular para predicción y la selección de factores (15). El modelo generalmente consiste de tres capas (capa de entrada, capa oculta y capa de salida) [5], cada capa tiene una cantidad de neuronas asociadas, es decir, cada unidad en la capa de salida estará conectada con cada unidad en la capa de entrada y cada conexión tendrá un peso sináptico asociado (16), el objetivo de las RNA es minimizar la función de error entre la salida deseada y la del modelo neuronal a partir de un conjunto de observaciones ya clasificadas (13).

La salida de la red neuronal que se encuentra en la capa final, y está asociada a la ecuación 1 presentada, esta debe considerar que cada neurona de la capa oculta y la capa de entrada aportan pesos ponderados y valores que se ajustan en el proceso de aprendizaje de la red, este aprendizaje es el proceso por el cual una RNA modifica sus pesos sinápticos en respuesta al estímulo de entrada (17). Todo proceso de aprendizaje sigue los siguientes pasos (17):.

RNA estimulada.

RNA responde al estímulo.

RNA modifica sus pesos sinápticos para responder al estímulo.

así mismo, la función de activación puede ser mediante tangente hiperbólica es la presentada en la ecuación 2, mediante función sigmoidea presentada en la ecuación 3 o mediante una función identidad (18).

$$y = f(x, w) = w_0 + \sum_{i=1}^n w_i x_i \quad (ec. 1)$$

Donde:

y: son las neuronas de la capa de salida.

x_i : vector de características en la capa de entrada.

w_i : son los pesos sinápticos del proceso de aprendizaje y adaptación.

$$\varphi_v = \frac{e^v - e^{-\alpha v}}{e^v + e^{-\alpha v}} \quad (ec. 2)$$

Donde:

α : Es el parámetro de pendiente de la curva

v: Es la suma ponderada de la neurona

$$\varphi_v = \frac{1}{1 + e^{-v}} \quad (ec. 3)$$

Donde:

v: Es la suma ponderada de la neurona

II. MÉTODOS

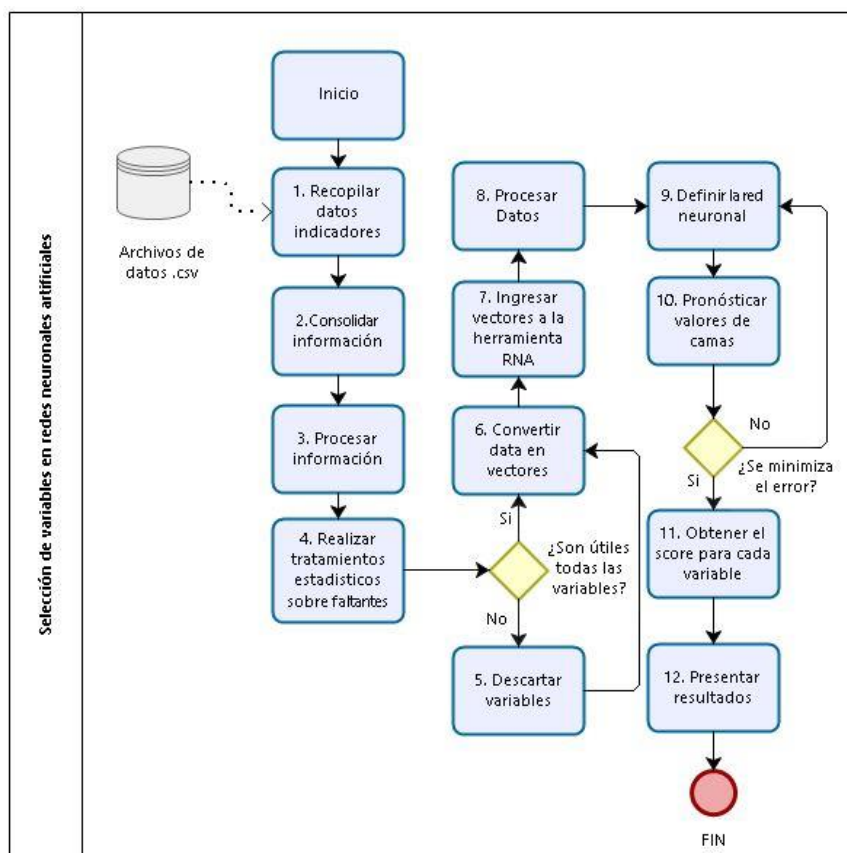
Población, muestra y protocolo de muestreo: Se analizaron 5 indicadores hospitalarios de una institución de alto nivel de complejidad de ámbito regional: Egresos, Indicador de Giro Cama, Porcentaje de ocupación, Tiempo promedio de estancia y Número de camas. Estos indicadores recopilados durante 14 años y 11 meses cada uno con temporalidad mensual, se obtuvieron a través de archivos en formato Microsoft EXCEL 2016 desde el mes de enero 2004 hasta el mes de diciembre 2018. El total de los datos analizados ha sido 895 registros, no se utilizó muestreo probabilístico para el análisis de los datos, por el contrario, se dispuso de todos los datos disponibles para el estudio, esto se debe a que es importante y necesario para realizar predicciones contar con todo el conjunto de datos, esto para mejorar la exactitud y estimación de los resultados.

