

Application of Artificial Neural Network Methodology for the Prediction of Labor Productivity in the Construction Sector

Bryam Alex Murga Díaz, Bach¹, Diego José Luna Peralta, Bach²
Anita Alva Sarmiento, Mg³

¹ Universidad Privada del Norte (UPN), Cajamarca, Perú. N00029031@upn.pe

² Universidad Privada del Norte (UPN), Cajamarca, Perú. N00026993@upn.pe

³ Universidad Privada del Norte (UPN), Cajamarca, Perú. anita.alva@upn.edu.pe

Abstract—The present research determined the level of prediction of labor productivity in road projects using the methodology of artificial neural networks, due to the relevance of this variable in the construction industry. In order to achieve this objective, first a systematic review was carried out to determine the most influential factors in labor productivity. Then, technical files were compiled that included the following items: "Manual cutting at subgrade level", "Subgrade leveling and compaction with light or manual equipment", "Conformation of granular base" and "Concrete in sidewalks" for the creation of the database used in the training and testing of the neural networks. Then, the optimal model for the development of the final neural networks was evaluated, generating 4 models of Machine Learning Artificial Neural Networks, one for each item, with the training algorithm "Bayesian Regularization" and with 20 neurons in the hidden layer, achieving values of 96%, 97%, 97% and 99% for the correlation factors between input and output values. Finally, the 4 models developed were validated with the application of data from works in progress, demonstrating that the models generated are more accurate and reliable than conventional methods when predicting the real productivity of a batch.

Key words: Construction Labor Productivity, Artificial Neural Networks, Predictive Modeling, Machine Learning.

I. INTRODUCCIÓN

La industria de la construcción es considerada un factor clave en el desarrollo económico del Perú, con un impacto significativo en el crecimiento del Producto Bruto Interno (PIB), ya que crea millones de empleos y apoya los flujos de inversión incluso en situaciones de crisis [1].

Sin embargo, uno de los mayores problemas de este sector está relacionado con la productividad de sus trabajadores, según el Informe de Desarrollo Económico 2018, la productividad del sector de la construcción por trabajador en el Perú es del 36% respecto a la de Estados Unidos durante los años 2004-2015 [2].

Cabe señalar que el entorno de productividad es impredecible y complejo debido a la gran cantidad de parámetros que afectan directa o indirectamente la

productividad y su proceso de seguimiento, el cual requiere mucho tiempo. Por lo tanto, crear un modelo predictivo requiere un estudio complejo de los varios factores que afectan la productividad laboral [3].

La referencia [4] titulada "Measuring and Modeling Labor Productivity Using Historical Data" y publicado en Journal of Construction Engineering and Management, presentaron una metodología para el modelado de la productividad de diseño y fabricación del acero donde primero definieron un sistema de medición de la productividad laboral para el diseño y actividades de fabricación en el taller; luego desarrollaron un sistema para obtener y recopilar datos de productividad laboral de proyectos pasados y actuales. Finalmente, utilizaron los datos recopilados para desarrollar modelos de productividad laboral utilizando redes neuronales artificiales y simulando eventos discretos. El estudio demostró que la productividad debe medirse constantemente para hacer predicciones efectivas y concluyó que las ANN son efectivas para modelar actividades individuales que tienen detalles complejos con relaciones complicadas entre la productividad y los factores de impacto.

La referencia [5] publicada en Al-Qadisiyah Journal For Engineering Sciences y titulada "Productivity Estimation Model for Bracklayer in Construction Projects Using Neural Network", en su investigación, el autor desarrolla una red neuronal artificial para predecir la productividad laboral de los albañiles, en la que utiliza 13 factores de influencia, entre los que se incluyen, por ejemplo, la productividad, edad, experiencia, tamaño del equipo de trabajo, entre otros. El resultado es que la productividad prevista es aproximadamente la misma que la productividad real con buena precisión, presentando un valor R del 86,28 % y un error cuadrático medio del 1,32 %. En conclusión, se puede decir que el modelo ANN desarrollado por el autor puede ser utilizado de manera confiable para estimar los valores de producción de los albañiles en cada proyecto de construcción de edificaciones, incluyendo la influencia de los factores seleccionados en este estudio.

