

PREDICCIÓN DE LA EFICIENCIA PRODUCTIVA, APROXIMACIÓN DESDE REDES NEURONALES Y REGRESIÓN LINEAL

PRODUCTIVE EFFICIENCY PREDICTION, APPROACH FROM NEURONAL NETWORKS AND LINEAR REGRESSION

Ruth Milena Suárez Castro ¹
Iván Darío Ladino Duque ²
Nelson Eduardo Lozano ³

1. RESUMEN

Introducción. En este estudio se realizó un modelo de regresión lineal y el diseño de una red neuronal con el propósito de predecir la eficiencia productiva para una empresa de confección. **Metodología.** Para el desarrollo de los modelos, se tomaron 10080 registros que permiten calcular eficiencia productiva (tiempo de fabricación, tiempos muertos y tamaño del lote fabricado). Los datos fueron separados en dos conjuntos, de entrenamiento y prueba con 7056 y 3024 registros de las variables mencionadas respectivamente. **Resultados.** El modelo de regresión lineal mostró que ausentismos, falta de material y falta de servicios tienen mayor incidencia en la eficiencia productiva. La red neuronal se estructuró (7,3,1) y utilizó algoritmo de aprendizaje de retropropagación. Se calculó el error cuadrado medio de cada modelo, como medida de desempeño. **Conclusiones.** Los resultados obtenidos para el error cuadrado medio muestran mejor desempeño de la red neuronal en la predicción de la eficiencia productiva.

PALABRAS CLAVE: Eficiencia productiva, redes neuronales, regresión lineal.

2. ABSTRACT

Introduction. In this study, a linear regression model and the design of a neural network were carried out in order to predict the productive efficiency for a clothing company. **Methodology.** For the development of the models, 10,080 records were taken that allow to calculate productive efficiency (manufacturing time, downtime and size of the manufactured batch). The data were separated into two sets, training and test with 7056 and 3024 records of the variables mentioned respectively. **Results.** The linear regression model showed that absenteeism, lack of material and lack of services have a greater impact on productive efficiency. The neural network was structured (7,3,1) and used backpropagation learning algorithm. The mean square error of each model was calculated as a performance measure. **Conclusions.** The results obtained for the mean square error show better performance of the neural network in the prediction of productive efficiency.

KEYWORDS: Productive efficiency, neural networks, linear regression.

SUMARIO: 1. Introducción. 2 Método. 2.1.1. Estrategias metodológicas. 2.1.2. Población y muestra. 2.1.3. Instrumentos de recogida de información. 2.1.4. Procedimiento. 3. Resultados. 4. Discusión y conclusiones. 5. Referencia bibliográficas.

¹Ing. Industrial, profesora del programa de Ingeniería Industrial de La Fundación Universitaria Los Libertadores, Colombia - rmsuarezc@libertadores.edu.co

²Ing. Electrónico, profesor del programa de Ingeniería Electrónica de La Fundación Universitaria Los Libertadores, Colombia - idladinod@libertadores.edu.co

³ Ing. Electrónico, profesor del programa de Ingeniería Electrónica de La Fundación Universitaria Los Libertadores, Colombia - nelson.lozano@ulibertadores.edu.co

3. INTRODUCCIÓN

En el sector de la confección, el monitoreo continuo a la eficiencia de los procesos es una forma de asegurar la satisfacción de los clientes con la entrega de pedidos y el aprovechamiento de la capacidad de producción disponible. Con frecuencia, los procesos sufren retrasos debidos a un conjunto de interferencias y/o paradas de producción conocidas como tiempo muerto, que deben ser cuantificadas diariamente para determinar el nivel de eficiencia productiva.

Las interferencias en producción tienen relación directa con el recurso humano (ausentismos, permisos e incapacidades), con el mal estado de funcionamiento de máquinas, con problemas asociados a la calidad que obligan a reprocesar el producto, con el desabastecimiento de materias primas e insumos, y con factores externos asociados a la falta de servicios públicos necesarios para que el proceso funcione, entre otros (Herrera, 2018).

El concepto de eficiencia ha sido abordado como la razón entre la producción real obtenida y la producción estándar esperada (Sumanth, 1993), y como una capacidad para desarrollar una labor con el mínimo tiempo (Montero Vega, Díaz Rangel, Guevara Trujillo, Cepeda Rugeles, & Barrera Herrera, 2013). En el sector de la confección, la eficiencia es el principal indicador de planta y tiene un impacto directo en la utilidad percibida, de ahí la necesidad de mejorarla reduciendo las interferencias (Herrera, 2018) y de predecirla, a fin de conocer su influencia en el desempeño empresarial.