La metodología utilizada para determinar la relación entre las variables hospitalarias a través de la creación de la RNA se determinó mediante el flujograma presentado en el gráfico 1. Finalmente, el análisis y desarrollo de la RNA se realizó utilizando el software IBM SPSS versión 19.

Las técnicas de análisis utilizadas fueron descriptivas y para la modelación de los datos se utilizaron RNA del tipo perceptron multicapa con algoritmo de retropropagación, red que se entrena con los datos de las variables independientes de entrada que se dispongan.

La metodología implementada se puede observar en detalle en la **Figura 1**.

Figura 1. Metodología de aplicación RNA. Elaboración propia. Adaptado de (19)



Diseño del estudio: De acuerdo a la disponibilidad de datos de los indicadores, solo se contó en el momento de este estudio hasta el mes de diciembre del año 2018. El estudio se realizó a través de las RNA. Las redes neuronales son utilizadas para la predicción de valores, es decir, están clasificadas al igual que los árboles de decisión y redes elásticas Lasso en el conjunto de herramientas de regresión, principalmente, en los métodos de Inteligencia Artificial que tienen que ver con regresión, el conjunto de datos debe ser mayor de 50 datos y menor de 100000 datos, además es necesario utilizarlas para predecir cantidades numéricas.

Análisis estadístico: El software utilizado para la elaboración de las RNA es el IBM SPSS versión 19, el software propuesto cuenta con módulos de optimización y redes neuronales radiales y perceptrón. El propio software en los casos de construcción de redes recomienda, si se da el caso, mediante sus propios algoritmos, normalizar el conjunto de datos que se van a utilizar.

Aspectos éticos: Para el desarrollo de esta investigación, no se utilizó información relativa propia a pacientes o procedimientos o alguna información que ponga en peligro la seguridad o integridad de alguna persona.

III. RESULTADOS

Para la construcción de la red neuronal artificial perceptron multicapa con algoritmo de retropropagación, se van a seleccionar 4 variables independientes: Egresos, Indicador de Giro Cama, Porcentaje de ocupación y Tiempo promedio de estancia y 3 tipos de RNA con diferentes escenarios de arquitectura para probar el modelo. Hanafizadeh et al. (2010) sugieren una división de los datos entre 80% de prueba y 20% de validación, esto es común en la mayoría de los estudios realizados con RNA (20), otros autores como Blanco et al. (2013) sugieren dividir el conjunto en 75% de prueba y 25% de validación (3). En este caso de estudio, la partición del conjunto de datos se hizo aleatoriamente para asegurar que cada elemento de los subconjuntos representa un conjunto completo. Las particiones de los conjuntos de entrenamiento y prueba en las RNA son importantes, ya que una vez la red se ha entrenado con los datos, los pesos sinápticos son ajustados y fijados, lo que significa que la RNA está lista para usar (10). En la **Tabla 1** se pueden ver los parámetros de construcción y la información de inicio para la red.