La referencia [6] publicada en ARPN Journal of Engineering and Applied Sciences y titulada "Development of the construction productivity estimation model using artificial

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

neural network for finishing works for floors with marble”, los autores presentan una formulación para el entrenamiento de perceptrones multicapa utilizando un algoritmo de retro propagación de redes neuronales para predecir la productividad en proyectos residenciales, comerciales y educativos. Los autores investigaron diez factores que influyen en la predicción de la productividad al utilizar un modelo ANN, tomando como objeto de investigación el rendimiento de la actividad “acabados de mármol en pisos”. Los resultados confirmaron la buena capacidad predictiva del modelo ANN desarrollado, ya que el valor del coeficiente de correlación es del 89,55 % y el valor del porcentaje de precisión promedio es del 90,9 %.

Por lo tanto, el propósito de este estudio es presentar y revisar un enfoque de ingeniería para la predicción de la productividad laboral de la construcción desde el concepto hasta el detalle utilizando la metodología de redes neuronales artificiales para investigar y cuantificar las relaciones entre los factores que influyen y las tasas de productividad correspondientes.

Esperando que se determine un coeficiente de correlación entre 90% a 95% para la predicción de la productividad laboral en el sector construcción mediante la aplicación de Redes Neuronales Artificiales.

II. METODOLOGÍA

La investigación es de enfoque cuantitativo, no experimental, de tipo transeccional correlacional-causal, para la recolección de datos se utilizó la técnica de revisión documental de diversas fuentes bibliográficas que permitan el análisis de métodos de procesamiento y recopilación de datos. En el análisis de datos la técnica utilizada fue el análisis documental para la organización de la información recopilada en tablas, cuadros y gráficos.

Como parte de los instrumentos se desarrollaron fichas de recolección de datos y fichas de procesamiento que permitieron el tratamiento de los datos para ingresarlos a las redes neuronales artificiales. Fue fundamental el uso de programas de ofimática, así como el software MATLAB R2020b para generar las RNAs.

De manera detallada el procedimiento se divide en 5 etapas:

A. Etapa 1: Revisión Documental

Se inició con la búsqueda de literatura para conocer cuáles eran los factores más influyentes para la productividad laboral en campo; se utilizó las bases de datos: Proquest, EBSCO, ReasearchGATE, Scopus y Scielo, para las palabras

claves: productividad laboral, productividad en campo, redes neuronales y productividad en construcción, en inglés y español.

Fue necesario excluir los artículos por no ser aplicados en el rubro de la ingeniería civil, por el año de antigüedad, excluirlos por la complejidad de los mismos y de esta manera se incluyeron los artículos en la revisión documental

Esta etapa culminó con la evaluación de los artículos seleccionados, a los cuales se les asignaron códigos que permitieron organizarlos según su tipo de estudio, título, año de publicación, autores, base de datos, resumen, DOI y referencia. Para la recopilación de sus resultados se utilizó una ficha que permitió identificar cuáles eran los factores considerados como más relevantes por el autor. Incluyendo para este estudio los que fueron más repetidos por distintos autores.

B. Etapa 2: Recopilación de Expedientes Técnicos

Para la búsqueda de los Expedientes técnicos se utilizaron las bases de datos: Sistema electrónico de Contrataciones del Estado, InfoObras, bases de datos de empresas privadas formales y entidades estatales (municipalidades) para los proyectos: mejoramiento del servicio de transitabilidad, creación del servicio de transitabilidad, pavimentación, pistas y veredas.

La población para el estudio fueron obras de construcción de carreteras desarrolladas en el periodo 2012-2022, para las cuales se recogieron 50 expedientes técnicos. Dado que la población se encuentra compuesta por fenómenos homogéneos la muestra es no probabilística por conveniencia.

