

Redes neuronales artificiales: una medición de aprendizajes de pronósticos como demanda potencial

Willy Alex Castañeda Sánchez
<https://orcid.org/0000-0002-4421-4778>
wcastaneda@ucv.edu.pe
Universidad César Vallejo
Trujillo, Perú

Benjamín Roldan Polo Escobar
<https://orcid.org/0000-0001-5056-9957>
Benjamin.polo@untrm.edu.pe
Universidad Toribio Rodríguez de Mendoza
Amazonas, Perú

Fernando Vega Huincho
<https://orcid.org/0000-0003-0320-5258>
fvegah@ucv.edu.pe
Universidad César Vallejo
Trujillo, Perú

Recibido (30/06/2022), Aceptado (11/12/2022)

Resumen: Las redes neuronales en la actualidad se han constituido una herramienta tecnológica muy importante debido a su contribución en el desarrollo de problemas relacionados con los aprendizajes de pronósticos en la planificación de la producción para cumplir la demanda potencial. El objetivo de la investigación consiste en aplicar las redes neuronales artificiales para medir el aprendizaje profundo en pronósticos. El estudio es cuantitativo de diseño preexperimental. Se aplicó una prueba con pres test y pos test sobre lenguaje de programación Visual Net de red neuronal para cada tipo de aprendizaje programado. Los resultados basados en los promedios respecto al aprendizaje conceptual de pronóstico y el método de red neuronal fueron sustanciales, mientras con el aprendizaje automático y profundo contribuyeron al desarrollo del problema, en cuanto al aprendizaje profundo de las conductas de los alumnos es importante y los resultados de la aplicación de pronósticos ayudaron a los cambios de la red neuronal en adquirir la capacidad de aprender funciones más complejas. Concluyendo que las redes neuronales artificiales en el aprendizaje profundo de pronóstico mejoran sustancialmente los aprendizajes en conceptos, procedimientos y conductas las cuales con llevan a la empresa a minimizar los costos e incrementar utilidades por diversos conceptos.

Palabras clave: Redes neuronales artificiales, aprendizaje de pronósticos, planificación, producción.

Artificial neural networks: a measurement of forecast learnings as potential demand

Abstract.- Neural networks today have become an essential technological tool due to their contribution to developing problems related to forecasting learning in production planning to meet potential demand. The research aims to apply artificial neural networks to measure a deep understanding of forecasts. The study is quantitative with a pre-experimental design. A test with pre-test and post-test was used for the Visual Net neural network programming language for each type of programmed learning. The results based on the averages regarding the predictive conceptual understanding and the neural network method were substantial. In contrast, automatic and deep learning contributed to the development of the problem. In terms of a deep understanding of the student's behaviors is essential. The results of the application of forecasts helped the changes of the neural network in acquiring the ability to learn more complex functions and concluding that artificial neural networks in deep forecasting learning substantially improve learning in concepts, procedures, and behaviors which leads the company to minimize costs and increase profits for various ideas.

Keywords: Artificial neural networks, forecast learning, planning, production.



I. INTRODUCCIÓN

Los aprendizajes de pronósticos son fundamentales en la planificación de la producción porque una de sus finalidades es cumplir la demanda potencial. Al final de cada año las empresas planifican para la producción de los próximos años. Para ello se requiere saber la cantidad de productos a producir, y las empresas realizan modelos de pronósticos, para ello se aplicaron las redes neuronales como máquina de aprendizaje. Estos modelos imitan el aprendizaje tal como lo hacen las neuronas biológicas humanas estructuralmente se componen de capas de nodos interconectados, el modelo de red neuronal admite todos los casos de una realidad de proceso de aprendizaje en el mundo real. Una red neuronal está en la capacidad de aprender de los datos, de manera que se puede entrenar para que reconozca patrones, clasifique datos y pronostique eventos futuros [1].