Tabla 1. Construcción de las redes neuronales

| Información sobre la red neuronal | | | | |
|-----------------------------------|--------------------------------------|----------------------|-----------------|----------------------|
| | | Modelo RNA 1 | Modelo RNA 2 | Modelo RNA 3 |
| Capa de entrada | Variables independientes factores | 4 | 4 | 4 |
| Capas ocultas | Número de capas ocultas | 1 | 1 | 2 |
| | Número de unidades de la capa oculta | 2 | 3 | 4 |
| | Función de activación de la red | Tangente hiperbólica | | |
| Capa de salida | Variables dependientes | 1 | 1 | 1 |
| | Número de unidades | 1 | 1 | 1 |
| | Función de activación | Identidad | Sigmoidea | Tangente hiperbólica |
| | Función de error | Suma cuadrados | | |
| Muestras | Porcentaje de entrenamiento | 70% | | |
| | Porcentaje de prueba | 30% | | |
| Tasa de aprendizaje | | 0.4 | 0.4 | 0.4 |
| Número de iteraciones | | 1000 | 1000 | 1000 |

Fuente: Elaboración propia de los autores

La **Figura 2** presenta los 3 modelos propuestos de redes neuronales artificiales perceptron multicapa, con sus capas de neuronas, en la capa de entrada se tienen las 4 variables independientes, la capa oculta, la cual mediante la función de activación ajusta los pesos en las neuronas. La primera capa de neuronas de la red se propaga a través de las capas superiores hasta generar una salida.

El algoritmo de aprendizaje de la red busca minimizar el error entre la salida de la red actual y el objetivo deseado [6], esto se hace a través de una comparación mediante la función de error, este error se transmite hacia atrás para que cada neurona reciba el error aproximado de participación. Kengpol (2006) indica que cuando hay mayor número de datos en el set de entrenamiento de una red, se puede demostrar que la función de error disminuye, esto confirmaría un correcto desempeño en la red neuronal (21).

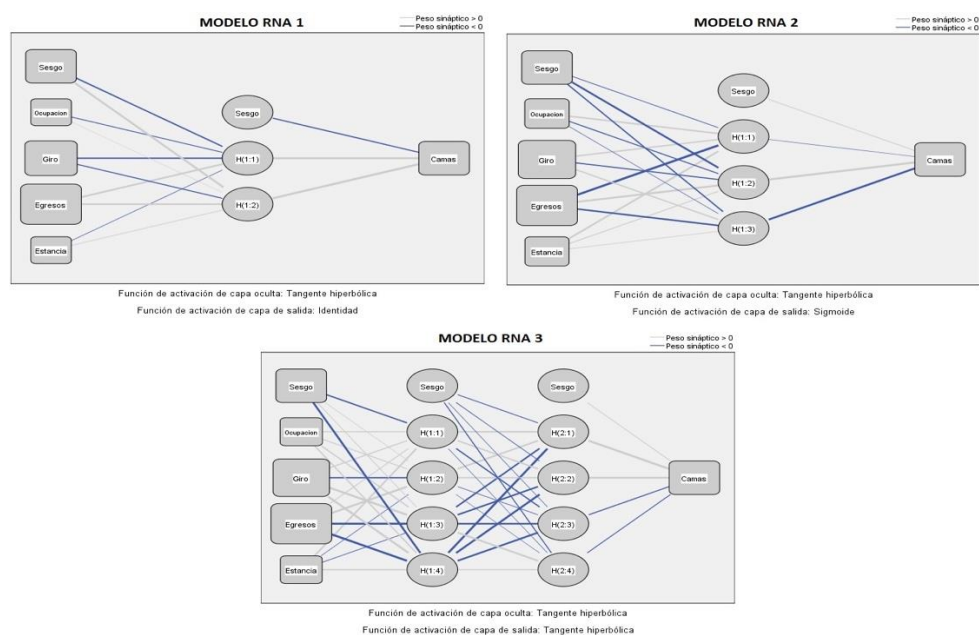
Por lo tanto, la calidad de la predicción de la RNA puede ser medida con la función de error cuadrático medio (MSE) (22), la cual es calculada de la siguiente manera en la ecuación 4.

$$MSE = \frac{\sum_{i=1}^n (\text{Valor de salida}_i - \text{Valor real}_i)^2}{n} \quad (\text{ec. 4})$$

Donde:


n: Es el número de neuronas de salida.