Como criterios de inclusión y exclusión para establecer la muestra se consideró: que los expedientes técnicos debían presentar como contenido mínimo: memoria descriptiva, cronograma de ejecución, presupuesto completo, análisis de precios unitarios de las partidas: “Concreto en veredas”, “Corte manual a nivel de subrasante”, “Nivelación y compactación de subrasante con equipo liviano o manual” y “Conformación de base granular”. Todo documento a considerar tubo que contar con la validación pertinente de especialistas y/o profesiones que aseguren su confiabilidad Los proyectos debían haber sido ejecutados en Zona 3 según el RNE y dentro del departamento de Cajamarca-Perú. Aplicados los criterios de inclusión y exclusión se obtuvo una muestra de 16 expediente técnicos, presentes en la tabla 1.

TABLA 1

GRUPO DE EXPEDIENTE TÉCNICOS SELECCIONADOS PARA LA MUESTRA

Nombre del Proyecto	Año de Ejecución	Código SNIP	Número de E.T.
Incremento de metas del proyecto "Mejoramiento del servicio de transitabilidad de las calles de la capital distrital de San José de Lourdes -San Ignacio-Cajamarca"	2021	325041	3
Mejoramiento (construcción) de la pavimentación del Jr. Santa María entre Av. Tahuantinsuyo y Jr. Celendín-Mollepampa - distrito de Cajamarca - provincia de Cajamarca - departamento de Cajamarca	2021	2048523	5
Mejoramiento de la transitabilidad vehicular y peatonal en la prolongación Av. Perú, entre el psje. Amambal y el psje Yanacocha, en el sector Samanacruz, provincia de Cajamarca - Cajamarca	2021	264402	8
Creación del servicio de transitabilidad con la construcción de la pavimentación del Jr. Perea entre Jr. Yurimaguas y Jr. niño de Jesús, provincia de Cajamarca - Cajamarca	2021	2186811	9
Creación del servicio de transitabilidad vehicular y peatonal en la zona periférica de la localidad de Bolívar del distrito de Bolívar - provincia de san miguel - departamento de Cajamarca	2020	2478686	10
Construcción de pista, vereda, cuneta y muro de contención; en el (la) jirón cristo pobre, Tuyurco, los jazmines y palao del centro poblado Araqueda; distrito de Cachachi, provincia Cajibamba, departamento Cajamarca	2020	2492170	11
Creación del servicio de transitabilidad con la pavimentación del Jr. San Pablo entre psje. Tupac Amaru y av. 28 de julio; y con los graderios, del psje. 06 de agosto entre av. los manantiales y av. Perú, de la av. 28 de julio entre jr. san pablo y av. Perú, y del jr. Bolívar entre av. los manantiales y av. Perú - sector 01 San Sebastián, distrito Cajamarca, provincia de Cajamarca - Cajamarca	2020	2380166	12
Creación del servicio de transitabilidad con la pavimentación de la av. Universitaria, jr. Miguel Ángel, psje. San Antonio y av. Aurelio pastor sector 13 San Martín - provincia de Cajamarca - Cajamarca	2020	234877	13
Creación del servicio de transitabilidad vehicular y peatonal en el caserío de San José del distrito de Bolívar - provincia de San miguel - departamento de Cajamarca	2020	2478841	14
Pavimentación del jr. Alfonso Ugarte entre el jr. Arcomayo y av. Héroes del Cenepa del sector Mollepampa	2021	23392	15
Mejoramiento del servicio de transitabilidad en el jr. 7 de junio y la prolongación Simón Bolívar cuerdas 01 y 02 de la ciudad de Bambamarca, distrito de Bambamarca, provincia de Hualgayoc - departamento de Cajamarca.	2020	2441923	16

Mejoramiento de pistas y veredas de la localidad de Tocmoche - distrito de Tocmoche - Chota - Cajamarca	2019	333787	20
Creación del servicio de transitabilidad con la pavimentación del jr. los eucaliptos cuadra 01 y 02, jr. los pinos cuadra 04 y pasaje. Ezequiel bringas Marchena, urbanización Santa Rosa II etapa, sector Chontapaccha, provincia de Cajamarca-Cajamarca	2019	215724	26
Creación del servicio de transitabilidad del psje. San José obrero, jr. los conquistadores, jr. la república, jr. los emancipadores, jr. la mosqueta - sector 13 San Martín, provincia de Cajamarca - Cajamarca	2019	233505	29
Pavimentación del jr. Nicolás Arriola entre el jr. Bolívar y la av. independencia y del puente carrozable sobre la quebrada calispuquio en la intersección del jr. Nicolás Arriola y psje. Independencia, sector 01 San Sebastián, provincia de Cajamarca - Cajamarca	2019	22152	30
Mejoramiento del servicio de transitabilidad con la pavimentación de las calles de la urbanización Condado Real - Sector 10 San Antonio, provincia de Cajamarca - Cajamarca	2022	357989	33