En este sentido, son los estudiantes de ingeniería que deben aprender los aspectos conceptuales, procedimentales, actitudinales en modelos de pronósticos en un nivel profundo para aplicarlo en actividades empresariales, para minimizar los costos e incrementar las utilidades por diversos conceptos de costos y de ingresos. Hoy en día se ve reflejado la deficiencia de los estudiantes en aplicar los métodos de pronósticos, si eso continua la empresa corre riesgo de perder posición en el mercado.

En el caso de los mercados se perciben varias herramientas para el modelamiento de Redes Neuronales artificiales, para ello se realiza un programa de Lenguaje de Algoritmos NeuroSchese que nos ayuda en la capacidad expresiva, elegancia y claridad. Respecto a redes neuronales artificiales nos proporcionan un proceso de aprendizaje que nos permite crear una red neuronal y su entrenamiento antes y después de una fase en relación a una cantidad de labores [2].

Las empresas hoy en día buscan formas de ver reflejado el incremento de sus costos e ingresos para incrementar sus utilidades. Un manejo eficiente de la información permite hacer predicciones acertadas de acuerdo a la época del año y manejar niveles de inventarios adecuados con el menor porcentaje de error en la empresa y no pierda posición en el mercado hasta desaparecer [3]. Por ejemplo al final de cada año, en los meses de noviembre o diciembre, las empresas planifican la producción del próximo año, para llevarla a cabo lo que se requiere saber la cantidad de productos a producir, y para que la empresa sepa eso, debe hacer uso de los modelos de pronósticos, siendo uno de los más utilizados, el modelo de Regresión Lineal o Análisis de Regresión Lineal, pero ahora gracias a las Redes Neuronales Artificiales como máquina de aprendizaje y de automatización se podrá mejorar el aprendizaje de los alumnos para que las empresas tengan una planificación de la producción.

Por otro lado, la comunidad comprometida necesita obtener los productos en tiempo real y productos de calidad, si las empresas actúan bajo un plan de pronósticos sucede lo contrario, es decir sus costos se incrementarían y se tendrían ingresos altos y las empresas no correrían riesgo en el mercado. Para ello es importante desarrollar en los estudiantes capacidades que ayuden medir el aprendizaje profundo de pronósticos en los problemas empresariales específicamente en la planificación de la producción para aplicarlos con mayor efectividad en las realidades de las empresas. En ese sentido, el objetivo que se plantea en la presente investigación es aplicar las redes neuronales artificiales para medir el aprendizaje profundo de pronósticos. Investigación que se aplica con eficiencia y eficacia en los cálculos de pronósticos en los problemas empresariales, especialmente en la planificación de la producción a través de la estrategia de las redes neuronales como máquina de aprendizaje.

II. DESARROLLO

Una caracterización importante de las redes neuronales es simular o imitar el proceso de aprendizaje del cerebro humano. Proceso que utilizan algoritmos o programas informáticos con el propósito de aprender. La neurona biológica actúa como un sistema de proceso de señales, aprende por medio de procesos sinápticos, la cual consiste en conectar dos o más neuronas en donde la información es analizada y procesada por procesos electroquímicos, el axón tiene la función de transmitir data e información a las neuronas con las cuales se conectan, proceso que es denominado sinapsis. La información se da una neurona a otra se denomina salida, y toda la información procesada en una neurona se denomina capa [4].

En las redes neuronales, el aprendizaje es ponderado, los pesos son sumados con la finalidad de proporcionar o generar una activación de nodo, la cuales denominada unidad lógica de umbral. La salida es relativa, las capas de neuronas entregan información de una capa a otra, la eficiencia del aprendizaje generalmente disminuye a medida en que se profundiza el aprendizaje [5]. En la actualidad, las redes neuronales se han constituido como una herramienta tecnológica muy importante debido a que son agentes inteligentes que contribuyen en el desarrollo de problemas relacionados con el aprendizaje automático y aprendizaje profundo, esto se debe a la capacidad de resolver problemas matemáticos complejos, problemas de ingeniería de alta complejidad en todos los ámbitos [4].