El objetivo del estudio es predecir el valor medio de la eficiencia productiva a partir de un modelo de regresión lineal con múltiples variables y de una red neuronal con retropropagación, que permitan responder ¿Cuál es técnica de análisis de datos que ofrece un mejor ajuste en la predicción de la eficiencia productiva? Para responder a este interrogante se realizó una comparación de los resultados del error cuadrado medio MSE de un modelo de regresión lineal y de una red neuronal del tipo perceptrón multicapa.

Los modelos de regresión muestran que la relación entre variables tiene una forma lineal; para el caso de la regresión lineal múltiple se intenta ajustar un modelo lineal entre múltiples variables independientes que ejercen influencia y la variable dependiente. Los supuestos que requiere verificar este tipo de modelos son heterocedasticidad y multicolinealidad (Montero Granados, 2016).

Un modelo de regresión lineal presenta la siguiente estructura: $y = 0 + 1 \cdot X_1 + 2 \cdot X_2 + \dots + n \cdot X_n + e$ (Aguilar Márquez, Pineda, Altamira, Axotla, & García, 2011), donde y hace referencia al valor estimado de la variable dependiente, 0 se refiere a la intersección en el origen del plano y el eje y , 1 representa el coeficiente de regresión parcial de y , que se interpreta como la cantidad en la que se modifica la variable dependiente, cuando hay un incremento sobre X_1 , si las demás variables

x , se mantienen constantes; por último e hace referencia al error, que indica la porción de respuesta del modelo que no puede explicarse por la ecuación de regresión. (Carrasquilla-Batista, y otros, 2016).

Las redes neuronales artificiales son modelos de Machine learning de amplia utilización, que buscan replicar el proceso natural de las neuronas del cerebro humano. Son entendidas como conjuntos de neuronas simuladas conectadas entre sí, que interactúan con elementos de un sistema real logrando aprender del sistema a través de ejemplos resueltos para predecir comportamientos del sistema real (Acevedo Orduña, Caicedo Bravo, & Loaiza Correa, 2007), (Rivas Asanza & Mazón Olivo, 2018), a partir de un conjunto de datos. La estructura matemática de la neurona artificial se describe en la ecuación (1):

Ecuación 1. Estructura matemática de la neurona artificial.


$$z_j = b_j + \sum_{i=1}^n x_i w_i \quad (1)$$

Donde, Z_j es la suma ponderada de los factores x de entrada con los pesos sinápticos w , B_j hace referencia al sesgo o vías, X_i representa a cada una de las n entradas, w_i representan a los pesos sinápticos. Generalmente las estructuras de redes neuronales artificiales se forman por conjuntos de neuronas que se agrupan en capas: capa de entrada (input layer), capas ocultas (Hidden Layer), capa de salida (Output layer), donde las neuronas de cada capa comparten características comunes (Yang, 2019).

Las redes neuronales se consideran una herramienta con habilidad de aprendizaje y de generalización, lo que las hace capaces de realizar tareas complejas como predicción de comportamientos, reconocimiento de patrones, estimación de parámetros y toma de decisiones (Sarmiento Ramos, 2020), tienen la capacidad de generalizar y son adaptables a los cambios en el ambiente que las rodea (Lázaro, Puente, Lazaro, Capote, & Alvear, 2013).

La estructura de redes neuronales se forma cuando se conectan diversas neuronas según una arquitectura dada, es decir, cada neurona estará conectada a neuronas de capas adyacentes y conformarán una red, en la que la neurona transforma los datos de entrada por medio de la suma ponderada de la salida de las neuronas de la anterior capa y luego la pasa por una función no lineal que genera la salida de esa neurona, esta salida se convierte en la entrada de la siguiente capa hasta llegar a la capa final (Vieira, López Pinaya, García-Díaz, & Rafael, 2020), tal como se observa (en la Ilustración 1):

Ilustración 1. Estructura de la red neuronal.



Fuente: Tomada literalmente de la referencia (Trujillano Cabello, y otros, 2005).