Figura 2. RNA Perceptron multicapa. Elaboración Propia



El modelo creado de RNA, responde a la clasificación de factores e importancia de las variables sobre la influencia de las salidas del modelo. Las variables categorizadas en orden de importancia se ilustran en la **Figura 3**.

Para cada uno de los modelos de RNA, se encuentra que los egresos es la variable con mayor importancia en el modelo, donde para cada red tiene 63%, 45% y 51% de importancia respectivamente. La segunda variable en importancia es el indicador de giro cama, la importancia de este indicador para cada modelo son las siguientes: 37%, 38% y 41%. En tercer lugar, se presenta el porcentaje de ocupación con 0.4%, 9% y 5%, finalmente, el tiempo promedio de estancia es la variable con menor importancia para el modelo con 0.3%, 8% y 3%.

Figura 3. Resultados de clasificación de la red neuronal.

Por otro lado, el cálculo de los errores cuadráticos para cada modelo de RNA según la tabla 2, muestra que el modelo 1 de RNA tiene un indicador de suma de errores cuadráticos menor en comparación con los demás modelos, adicional a esto, en los datos de prueba de la red el indicador arroja una sumatoria mucho mejor que los demás modelos. Teóricamente, mientras más bajo es el MSE, mejores son las predicciones hechas (22).

Tabla 2. Errores cuadráticos calculados.

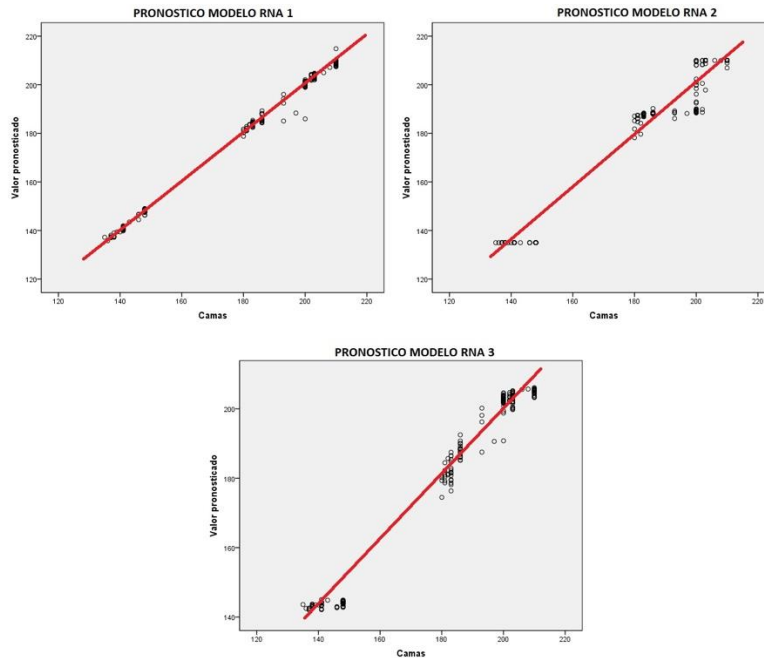
| Resumen modelos | | Modelo RNA 1 | Modelo RNA 2 | Modelo RNA 3 |
|-----------------|-----------------------------|--------------|--------------|--------------|
| Entrenamiento | Suma de errores cuadráticos | 0.406 | 0.498 | 0.649 |
| Prueba | Suma de errores cuadráticos | 0.054 | 0.269 | 0.23 |

Fuente: Elaboración propia.

En la literatura sobre las RNA se ha encontrado que estas tienen ventajas importantes sobre otros métodos de predicción, la ventaja principal radica en la solución de problemas no lineales y su aprendizaje sobre los datos y ajustes sobre los mismos, por otro lado, no se necesitan supuestos sobre las distribuciones de probabilidad, datos faltantes o valores atípicos (23), respecto a lo anteriormente mencionado, se puede decir que respecto a los modelos y la arquitectura propuesta para cada uno de ellos, se puede observar a través de la figura 4 que, empíricamente, los pronósticos del modelo RNA 1 son mucho más ajustados en comparación

con los pronósticos entregados por los demás modelos desarrollados, ya que en el modelo RNA 2 y 3 existen una mayoría de puntos de valores pronosticados por fuera de la línea trazada, lo cual indica que el modelo RNA 1 es una estructura ajustada y confiable para predecir.