Las redes artificiales imitan a las redes neuronales biológicas, es decir las redes artificiales deben reproducir los componentes primarios de las redes neuronales biológicas. Existen dos aproximaciones que se utilizan en la construcción de las redes artificiales, las que usan chips experimentales que simulan a las neuronas para formar las redes, mientras la segunda se crea las redes mediante software, esto permite desarrollarlas más fácil que mediante la utilización de las computadoras. En la figura 1 se muestra la equivalencia entre los componentes neuronas biológicas y las neuronas artificiales [6].

A. Neurona artificial.

Como proceso la neurona artificial cumple la función de activación, reporta una salida la misma que es creada por la neurona como resultado del procesamiento de las entradas. La función de activación está presente en cada una de las capas de las redes neuronales artificiales.

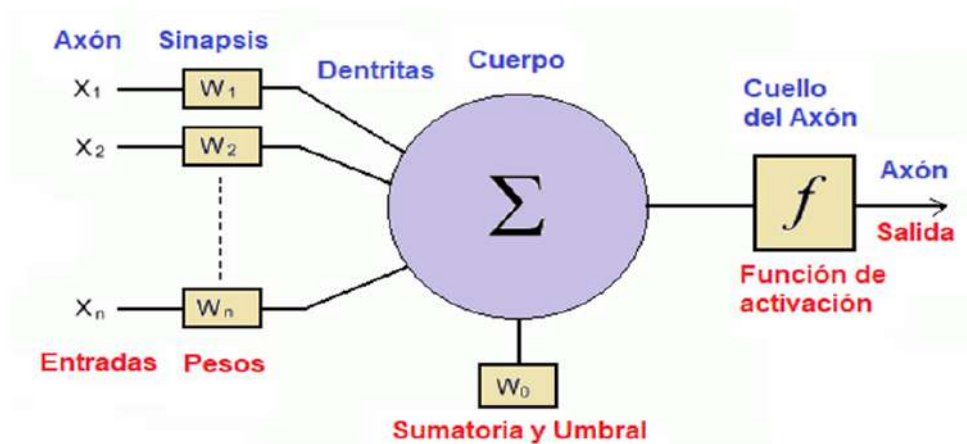


Fig. 1. Estructura básica de una Neurona Artificial y similitud con la neurona biológica [6].

B. Funciones de activación más utilizadas.

Identidad: es una de las funciones de activación más simples, siempre devuelve como salida su valor de entrada. Su rango es $(-\infty+\infty)$, y es una función monótona.

$$f(x) = x \tag{1}$$

Escalón binario: es una de las funciones más usadas en las redes neuronales binarias debido a que no es lineal y es bastante sencilla. La red neuronal de Hopfield utiliza esta función. Cuenta con un rango $(0,1)$, y generalmente es monótona.

$$f(x) = \begin{cases} 0 & x < 0 \\ 1 & x \geq 0 \end{cases} \tag{2}$$

Función Sigmoide: de acuerdo con la literatura científica, es una de las funciones más usadas como activación de las redes neuronales. En la figura 2 se observa el rango continuo en los valores $(0,1)$, es monótona e infinitamente diferenciable.

$$\sigma(x) = \frac{1}{1+e^{-x}} \tag{3}$$




Fig. 2. Función Sigmoide

Tangente hiperbólica: esta función es utilizada por redes neuronales con salidas continuas. Su aplicación más común se da en el Perceptrón multicapa con retro propagación, debido a que su algoritmo de aprendizaje requiere de una función derivable, es monótona, y se aproxima a la función identidad en su origen tal como se observa en la figura 3.