C. Etapa 3: Base de Datos Históricas

Con los 16 expedientes técnicos se creó una base de datos como se muestra en la tabla 1, teniendo en cuenta: la duración real del proyecto, la fecha de inicio de obra, metros sobre el nivel del mar (m.s.n.m) donde se realizó, número de obreros, número de oficiales, rendimiento según el análisis de precios unitarios, metrado de la partida, duración programada antes de la ejecución; esta información se obtuvo para las 4 partidas que se están analizando y para las partidas de: “Conformación de base granular” y “Concreto en veredas” se definió el espesor con el que se trabajó y la resistencia del concreto.

Para ingresar los datos a la RNA es necesario el tratamiento de estos, por ello al observar que los proyectos se entraron en un rango de 900 m.s.n.m. y los 2900.00 m.s.n.m. para el factor de altura se le asignó un valor numérico entre 1 y 5, esta escala quedó a criterio de los autores, permitiendo medir el factor, como se observa en la tabla 2.

TABLA 2
ESCALA DE RANGOS DE ALTURA SEGÚN LA UBICACIÓN DEL PROYECTO

ESCALA	DESDE (m.s.n.m.)	HASTA (m.s.n.m.)
1	900.00	1300.00
2	1301.00	1700.00
3	1701.00	2100.00
4	2101.00	2500.00
5	2501.00	2900.00

Para dimensionar la relación existente entre el número de oficiales y peones que conformaron cada cuadrilla se utilizó la fórmula (1)

$$Rop = \frac{\text{Número de oficiales en la cuadrilla}}{\text{Número de peones en la cuadrilla}} \quad (1)$$

El nivel de motivación durante la ejecución de la actividad se midió en una escala numérica dividiendo la duración total del proyecto entre 5 e identificando en que parte se ejecutaba la partida se asignó un valor del 1 al 5, donde la etapa inicial y 5 la final.

Para el cálculo de la productividad real en campo se estableció la fórmula (2) de la relación entre el metrado y la duración real de la partida.

$$\text{Productividad} = \frac{\text{Cantidad realizada (metrado)}}{\text{Horas de trabajo de mano de obra (duración de la partida)}} \quad (1)$$

D. Etapa 4: Desarrollo de la Red Neuronal Artificial

Para crear la RNA se utilizó la topología identificada en la figura 1, para la cual se trabajó con un modelo de “Machine Learning”, compuesto por una capa oculta en donde se fue evaluando el número óptimo de neuronas según el algoritmo que demostró un mejor desenvolvimiento; para finalmente ir a la capa de salida que predijo la duración real de la partida




Fig. 1 Esquema de la topología de la Red Neuronal Artificial a desarrollar

Para la creación de la red es necesario dividir los datos para cada etapa tomando la decisión de establecer 70% para entrenamiento, 15% para test y el 15% para validación; estos porcentajes fueron considerados según el criterio de los autores, debido a que no existe ninguna regla ni normativa que indique un porcentaje determinado a trabajar en cada etapa de la creación [7] [8].

Se evaluó la combinación de las cuatro partidas, con los tres algoritmos de entrenamiento, generando de esta manera la tabla 5.