Figura 4. Gráficos de pronóstico

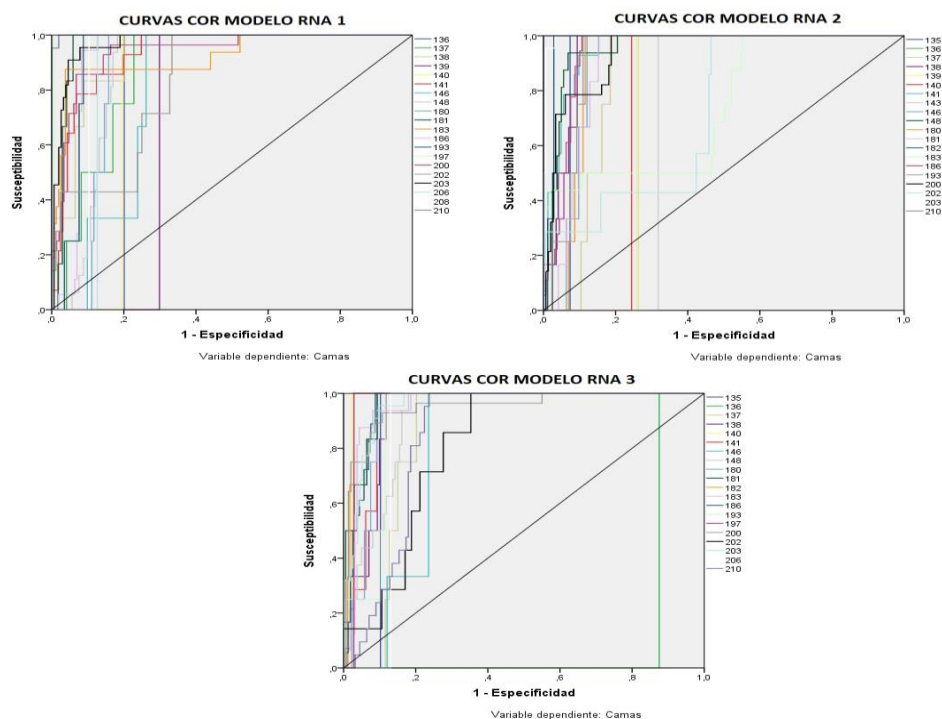


Una forma de validar el uso y la potencia de los modelos de RNA se utilizan las curvas de operación características del receptor (Receiver-Operating Characteristic), los cuales son indicadores de precisión en la prueba dentro del perceptron multicapa y demás herramientas de optimización, clasificación y predicción. Las curvas COR es un método muy popular para entender visualmente el desempeño de la red (24), por otro lado, proporcionan un buen índice de la capacidad de prueba y selección umbrales de decisión. Las curvas COR fueron desarrolladas en el contexto de detección de señales electrónicas en los años 1950 y se extendieron a campos como la psicología, medicina, psicofísica experimental (25), radiología, estadística, bioinformática, aprendizaje de máquina y reconocimiento de patrones (24).

Dentro de las ventajas que tiene el uso de las curvas COR se encuentra la representación simple y comprensible de fenómenos y proporciona una comparación visual entre las múltiples opciones sobre una escala común, sin embargo, la prueba no presenta el número de sujetos ni la medida del tamaño de la muestra, por otro lado, como dificultades en la obtención de las curvas COR debe precisarse que estas deben obtenerse mediante programas de computación, los cuales no siempre están disponibles (25).

Las curvas COR se interpretan mediante su área bajo la curva, esta área siempre debe ser mayor o igual a 0,5, de este modo desde el valor 0,75 hasta 1 indican pruebas desde buenas a excelentes. Para cada variable en la capa de salida del valor percibido se pueden ver sus áreas bajo la curva y valores característicos para indicar cuales fueron las salidas más acertadas del perceptron multicapa, sus valores pueden observarse en la **Figura 5**.

Figura 5. Curvas COR para cada modelo de red.



Los valores conseguidos a través de la evaluación del algoritmo de aprendizaje de la RNA y los valores del área bajo las curvas COR se pueden representar en la **Tabla 3**. En este caso, los valores de salida están marcados en gris, indicando que ha sido el valor más ajustado según la curva COR. En este caso para los tres modelos hay valores sobre el número de camas requeridas que comparten los modelos, en este caso valores de 210, 203, 197, 182 y 181, son valores típicos con buenas curvas de validación.