$$f(x) = \text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \tag{4}$$

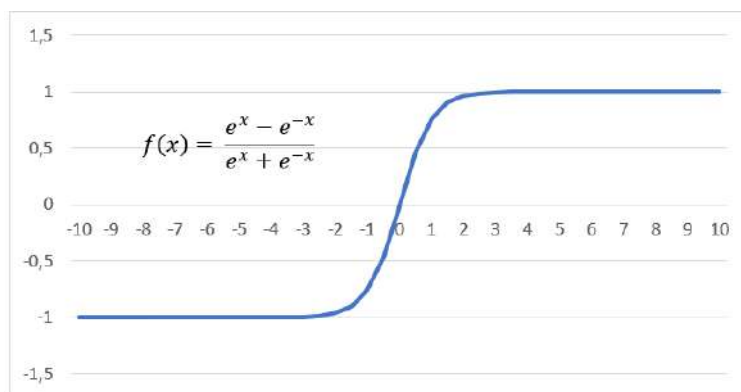


Fig. 3. Función Hiperbólica

Función Rectificadora: esta función de activación generalmente se usa en redes convolucionales, se fundamenta en la teoría de las probabilidades, es más versátil que la función de activación tangente hiperbólica. Es una de las funciones de activación que más se están aplicando a investigaciones con Deep Learning.

$$f(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} \quad (5)$$

Función suavizada: esta función activadora es una aproximación suavizada de la función de activación rectificadora.

$$f(x) = \ln(1 + e^x) \quad (6)$$

C. Tipos de aprendizaje en redes neuronales.

Aprendizaje supervisado, en este tipo de aprendizaje se tiene un grupo de datos inicialmente calificado, a esos datos se denominan a priori y se le relaciona como si fuera un maestro, y estos datos supervisan el aprendizaje, las neuronas aprenden funciones o relaciones que establecen relación de asociación de las entradas con salidas. En este tipo de red neuronal artificial, se presenta una entrada en el nivel de capa de entrada junto con una respuesta deseada para la capa de salida, el proceso de aprendizaje se fundamenta en la comparación entre los datos de salida que calcula la red y la respuesta que se desea, se puede generar un error, el error es utilizado en el cambio de los parámetros de la red (pesos) de modo que resulte un mejor rendimiento [7]. Ahora bien, la clasificación en este subtipo, los datos pueden pertenecer a dos o más clases, se busca aprender como clasificar nuevas entradas en esas clases a partir de datos que ya se conoce. En el aprendizaje no supervisado, se utiliza un conjunto de datos sin clasificar, las neuronas buscan incrementar el conocimiento estructural de los datos disponibles, así como de los probables datos futuros que deriven del mismo fenómeno. En el aprendizaje no supervisado no existe un conocimiento a priori. Así pues, la topología de una red neurona indica el espacio o posición que ocupa una neurona dentro de la red, las neuronas se asocian formando capas, que pueden diferentes características. De acuerdo a la topología de las redes neuronales, existen tres tipos de neuronas artificiales como sostiene [8].

D. Tipos de neuronas artificiales.

Neuronas de entrada: Reciben señales (datos o información) desde el entorno; estas entradas provienen generalmente de otros espacios del sistema como información de almacenamiento de patrones de aprendizaje.

Neuronas de salida: Envían señales (resultados de aprendizaje o datos) en forma externa del sistema una vez terminado el tratamiento de la información es decir la salida de la red.

Neuronas ocultas: Reciben estímulos y generan salidas dentro del sistema, no mantienen ningún tipo de contacto con el exterior. Las neuronas ocultas incorporan información y establecen la representación interna de ésta [9].

Ahora bien, el aprendizaje profundo hace referencia a la formación de redes neuronales con más de dos capas ocultas. Deep Learning, en español aprendizaje profundo es una Sub área en los temas de máquina de aprendizaje o también conocido como Machine Learning, la misma que usa varias estructuras de redes neuronales con la finalidad de alcanzar el aprendizaje de capas continuas o sucesivas. Se refiere a la cantidad de capas de representaciones que se usan en el modelo; comúnmente se acostumbra a utilizar decenas o cientos de capas de representación, estas capas aprenden de manera automática siempre en cuando el modelo es entrenado con los datos [10].

El aprendizaje por representación implica varios métodos que ayudan a un conjunto de redes neuronales en la recepción de la data o información sin haber sido procesado y descubrir de manera automática las representaciones que se requieren para la identificación o clasificación. Los procesos propios de aprendizaje profundo son técnicas y metodologías de aprendizaje de representación con varios niveles de representación, logrados con la ayuda de la composición de módulos simples no lineales que cambian la representación en un nivel superior y sutilmente más abstracto, con la estructuración de varios cambios la red neuronal adquiere la capacidad de aprender funciones muy complejas. En los procesos de clasificación, las capas superiores de representación amplifican las entradas de mayor importancia con fines de selección y eliminan las variaciones irrelevantes [11].