TABLA 3
NOMBRE DE LAS PARTIDAS Y CÓDIGOS ASIGNADOS A LOS MISMOS

NOMBRE DE LA PARTIDA	CÓDIGO
Corte manual a nivel de subrasante	CM
Nivelación y compactación de subrasante con equipo liviano o manual	NC
Conformación de base granular	CB
Concreto en veredas	CV

TABLA 4
NOMBRE DE LOS ALGORITMOS DE ENTRENAMIENTO UTILIZADOS Y CÓDIGOS ASIGNADOS A LOS MISMOS

NOMBRE DEL ALGORITMO DE LA RNA	CÓDIGO
Levenberg - Marquardt	LM
Bayesian Regularization	BR
Scaled Conjugate Gradient	SC

TABLA 5
LISTA CON LOS CÓDIGOS DE LAS RNAs PARA EVALUACIÓN DEL ALGORITMO DE ENTRENAMIENTO

NÚMERO DE RNA	CÓDIGO DE LA RNA
1	LMCM
2	LMNC
3	LMCB
4	LMCV
5	BRCM
6	BRNC
7	BRCB
8	BRCV
9	SCCM
10	SCNC
11	SCCB
12	SCCV

Una vez determinado el algoritmo de mejor desempeño se evaluó cada partida: “Concreto en veredas”, “Corte manual a nivel de subrasante”, “Nivelación y compactación de subrasante con equipo liviano o manual” y “Conformación de base granular”, con el número de neuronas en la capa para 5, 10, 15 y 20 neuronas por lo que se crearon 16 redes neuronales artificiales como se muestra en la tabla 6.

TABLA 6
LISTA CON CÓDIGOS DE LAS REDES NEURONALES PARA EVALUAR EL NÚMERO DE NEURONAS EN LA CAPA OCULTA

NÚMERO DE RNA	CÓDIGO DE LA RNA
13	BRCM5
14	BRNC5
15	BRCB5
16	BRCV5
17	BRCM15
18	BRNC15
19	BRCB15
20	BRCV15
21	BRCM10
22	BRNC10
23	BRCB10
24	BRCV10
25	BRCM20
26	BRNC20
27	BRCB20
28	BRCV20

Una vez obtenido el mejor algoritmo de entrenamiento y el número de neuronas óptimo en la capa oculta se procede a generar las 4 redes neuronales finales como se muestra en la tabla 7.

LISTA CON CÓDIGOS DE LAS REDES NEURONALES FINALES

Nº RNA	CÓDIGO
29	CORTEMANUAL
30	NIVELACIONYCOMPACTACIÓN
31	CONFORMACIÓNBASEGRANULAR
32	CONCRETOVEREDA

E. Etapa 5: Desarrollo de la Red Neuronal Artificial

Una vez obtenidos los modelos finales de las RNAs óptimas, se realiza la validación en campo utilizando las 5 obras mostradas en la tabla 8, en donde se predice la productividad real para cada una de las partidas de estudio.

LISTA CON CÓDIGOS DE LAS REDES NEURONALES FINALES

NOMBRE DEL PROYECTO	CÓDIGO
Creación del servicio de transitabilidad vehicular y peatonal en la Av. Industrial, entre Av. Nuevo Cajamarca y Av. Vía de Evitamiento Sur – Sectores 13 San Martín, 19 nuevo Cajamarca, 24 Villa Huacariz, distrito de Cajamarca, provincia de Cajamarca - departamento de Cajamarca.	IND
Creación del servicio de movilidad urbana en las vías locales de av. miguel de cervantes desde la cuadra 12 hasta la cuadra 29, sectores 15 San Vicente y 16 el estanco en el centro poblado Cajamarca, distrito de Cajamarca, provincia de Cajamarca, departamento de Cajamarca.	SAN
Construcción pavimentación de las vías urbanas de la zona este de los Baños del Inca, distrito de los Baños del Inca - Cajamarca - Cajamarca - sector el sol	SOL
Construcción pavimentación de las vías urbanas de la zona este de los Baños del Inca, distrito de los Baños del Inca - Cajamarca - Cajamarca - sector la esperanza	ESP
Mejoramiento de la transitabilidad vehicular y peatonal en la av. Alfonso Ugarte entre la av. Héroes del Cenepa hasta la quebrada cruz blanca Cajamarca	CNP