IV. DISCUSIÓN

Los modelos de RNA propuestos resultan pertinentes para explicar los factores que determinan el número de camas hospitalarias en una institución de alta complejidad. A través de este estudio se logró mostrar que la institución de salud debe dar mayor importancia a factores como son la cantidad de egresos y el indicador de giro cama. Estos factores deben ser gestionados de manera constante dentro de la labor administrativa de la institución.

El número de camas hospitalarias y sus resultados explicados en las curvas COR indican que es importante indicar que existe una confianza mucho mayor en algunas cantidades precisas de camas como por ejemplo 210 y 203 camas. La gestión sobre las variables de la capa de entrada, y datos completos para análisis, generaran mayor confianza en el uso y en el aprendizaje de la red.

Tabla 3. Áreas bajo la curva COR para cada RNA

| Área debajo de la curva | | | | | | | | |
|-------------------------|-----|------|--------------------|-----|-------|--------------------|-----|------|
| Curva COR Modelo 1 | | | Curva COR Modelo 2 | | | Curva COR Modelo 3 | | |
| Camas | 136 | ,799 | Camas | 135 | ,926 | Camas | 135 | ,898 |
| | 137 | ,870 | | 136 | ,739 | | 136 | ,125 |
| | 138 | ,928 | | 137 | ,857 | | 137 | ,851 |
| | 139 | ,701 | | 138 | ,944 | | 138 | ,933 |
| | 140 | ,805 | | 139 | ,739 | | 140 | ,977 |
| | 141 | ,932 | | 140 | ,756 | | 141 | ,938 |
| | 146 | ,800 | | 141 | ,956 | | 146 | ,803 |
| | 148 | ,873 | | 143 | ,682 | | 148 | ,910 |
| | 180 | ,867 | | 146 | ,906 | | 180 | ,938 |
| | 181 | ,965 | | 148 | ,952 | | 181 | ,967 |
| | 183 | ,922 | | 180 | ,905 | | 182 | ,981 |
| | 186 | ,924 | | 181 | ,905 | | 183 | ,956 |
| | 193 | ,931 | | 182 | ,977 | | 186 | ,958 |
| | 197 | ,994 | | 183 | ,739 | | 193 | ,915 |
| | 200 | ,940 | | 186 | ,942 | | 197 | ,972 |
| | 202 | ,831 | | 193 | ,925 | | 200 | ,950 |
| | 203 | ,971 | | 200 | ,941 | | 202 | ,813 |
| | 206 | ,874 | | 202 | ,718 | | 203 | ,960 |
| | 208 | ,897 | | 203 | ,996 | | 206 | ,869 |
| | 210 | ,999 | | 210 | 1,000 | | 210 | ,850 |

Fuente: Elaboración propia.

Sobre la herramienta utilizada es importante aclarar que, dentro del método de aplicación de las redes neuronales, existen desventajas y es el hecho que no hay un procedimiento único conocido que garantice que las soluciones globales encontradas, logren para el problema, encontrar una configuración de pesos sinápticos que minimice el criterio de error, por lo tanto, uno de los múltiples mínimos locales posibles es obtenido a través de una de las muchas reglas propuestas en la literatura. Por otro lado, como bien se ha explicado las redes neuronales artificiales son una simplificación del proceso biológico y el modelo creado no captura la dinámica ni las propiedades espacio temporales, las cuales son importantes en el proceso biológico. No obstante, como ya se ha mencionado las redes neuronales artificiales pueden aproximar con exactitud diversos tipos de relaciones complejas (13), pero con sus claras limitantes.

En la literatura consultada se ha encontrado que otras de las desventajas evidentes en el uso de la metodología propuesta tiene que ver con la subjetividad en la selección de las capas ocultas, numero de neuronas y demás ítems de especial importancia en la arquitectura de la red. En muchos casos de implementación de las RNA se debe contar con usuarios experimentados para su aplicación y uso.