Actualmente, el aprendizaje profundo está obteniendo adelantos muy importantes en los procesos de dar solución a problemas complejos que han resistido las mejores tentativas de solución por parte de la comunidad de inteligencia artificial durante muchos años, el aprendizaje profundo ha demostrado su potencialidad en la solución compleja de varias ramas del saber humano. Se orienta en el conocimiento en la profundidad de la comprensión de los alumnos al leer o estudiar un texto y entender las diferencias individuales evidenciadas por los alumnos en su proceso de aprendizaje de las informaciones, los cuales establecen la orientación de la tarea, la comunidad científica ha establecido los términos Enfoque Profundo y Enfoque Superficial del Aprendizaje para hacer referencia a dos formas que seleccionan los estudiantes durante el proceso de la información. El término superficial hace referencia al procesamiento encaminado al texto mismo, mostrando una concepción reproductiva del aprendizaje. El término profundo hace referencia a los estudiantes centrados en la comprensión del texto, demostrando mayor interés por el contenido, mensaje o significado [12].

De esta manera, los enfoques superficiales y profundo son dos formas de relacionarse, en ese sentido, el sujeto que aprende con un entorno de enseñanza y aprendizaje, pero no son características fijas de éstos, son respuestas de naturaleza racional a sus ambientes educativos: en este caso, se evalúan los grados de complejidad en las salidas o resultados del aprendizaje en función a los propuestos [13]. Una neurona artificial se enfoca como la aplicación y suma de pesos sinápticos seguida de una transformación no lineal (denominada función de activación). Al instalar neuronas artificiales como elementos computacionales de una arquitectura profunda se obtiene redes neuronales artificiales de varias capas o también conocidas como redes multicapa. La manera más común de este tipo de redes consiste en la selección de solo una capa oculta relacionada con una capa de salida con lo que se logra una profundidad de dos capas. De esta manera la regularización se define como cualquier problema principal en el aprendizaje profundo que conlleva a la realización de un algoritmo que demuestre resultados tanto en los datos de entrenamiento como también en las nuevas entradas. Varias acciones son usadas en el aprendizaje profundo para la reducción o minimización del error de prueba, probable a costa de un mayor error de entrenamiento. Estas destrezas son conocidas como regularización [14]. En este sentido, la regularización es la modificación que se realiza al algoritmo de aprendizaje, el mismo que tiene como objetivo la reducción del error de generalización, y no su error de entrenamiento. Existen varias formas de regularización, algunos de ellos colocan limitaciones adicionales en un modelo de aprendizaje profundo o automático, en ciertos casos se perciben las limitaciones en los valores de los parámetros. Otros prefieren agregar información adicional en la función objetivo que pueden considerarse como correspondientes a una limitación suave en los valores de los parámetros. En el caso de una elección cuidadosa, estas limitaciones y penalizaciones adicionales pueden medir el rendimiento en el grupo de pruebas [15].

III. METODOLOGÍA

El estudio fue cuantitativo de diseño pre experimental. Se consideraron los métodos analítico- sintético, para medir las variables redes neuronales artificiales y aprendizaje profundo de pronósticos, para ello se utilizó una prueba de pronósticos de análisis de regresión lineal con pre test y pos test de la aplicación de las redes neuronales, constituida por 12 preguntas. El estudio estuvo representado por 25 estudiantes de la escuela de ingeniería industrial, con el propósito de determinar sus aprendizajes respectivamente. El instrumento fue validado por tres jueces de expertos calificados para evaluar las preguntas propuestas.