Una manera de determinar el mejor desempeño de las redes neuronales, está dado por la capacidad de minimizar los errores que se generen en el aprendizaje y la predicción (Yang, 2019). Para el caso de las redes perceptrón multicapa (MPL) que utilizan el algoritmo Backpropagation en la corrección del error, su funcionamiento consiste en el aprendizaje de un conjunto de entradas y salidas a modo de ejemplo, que permiten a la red aprender a través de la comparación con la salida ejemplo, esto ocurre por la propagación de un estímulo por la capa de entrada que se propaga a las demás capas y que va generando un valor de error al contrastarse con la salida esperada.

4. MÉTODO

4.1. Estrategias metodológicas

Para este estudio se trabajó con un estudio de caso, en razón a que se tomó información de una única planta de confección. La intención de comparar el nivel de predicción de la eficiencia productiva para una empresa de este tipo, se utilizó el software R para aplicar un modelo de regresión lineal y luego una red neuronal sobre los datos de la muestra, obteniendo de cada uno de los modelos una medida del error que fue contrastada posteriormente.

4.2. Población y muestra

Se tomaron 10080 registros de producción por hora de una planta de confección de prendas femeninas, utilizados para terminar la eficiencia productiva. Se definieron como variables independientes medidas en minutos: tiempo de fabricación, tiempo por daño mecánico, tiempo de ausentismos, tiempo por falta de material, tiempo por reprocesos y tiempo por falta de servicios, por ser las interferencias más comunes del proceso y la variable tamaño de lote medida en unidades. La variable dependiente fue la eficiencia productiva.

4.3. Procedimiento

Se hizo un análisis de correlación para descartar multicolinealidad y se procedió a crear un modelo de regresión lineal que predijera la eficiencia productiva. Posteriormente se realizó el diseño de una red neuronal con algoritmo de retropropagación y estructura (7,3,1), clasificando los registros en muestra de entrenamiento y muestra de prueba, para predecir la variable dependiente. Se calculó el error cuadrado medio como medida de desempeño para cada uno de los modelos, de tal forma que fuera posible realizar la comparación de métodos, en términos del menor error obtenido.

5. RESULTADOS

Para pronosticar la eficiencia productiva en una empresa de confección se utilizaron dos métodos, un modelo lineal y el diseño de una red neuronal con algoritmo de retropropagación, que cuenta con una estructura de 7 neuronas en la capa de entrada, 3 neuronas en la capa oculta y una neurona en la capa de salida. El modelo de regresión lineal utilizó como medida de desempeño el error cuadrado medio, para medir la diferencia existente entre los datos reales y lo predicho por el modelo lineal. El resultado obtenido del modelo lineal se presenta a continuación.

Tabla 1. Resultado del Modelo de Regresión Lineal.

Coefficients	Estimate Std.	Error	t value	Pr (> t)
(Intercept)	7,82E+02	1,83E+0	427.786	< 2e-16 ***
Tamaño_lote	2,56E-02	6,52E-04	39.320	< 2e-16 ***
Tiempo_fabricacion	6,72E-03	1,92E-04	34.950	< 2e-16 ***
Ausentismos	-1,21E-01	1,50E-02	-8.078	7.71e-16 ***
Daño_mecanico	-9,32E-02	1,49E-02	-6.266	3.92e-10 ***
Falta_material	-1,26E-01	1,60E-02	-7.876	3.89e-15 ***
Reprocesos	-9,86E-02	2,22E-02	-4.445	8.92e-06 ***
Falta_servicios	-1,48E-01	3,27E-02	-4.510	6.60e-06 ***
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				

Fuente: Completamente generada por el autor, 2021.

Para el análisis de eficiencia productiva se infiere del modelo, que se tendrá un incremento en la productividad en 6.723e-06 por cada incremento de 1 minuto en el tiempo de fabricación si las demás variables se mantienen constantes, igualmente se incrementa la eficiencia en 2.564 por cada unidad que se incremente el tamaño del lote. Sumado a esto, se reducirá la eficiencia por cada minuto


de incremento en las variables de: ausentismo, daño mecánico. Falta de material. Reprocesos y falta de servicios, reducen la eficiencia en $-1.211\text{e-}04$, $-9.317\text{e-}05$, $-1.258\text{e-}04$, $-9.861\text{e-}05$ y $-1.476\text{e-}04$ unidades porcentuales respectivamente. Siendo ausentismos, falta de material y falta de servicios, los que reducen con mayor impacto la eficiencia. Adicionalmente, el error cuadrado medio (MSE) que tiene el modelo de regresión lineal múltiple equivale a 0.002602184.