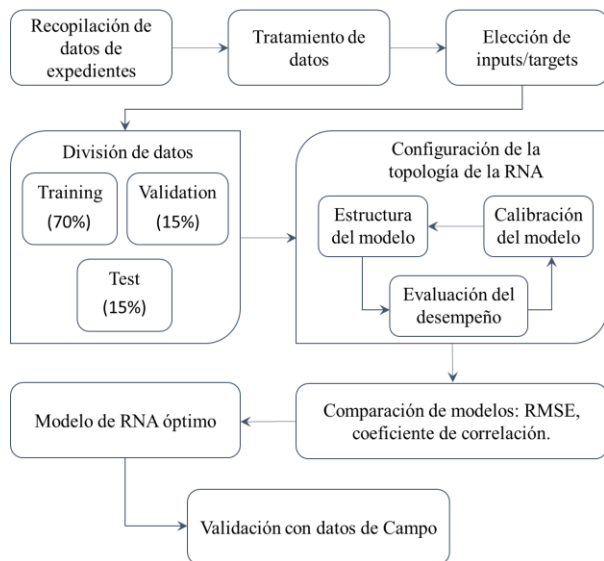


Fig. 2 Visión general de la propuesta para la creación y optimización del modelo de Red Neuronal Artificial

III. RESULTADOS Y DISCUSIÓN

A. Comportamiento de las Redes Neuronales creadas

Se muestra un resumen de los resultados mostrando el número de iteraciones, los valores de R (%) para entrenamiento, test y total, de cada red neuronal.

RESULTADO DEL DESEMPEÑO DE LAS REDES NEURONALES

Código	A.E.	N.It.	Re (%)	Rt (%)	RT (%)
CM	BR	535	99.97%	100.00%	96.50%
NC	BR	1000	99.95%	100.00%	97.44%
CB	BR	541	99.99%	100.00%	97.07%
CV	BR	907	100.00%	97.27%	99.73%

A.E.: Algoritmo de Entrenamiento.
 B.R.: Bayesian Regularization.
 N.It.: Número de Iteraciones.
 Re: Factor de correlación entre valores de entrada y salida de entrenamiento.
 Rt: Factor de correlación entre valores de entrada y salida de test.
 RT: Factor de correlación entre valores de entrada y salida total.

B. Validación con datos de campo

En esta etapa la RNA creada con la base de datos históricos es probada en 5 proyectos viales los cuales se encuentran ubicados en distintos sectores de la ciudad de Cajamarca mostrados en la tabla 8. obteniendo como resultado el nivel de la predicción con el uso de la RNA para proyectos con características variadas.

En las tablas 10, 11, 12 y 13 se realiza el comparativo de: la productividad real (obtenida de campo), la productividad programada (proveniente de expedientes técnicos) y la productividad predicha por la RNA (calculada de la afectación de la duración predicha por la RNA con el metrado según la fórmula 2 para cada partida analizada). Para concluir, se contrastaron los datos predichos por la RNA con los estimados en los expedientes técnicos y los obtenidos en campo. Con la finalidad de tener una mejor perspectiva del nivel de precisión en cada partida, se muestran tablas de resultados con sus respectivos gráficos de dispersión en las figuras 3, 4, 5 y 6.

RESULTADO DE LAS PREDICIONES REALIZADAS POR LA RED NEURONAL EN LA PARTIDA “CORTE MANUAL A NIVEL DE SUBRASANTE”

Obra	Productividad real (m3/día)	Productividad programada (m3/día)	Productividad predicha por la RNA (m3/día)
IND	55.51	46.26	57.60
SOL	30.57	28.66	30.77
ESP	34.50	36.80	34.46
CNP	59.22	55.27	58.12
SAN	37.38	41.86	38.54

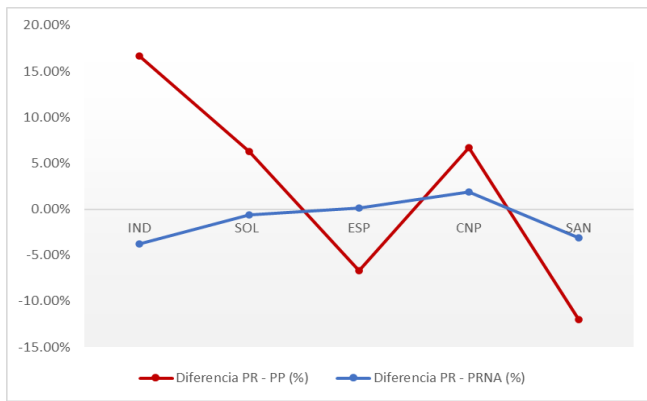


Fig.3 Comparación de la diferencia de los valores de productividad real (PR) con la productividad programada (PP) y la productividad predicha (PRNA) para la partida “Corte manual a nivel de subrasante”.