Para el proceso del estudio se ha empleado la prueba donde cada estudiante debía responder las doce preguntas sobre el análisis de los temas de pronósticos del aprendizaje profundo. Con la aplicación del pretest y postest se esperaba medir el nivel de los conocimientos de pronósticos que tenían cada estudiante. El aprendizaje profundo hace referencia a los niveles que existe entre una pregunta simple, intermedia y compleja, es decir las distancias entre las preguntas simples, intermedia y compleja que se denominan capas, mientras más profunda es la capa, más complejo es el nivel del conocimiento.

IV. RESULTADOS

A. Principales hallazgos.

El estudio muestra los resultados del aprendizaje profundo de los conceptos de pronósticos antes y después de aplicar las redes neuronales artificiales. Para ello las notas de los 25 estudiantes muestran un promedio de 13,92 y los resultados de nota Aprendizaje conceptual de pronóstico (ACP) fue 13,60, resultados cuya diferencia fue de 0,32, ambos aproximadamente cierran un promedio de 14.




Fig. 4. Registro de nota respecto a conceptos de pronóstico antes y con red neuronal

En la figura 4 se pueden observar las notas del acta de registro reales respecto al aprendizaje conceptual de pronóstico y las notas simuladas con el método de red neuronal del mismo tema, los promedios son casi similares, 13,92 puntos y 13,60 puntos respectivamente, redondeando ambos dan un promedio de 14 puntos de nota.

Otro aprendizaje profundo desarrollado fue los procedimientos de cálculo de pronósticos el resultado obtenido fue de 13,56 (CAPR) en relación al promedio obtenido de 13,80 al aplica las redes neuronales, obteniéndose una diferencia de 0,24. En ese sentido, este proceso de resultado contribuye al desarrollo de problema relacionado con el aprendizaje automático y aprendizaje profundo.



Fig. 5. Registro de nota respecto al aprendizaje de procedimiento de cálculo de pronóstico.

En la figura 5 se pueden observar las notas del acta de registro de notas reales respecto al aprendizaje de procedimiento de cálculo de pronóstico y las notas simuladas con el método de red neuronal del mismo tema, los promedios son casi similares, 13,80 y 13,56 respectivamente, redondeando ambos dan un promedio 14 de nota.

Así mismo, tenemos los resultados del aprendizaje profundo de las conductas de los alumnos, para ello se obtuvo un promedio de 13,60 (COAL), además un promedio de 14,40 después de aplicar las redes neuronales con una diferencia de 0,80, con estos resultados nos muestra que el aprendizaje profundo se ha realizado con redes con más de dos capas ocultas, donde se utilizó varias estructuras de redes neuronales con el propósito de alcanzar el aprendizaje.

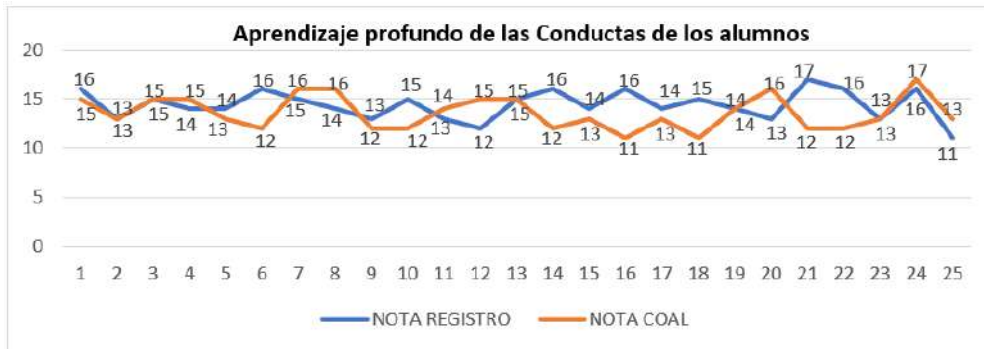


Fig. 6. Registro de nota de conducta de los alumnos antes y con red neuronal.

En la figura 6 se puede observar las notas del acta de registro de notas reales respecto a la conducta del alumno respecto al aprendizaje de pronóstico y las notas simuladas con el método de red neuronal del mismo tema, los promedios son casi similares, 14,40 y 13,60 respectivamente, redondeando ambos dan un promedio 14 puntos calificación.