Contribución de los autores: "Conceptualización, Uribe J y Barrientos J; metodología, Uribe J; software, Uribe J; validación, Uribe J y Barrientos J; análisis formal, Uribe J; investigación, Uribe J y Barrientos J; recursos, No aplica; curación de datos, Uribe J; escritura: preparación del borrador original, Uribe J; escritura: revisión y edición, Uribe J; visualización, Uribe J; supervisión, Barrientos J; administración del proyecto, Uribe J y Barrientos J; adquisición de fondos, No aplica Todos los autores han leído y aceptado la versión publicada del manuscrito.

Conflictos de intereses: Los autores declaran no tener ningún conflicto de intereses.

REFERENCIAS

1. Iqbal R, Doctor F, More B , Mahmud S, Yousuf U. Big data analytics: Computational intelligence techniques and application areas. *Technol. Forecast. Soc. Change*, no. December 2017, pp. 0–1, 2018. DOI: [10.1016/j.techfore.2018.03.024](https://doi.org/10.1016/j.techfore.2018.03.024)
2. Mejía D, Toro E. Pronóstico de ventas usando redes neuronales. *Sci. Tech.*, vol. 10, no. 26, pp. 25–30, 2004. DOI: [10.22517/23447214.7047](https://doi.org/10.22517/23447214.7047)
3. Blanco A, Pino-Mejías R, Lara J, Rayo S. Credit scoring models for the microfinance industry using neural networks: Evidence from Peru. *Expert Syst. Appl.*, vol. 40, no. 1, pp. 356–364, 2013. DOI: [10.1016/j.eswa.2012.07.051](https://doi.org/10.1016/j.eswa.2012.07.051)
4. Pitarque A, Ruiz J, Roy J. Las redes neuronales como herramientas estadísticas no paramétricas de clasificación. *Psicothema*, vol. 12, no. SUPPL. 2, pp. 459–463, 2000. Disponible en: <http://www.psicothema.com/pdf/604.pdf>
5. Geem Z , Roper W. Energy demand estimation of South Korea using artificial neural network. *Energy Policy*, vol. 37, no. 10, pp. 4049–4054, 2009. DOI: [10.1016/j.enpol.2009.04.049](https://doi.org/10.1016/j.enpol.2009.04.049)
6. Xiang X, Deng Y. Second order spiking perceptron and its applications. *Appl. Math. Model.*, vol. 34, no. 10, pp. 2966–2980, 2010. DOI: [10.1016/j.apm.2010.01.006](https://doi.org/10.1016/j.apm.2010.01.006)
7. Lacson R, Ohno-Machado L. Artificial Neural Networks in Encyclopedia of Medical Decision Making M. W. Kattan, Ed. 2455 Teller Road, Thousand Oaks California 91320 United States: SAGE Publications, Inc., 2009, p. 9
8. Kigami J. *Mathematical Background*. 2001, pp. 196–211.
9. Bansal D, Chhikara R, Khanna K, Gupta P. Comparative Analysis of Various Machine Learning Algorithms for Detecting Dementia. *Procedia Comput. Sci.*, vol. 132, pp. 1497–1502, 2018. DOI: [10.1016/j.procs.2018.05.102](https://doi.org/10.1016/j.procs.2018.05.102)
10. Serrano-Cinca C. Self organizing neural networks for financial diagnosis. *Decis. Support Syst.*, vol. 17, no. 3, pp. 227–238, 1996. DOI: [10.1016/0167-9236\(95\)00033-X](https://doi.org/10.1016/0167-9236(95)00033-X)
11. Leshno M, Y. Spector Y. Neural network prediction analysis: The bankruptcy case. *Neurocomputing*, vol. 10, no. 2, pp. 125–147, 1996. DOI: [10.1016/0925-2312\(94\)00060-3](https://doi.org/10.1016/0925-2312(94)00060-3)
12. Kuzey C, Uyar A, Delen D. The impact of multinationality on firm value: A comparative analysis of machine learning techniques. *Decis. Support Syst.*, vol. 59, no. 1, pp. 127–142, 2014. DOI: [10.1016/j.dss.2013.11.001](https://doi.org/10.1016/j.dss.2013.11.001)
13. Lao O, Caridad M. Procedimiento para el pronóstico de la demanda mediante redes neuronales artificiales. *Ciencias Holguín*, vol. 23, no. 1, pp. 1–18, 2017. Disponible en: <http://www.ciencias.holguin.cu/index.php/cienciasholguin/article/view/995/1097>
14. Rajendra P, Manash E. Deep learning: A branch of machine learning. *J. Phys. Conf. Ser.*, vol. 1228, no. 1, 2019. Disponible en: <https://iopscience.iop.org/article/10.1088/1742-6596/1228/1/012045/meta>
15. Hamadache M, Benkortbi O, Hanini S, Amrane A. Application of multilayer perceptron for prediction of the rat acute toxicity of insecticides. *Energy Procedia*, vol. 139, pp. 37–42, 2017. DOI: [10.1016/j.egypro.2017.11.169](https://doi.org/10.1016/j.egypro.2017.11.169)