Para determinar la precisión de los modelos generados durante el entrenamiento y test se consideró la cantidad de iteraciones necesarias para obtener el algoritmo final de la RNA, comprendiendo que aun mayor número de iteraciones le corresponde un mejor análisis de los valores; el siguiente factor que se tuvo en consideración fue el “coeficiente de correlación” pues determina que tan precisa es la predicción generada por la RNA. Para obtener mejores resultados se puede variar: la cantidad de capas, de neuronas o el algoritmo de entrenamiento, esto mediante prueba y error.

TABLA 11
RESULTADO DE LAS PREDICIONES REALIZADAS POR LA RED NEURONAL EN LA PARTIDA “NIVELACIÓN Y COMPACTACIÓN DE SUBRASANTE CON EQUIPO LIVIANO O MANUAL”

Obra	Productividad real (m2/día)	Productividad programada (m2/día)	Productividad predicha por la RNA (m2/día)
IND	189.37	177.54	178.56
SOL	182.45	193.86	176.25
ESP	182.43	195.46	190.55
CNP	142.41	170.89	143.57
SAN	128.08	129.10	127.07




Fig. 4 Comparación de la diferencia de los valores de productividad real (PR) con la productividad programada (PP) y la productividad predicha (PRNA) para la partida “Nivelación y compactación a nivel de subrasante con equipo liviano o manual”.

Para medir la precisión de las predicciones de las RNAs creadas con respecto a los valores reales obtenidos de campo

se generaron las comparaciones de los resultados en las figuras 3, 4, 5 y 6 las cuales presentan una recta de color azul (Diferencia PR-PRNA) que muestra el error de la predicción del modelo de RNA en comparación con el valor medido en campo; y otra recta de color rojo (Diferencia PR-PP) que describe el error de la productividad programada de manera tradicional en comparación con el valor real; presentando diferencias significativas en donde las RNAs brindan valores más cercanos a la realidad en comparación al método de programación tradicional.

TABLA 12
RESULTADO DE LAS PREDICIONES REALIZADAS POR LA RED NEURONAL EN LA PARTIDA “CONFORMACIÓN DE BASE GRANULAR”

Obra	Productividad real (m2/día)	Productividad programada (m2/día)	Productividad predicha por la RNA (m2/día)
IND	407.50	414.29	410.05
SOL	775.43	1033.90	868.49
ESP	1094.58	1368.22	1088.39
CNP	712.04	949.38	728.52
SAN	1478.73	1626.60	1410.43




Fig. 5 Comparación de la diferencia de los valores de productividad real (PR) con la productividad programada (PP) y la productividad predicha (PRNA) para la partida “Conformación de base granular”.

De la tabla 10 podemos interpretar la eficacia del modelo de RNA creado para la partida de “Corte manual a nivel de subrasante” pues la variación de lo predicho por la Red Neuronal va desde -3.75 % hasta 1.85%, mientras que el método tradicional llega a estimar la productividad con errores de -12.00% hasta 16.67%. Las tablas 11, 12 y 13 reafirman lo mostrado en la tabla 10 haciendo notorio que la RNA puede predecir la productividad laboral con alta precisión.

TABLA 13
RESULTADO DE LAS PREDICIONES REALIZADAS POR LA RED NEURONAL EN LA PARTIDA “CONCRETO EN VEREDAS”

Obra	Productividad real (m2/día)	Productividad programada (m2/día)	Productividad predicha por la RNA (m2/día)
IND	254.69	230.43	267.78
SOL	140.04	149.37	142.81
ESP	343.90	286.58	299.89
CNP	373.05	559.58	337.85
SAN	198.58	190.30	201.14