También se obtuvieron los resultados del aprendizaje profundo de la aplicación de pronósticos en los problemas empresariales en la Escuela de Ingeniería Industrial, los promedios obtenidos fueron de 14,24 puntos (AEP) y 14,2 puntos en promedio, para dichos resultados se utilizaron técnicas tales como composición de módulos simples o lineales lo cual cambian la representación en un nivel superior y con estos cambios la red neuronal adquiere la capacidad de aprender funciones muy complejas [14].

B. Promedios de Aprendizajes profundos de pronósticos.

Tabla 1. Registro de promedio de notas de la red neuronal.

Aprendizaje Profundo de conceptos							
Conceptos		Procedimientos de cálculo		Conductas		Aplicación de pronósticos	
Notas de Registro	Notas ACP	Notas de Registro	Notas CAPR	Notas de Registro	Notas COAL	Notas de Registro	Notas AEP
13,92	13,60	13,80	13,56	14,40	13,60	14,20	14,24

Fuente: Elaboración propia de los autores.

En la tabla 1 se puede observar las notas promedio del acta de registro de notas reales con el promedio de notas obtenidas mediante la aplicación del programa de red neuronal, los promedios generales son casi similares, el promedio de los promedios obtenidos fueron 14,16 puntos y 13,88 puntos respectivamente, redondeando ambos dan un promedio 14 puntos.

CONCLUSIONES

Al aplicar las redes neuronales artificiales para medir el aprendizaje profundo de pronósticos se llegó a las siguientes conclusiones:

Se realizó el proceso de las redes neuronales utilizando el software MATLAB, los elementos que utilizaron fueron: aspectos referentes al entrenamiento de las redes, el comportamiento de las pruebas y los resultados de las comparaciones. También es importante saber que para sea aplicable los datos deben presentar algunas características: independencia, linealidad y tamaño.

La aplicación de las Redes Neuronales Artificiales en la medición del aprendizaje profundo de Pronósticos en la Escuela de Ingeniería Industrial, se obtuvo como promedio en notas de 13,88, las notas reales fueron obtenidos 14,16, los resultados fueron similares redondeando las notas.

Las Redes Neuronales Artificiales en la medición del aprendizaje profundo de los conceptos de Pronósticos se encontró un promedio de notas simuladas de 13,60 y las notas reales tuvieron promedio de 13,92, redondeando ambos promedios fueron similares.

En la medición del procedimiento de aprendizaje de cálculo de pronósticos aplicando las redes Neuronales Artificiales se encontró un promedio de notas simuladas de 13,56 y las notas reales tuvieron promedio de 13,80, redondeando ambos promedios fueron similares.

En la medición de la conducta del alumno respecto al aprendizaje de pronóstico, aplicando las redes Neuronales Artificiales se encontró un promedio de notas simuladas de 13,60 y las notas reales tuvieron promedio de 14,40, redondeando ambos promedios fueron similares.

Con la aplicación de las Redes Neuronales Artificiales en la medición de la aplicación de Pronósticos en los problemas empresariales se encontró un promedio de notas simuladas de 14,24 y las notas reales tuvieron promedio de 11,12, redondeando ambos promedios fueron similares.

Utilizar las redes neuronales para lograr cambios en los aprendizajes son importantes porque nos permite dar solución en el escenario de la inteligencia artificial, unos de los aspectos resaltantes es la orientación al conocimiento en la profundidad en la comprensión de los estudiantes cuando deciden realizar una lectura o algún estudio de un texto. En el caso del cálculo de pronóstico de las ventas, el porcentaje de error se mostró en 1% siendo el modelo 3 el más adecuado; es decir, para realizar estos procesos la red neuronal se mostró con una capa oculta donde se realizó el proceso de los datos.

Un aspecto importante es saber la utilización de las redes neuronales en diagnosticar el proceso pronostico llevando a un nivel alto de incertidumbre en los resultados de previsión a comparación de los métodos convencionales porque no existe un alto grado de dispersión en datos de información técnica en el caso de energía eléctrica.