La red neuronal NN en la capa de entrada contiene 7 neuronas que corresponden al conjunto de variables utilizadas para comparar el tiempo esperado de fabricación y el tiempo real invertido en el proceso, como son: Las horas de fabricación cargadas a cada producto, el tiempo no trabajado debido a daños de máquinas, falta de material, ausentismos, reprocesos, problemas de calidad y falta de servicios públicos, que tienen como propósito pronosticar el valor de la eficiencia productiva.

Para el cálculo del número de neuronas en la capa oculta, se utilizó la regla de la pirámide geométrica (Zepeda Hernández, Aguilar Castillejos, Hernández, & Salgado Gutiérrez, 2015), técnica que especifica la determinación del número de neuronas a partir de la expresión $n*m$, donde n es el número de neuronas en la capa de entrada y m el número de neuronas de salida. Para este caso, por ser una red neuronal de regresión, la capa de salida debe contener una sola neurona, cuyo valor hace referencia al valor buscado, en este caso, la eficiencia pronosticada.

Los datos de la red neuronal NN fueron divididos en datos de entrenamiento y datos de prueba. Para el caso de los datos de entrenamiento de la red neuronal se tomó el 70% del total de valores existentes y se procedió a realizar el modelo de regresión lineal. Dado el total de datos analizados, el tamaño de la muestra de entrenamiento correspondió a 7034 datos y la muestra de prueba fue de 3000 datos. En el proceso de preprocesamiento de los datos, estos fueron normalizados utilizando la escala mínima-máxima en el intervalo entre [0,1] y se procedió a diseñar la red neuronal presentada (en la Ilustración 2) con el paquete Neuralnet de R Studio.

Ilustración 1. Estructura de la red neuronal.




Fuente: Completamente generada por el autor, 2021

Para el entrenamiento de la red neuronal se utilizó el algoritmo de retropropagación Resilient Backpropagation. Las conexiones existentes entre las neuronas de las 3 capas se visualizan en la Figura 2 de color negro, así como, se visualizan los pesos sinápticos asociados a las conexiones. El bias se presenta en la red neuronal de color azul e indican el sesgo agregado en cada paso.

La Figura 3 muestra la predicción de los valores de eficiencia productiva obtenidos por el modelo de red neuronal NN y la predicción obtenida por el modelo de regresión lineal LM. Para el caso de la red neuronal NN, los datos de predicción se ajustan adecuadamente a los datos reales, siendo mayor el ajuste para eficiencias entre 0,8 y 1. El valor del error cuadrado medio MSE de la red neuronal correspondió a 0.00196467.

De otra parte, la predicción obtenida con el modelo de regresión lineal muestra elevada dispersión de los valores de eficiencia productiva especialmente entre 0.8 y 0.9, así como un mejor ajuste entre 0,9 y 1. El resultado del MSE para el modelo de regresión lineal es de 0.002602184, este resultado es mayor al obtenido por el modelo de red neuronal, donde el MSE es 0.00196467.

Ilustración 3. Comparación de los Valores Reales Vs los Valores de Predicción del Modelo de Red Neuronal de Retropropagación NN y del Modelo de Regresión Lineal LM.



Fuente: Completamente generada por el autor,2021

6. DISCUSIONES

El uso de redes neuronales en tareas de pronóstico, se convierte en una opción confiable para el monitoreo de la eficiencia productiva en plantas de confección, a pesar de que los modelos de regresión lineal también ofrecen resultados cercanos, pero con mayor error.

La diferencia existente entre el valor de MSE para el modelo de regresión lineal y el MSE del modelo de red neuronal, permite asegurar que el modelo de red neuronal presenta un mejor ajuste con los datos reales.

La capacidad de aprendizaje de las redes neuronales para entender ciertas características de un objeto de estudio, especialmente las de aprendizaje supervisado, hace posible utilizarlas como herramienta de predicción donde se cuente con una muestra de entrenamiento y otra muestra de prueba, en los casos en los que se tengan variables con un comportamiento similar a pesar de la variabilidad en los datos.