- 16.** Baum E. On the capabilities of multilayer perceptrons. *J. Complex.*, vol. 4, no. 3, pp. 193–215, 1988. DOI: [10.1016/0885-064X\(88\)90020-9](https://doi.org/10.1016/0885-064X(88)90020-9)
- 17.** Gómez O, Garcés L. Inferencia estadística utilizando redes neuronales artificiales. *Sci. Tech.*, vol. 5, no. 26, pp. 31–36, 2004. Disponible en: <https://revistas.utp.edu.co/index.php/revistaciencia/article/view/7049>
- 18.** Arroyo I. Evaluación de dos técnicas de reconocimiento de patrones para su implementación en el simulador de pilotaje automático de taller del STC metro de la ciudad de México. Universidad tecnológica de la Mixteca, 2013. Disponible en: https://www.academia.edu/16113248/Evaluaci%C3%B3n_de_dos_t%C3%A9cnicas_de_reconocimiento_de_patrones_para_su_implementaci%C3%B3n_en_el_Simulador_de_pilotaje_autom%C3%A1tico_de_taller_del_STC_Metro_de_la_Cd._de_M%C3%A9xico
- 19.** Cabaneros S, Calautit J, Hughes B. Hybrid Artificial Neural Network Models for Effective Prediction and Mitigation of Urban Roadside NO₂ Pollution. *Energy Procedia*, vol. 142, pp. 3524–3530, 2017. DOI: [10.1016/j.egypro.2017.12.240](https://doi.org/10.1016/j.egypro.2017.12.240)
- 20.** Hanafizadeh P, Ravasan A, Khaki H. An expert system for perfume selection using artificial neural network. *Expert Syst. Appl.*, vol. 37, no. 12, pp. 8879–8887, 2010. DOI: [10.1016/j.eswa.2010.06.008](https://doi.org/10.1016/j.eswa.2010.06.008)
- 21.** Kengpol A, Wangananon W. The expert system for assessing customer satisfaction on fragrance notes: Using artificial neural networks. *Comput. Ind. Eng.*, vol. 51, no. 4, pp. 567–584, 2006. DOI: [10.1016/j.cie.2006.04.006](https://doi.org/10.1016/j.cie.2006.04.006)
- 22.** Michalak K, Kwaśnicka H. Influence of data dimensionality on the quality of forecasts given by a multilayer perceptron. *Theor. Comput. Sci.*, vol. 371, no. 1–2, pp. 62–71, 2007. DOI: [10.1016/j.tcs.2006.10.014](https://doi.org/10.1016/j.tcs.2006.10.014)
- 23.** Galeshchuk S. Neural networks performance in exchange rate prediction. *Neurocomputing*, vol. 172, pp. 446–452, 2016. DOI: [10.1016/j.neucom.2015.03.100](https://doi.org/10.1016/j.neucom.2015.03.100)
- 24.** Hernández-Orallo J. ROC curves for regression. *Pattern Recognit.*, vol. 46, no. 12, pp. 3395–3411, 2013. DOI: [10.1016/j.patcog.2013.06.014](https://doi.org/10.1016/j.patcog.2013.06.014)
- 25.** Dominguez E, Gonzalez R. Análisis de las curvas Receiver Operating Characteristic: un método útil para evaluar procedimientos diagnósticos. 2002. Disponible en: http://scielo.sld.cu/scielo.php?script=sci_abstract&pid=S1561-29532002000200010&lng=es&nrm=iso&tlng=es