REFERENCIAS

- [1] H. Beale, and Demuth, MathWorks, 2020.
- [2] J. Velásquez. "Neuroscheme: un lenguaje para el modelamiento de redes neuronales artificiales". Dyna, 72(147), pp. 75-83, 2005.
- [3] E. Toro, D. Mejía, H. Salazar. "Pronóstico de ventas usando redes neuronales". Scientia Et Technica, 10, (26), pp. 25-30, 2004. <https://www.redalyc.org/articulo.oa?id=84911640006>
- [4] S. Hong Tang and Ch. Kit Ang, Predicting the Motion of a Robot Manipulator with Unknown Trajectories Based on an Artificial Neural Network. Mohd Khairol Anuar Bin Mohd Ariffin and Syamsiah Binti Mashohor, septiembre del 2014.

- [5] J. A. Anderson, *Redes Neuronales*. México: Alfaomega Grupo Editor, 2007.
- [6] A. Requena, R. Quintanilla, J. M. Bolarin, A. Vásquez, A. Bastidas, J. Zúñiga y L.M. Tomás. 2022. *Nuevas Tecnologías y Comunicación de Atmosferas, para PYMEs*. VI-3-4.
- [7] G. A. Kirby, Kevin, *Tutorial on Helmholtz Machine*. Department of Computer Science, Northern Kentucky University, June 2006.
- [8] R. F. López, and J. M. Fernández, *Las redes neuronales artificiales: Netbiblo*, 2008.
- [9] A.A. Jiménez, C.Q. Muñoz, and F.P. Márquez, *Machine learning and neural network for maintenance management*. Paper presented at the International Conference on Management Science and Engineering Management, 2017.
- [10] R. López, *Las Redes neuronales artificiales: fundamentos teóricos y aplicaciones prácticas*. Oleiros, La Coruña Netball, 2019.
- [11] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning". *Nature*, 521(7553), 436-444. 2015. <https://doi.org/10.1038/nature14539>
- [12] F. Marton, and R. Säljö, "On qualitative differences in learning. II. Outcome as a function of the learner's conception of the task". *British Journal of Educational Psychology*, 46, 128-148. 1976.
- [13] J. Biggs, and K. F. Collins, *Evaluating the quality of learning: The Solo Taxonomy*. Nueva York: Academic Press, 1982.
- [14] I. Goodfellow, Y. Bengio, and A. Courville, (2016). *Deep Learning Adaptive Computation and Machine Learning Series*. Estados Unidos: MIT Press, 2016. Obtenido de <https://www.deeplearningbook.org/contents/convnets.html>.
- [15] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning". *Nature*, 521(7553), 436-444, 2015. <https://doi.org/10.1038/nature14539>.



Willy Alex Castañeda Sánchez, Educador en la especialidad de Matemática y Física. Dr. En Educación Capacitado en investigación científica en innovación pedagógica y tecnológica, trabajo en equipo y habilidades. He realizado estudios de epistemología, estadística en el campo de la investigación científica y metodología. Así mismo, he realizado investigación en estrategias en las capacidades de resolución de problemas en el nivel superior.



Benjamín Roldan Polo Escobar, Ing. En Estadística e Informática, Licenciado en Administración, Magister en Dirección Estratégica en Tecnologías de la Información, Mg. En Gestión de los Servicios de Salud, Doctor en Gestión Pública y Gobernabilidad, Doctor en Administración de la Educación, con experiencia en el sector público por más de 20 años, docente investigador de la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas – Facultad de Ciencias Económicas y Administrativas.



Fernando Vega Huincho, Ingeniero Industrial, Licenciado en Educación, Maestro en Computación e Informática, Maestro en Investigación y Docencia y Doctor en Gestión y Ciencias de la Educación. Docente de la asignatura de Seminario de Proyecto de Tesis (Escuela de Ingeniería Informática y de Sistemas), Seminario de Tesis I (Escuela de Ingeniería Civil) ambas en la Universidad San Pedro. Asesor de tesis y jurado de tesis en los niveles de pregrado y maestría.