REFERENCIAS

- Acevedo Orduña, G. L., Caicedo Bravo, E. F., & Loaiza Correa, H. (2007). Selección de Personal mediante Redes Neuronales Artificiales. *Revista de Matemática: Teoría y Aplicaciones*, 7-20. doi:10.15517/rmta.v14i1.278
- Aguilar Márquez, A., Pineda, M., Altamira, J., Axotla, J. C., & García, O. (2011). Fascículo 10 Inferencia estadística: Regresión y correlación lineal múltiple. México D.F.: Universidad Nacional Autónoma de México.
- Carrasquilla-Batista, A., Chacón-Rodríguez, A., Núñez-Montero, K., Gómez-Espinoza, O., Valverde, J., & M., G. (2016). Regresión lineal simple y múltiple: aplicación en la predicción de variables naturales relacionadas con el crecimiento microalgal. *Tecnología en Marcha*, 33-45. doi:DOI: 10.18845/tm.v29i8.2983
- Herrera, J. (2018). Mejora en la eficiencia y en el ambiente de trabajo en Texgroup S.A. *Gestión de la producción*(36), 35-66. doi:https://doi.org/10.26439/ing.ind2018.n036.2445
- Lázaro, D., Puente, E., Lazaro, M., Capote, J., & Alvear, D. (2013). Posibilidades de un modelo sustituto de incendios mediante el empleo de redes neuronales. *Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería*, 29, 129-134. doi:10.1016 / j.rimni.2013.06.001
- Maisueche Cuadrado, A. (2019). Utilización del machine learning en la industria 4.0. Valladolid: Universidad de Valladolid.
- Montero Granados, R. (2016). Modelos de regresión lineal múltiple . *Documentos de Trabajo en Economía Aplicada*, 1-61.
- Montero Vega, J. C., Díaz Rangel, C., Guevara Trujillo, F., Cepeda Rugeles, A., & Barrera Herrera, J. C. (2013). Modelo para Medición de Eficiencia Real de Producción y Administración Integrada de Información en Planta de Beneficio. Bogotá: Cenipalma.
- Montesdeoca Santana, B. (2016). Estudios de predicción en series temporales de datos meteorológicos utilizando redes neuronales recurrentes. Gran Canaria: Universidad de las palmas de Gran Canaria.
- Peláez Chávez, N. (2012). Aprendizaje no supervisado y el algoritmo wake sleep en redes neuronales. Huajuapán : Universidad Tecnológica de la Mixteca.
- Ríos, J., Alanís, A., Arana-Daniel, N., & López-Franco, C. (2020). Appendix A - Artificial neural networks. En A. Press, *Neural networks modeling and control. Applications for unknown nonlinear delayed systems in discrete time* (págs. 117-124).
- Rivas Asanza, W., & Mazón Olivo, B. (2018). Redes neuronales artificiales aplicadas al reconocimiento de patrones. Machala: UTMACH.
- Sáenz Bajo, N., & Ballesteros, Á. (2002). Redes neuronales: concepto, aplicaciones y utilidad en medicina. *Reflexiones de medicina de familia*, 119-120.
- Sarmiento Ramos, J. L. (2020). Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. *Revista UIS Ingenierías*, 1-18. doi:https://doi.org/10.18273/revuin.v19n4-2020001
- Sumanth, D. (1993). *Ingeniería y administración de la productividad*. Mc Graw Hill.
- Trujillano Cabello, J., Badía Castello, M., March Llanes, J., Pozo, R., Serviá Goixart, L., & Sorribas Tello, A. (2005). Redes neuronales artificiales en Medicina Intensiva. Ejemplo de aplicación con las variables del MPM II. *Medicina intensiva*, 13-20. doi:10.1016/S0210-5691(05)74198-X
- Vieira, S., López Pinaya, W., García-Díaz, & Rafael, M. A. (2020). Chapter 9- Deep neural networks. En S. Vieira, & A. Mechelli, *Machine Learning Methods and applications to brain disorders* (págs. 157-172). Londres: Academic Press.
- Yang, X.-S. (2019). 8- Neural networks and deep learning. En X.-S. Yang, *Introduction to algorithms for data mining and machine learning* (págs. 139-161). Londres: Academic Press.
- Zepeda Hernández, J. A., Aguilar Castillejos, A. E., Hernández, A., & Salgado Gutiérrez, M. C. (2015). Metodología para determinar la topología, patrones de parámetros eléctricos y entrenamiento de una Red Neuronal Artificial para un control inteligente. *Revista Tecnología Digital*, Vol. 5 (No. 1), 104-113. Recuperado el 30 de Agosto de 2021, de chrome-extension://efaidnbmnnnibpcajpcgclefindmkaj/viewer.html?pdfurl=http%3A%2F%2Fwww.revistatecnologiadigital.com%2Fpdf%2F05_009_metodolog%25C3%25ADa_topolog%25C3%25ADa_patrones_par%25C3%25A1metros_el%25C3%25A9ctricos_entrenamiento_red_neuronal.pdf&cle