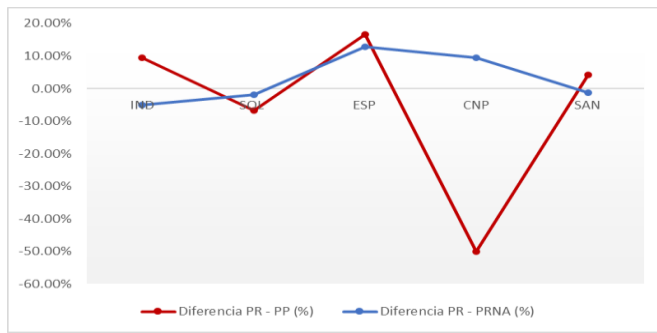


Fig. 6 Comparación de la diferencia de los valores de productividad real (PR) con la productividad programada (PP) y la productividad predicha (PRNA) para la partida “Concreto en veredas”.

Para llegar a los modelos de predicción finales fue necesario crear 28 RNAs, debido a que se determinaron los algoritmos de entrenamiento y número de redes neuronales en la capa oculta que presentaban errores menores. El algoritmo elegido fue “Bayesian Regularization” porque al contar con una sola capa oculta se debía evaluar los pesos que se iban a asignar a las neuronas y este algoritmo optimiza la determinación de los pesos debido a sus perceptores multicapa, obteniendo resultados cercanos a los valores reales el mismo resultado fue hallado por la referencia [3] en 2015 con el desarrollo de su investigación, puesto que trabajaron con un conjunto de datos reducido, para el entrenamiento de su RNA.

La RNA de la partida “Concreto en veredas” presenta un valor de correlación de 99.37%, lo que nos conduce a indicar que al tratarse de un nivel elevado de correlación los factores seleccionados para el estudio se consideran influyentes en el desarrollo de la partida y pueden utilizarse para la predicción de la productividad laboral.

Durante la etapa de validación se observó la notable capacidad de las RNAs al predecir la productividad en comparación con los métodos tradicionales. Como en la partida “Nivelación y compactación de subrasante con equipo liviano o manual” para la obra “CNP” la RNA obtuvo un error de -0.81%, mientras que el método tradicional un -20.00% de error. En general, las redes neuronales artificiales convergieron adecuadamente y tienen capacidades de estimación razonables [9] [4] [26].

La referencia [10] “Construction Productivity Estimation Model Using Artificial Neural Network for Foundations Works in Gaza Strip Construction Sites”, se estimó la productividad laboral para trabajos de concreto en zapatas considerando el avance por día en metros cúbicos, obteniendo un coeficiente de correlación de 99.70% sin observarse diferencias significativas entre los resultados predichos y el valor real; en el presente estudio con la partida de “Concreto en veredas” el coeficiente de correlación entre los factores de entrada y de salida de 99.73%, lo que lleva a comprender que

al realizar una prueba de algoritmos adecuada junto con una evaluación del número de neuronas y capas, las RNAs se pueden comportar de manera similar al estudio [10] y brindar resultados aproximados a los reales [26].

IV. CONCLUSIONES

- Los modelos de RNA generados en el estudio predicen la productividad laboral en obras viales para las partidas de: Corte manual a nivel de subrasante, Nivelación y compactación de subrasante con equipo liviano o manual, Conformación de base granular y Concreto en veredas, con valores de correlación entre los inputs y outputs de 96%, 97%, 97% y 99% respectivamente. Motivando al uso de RNAs en la estimación de valores o factores en la Ingeniería Civil.
- Mediante la revisión sistemática realizada se establecieron los factores de mayor incidencia en la productividad laboral y aquellos que sean medibles para el estudio, obteniendo: escala de altura, relación “oficiales/peones”, nivel de motivación, rendimiento programado, metrado, duración programada espesor base granular, espesor vereda y resistencia del concreto; sin embargo, se demostró que pueden variar de acuerdo a la partida de estudio y factores del proyecto, no obstante, el modelo creado presenta una gran flexibilidad permitiendo el ingreso de nuevos factores influyentes a su estructura para aumentar el nivel de predicción.
- El algoritmo de “Bayesian Regularization” utilizado para la generación de las RNAs es el que presenta un mayor factor de correlación para las partidas del estudio.
- En el proceso de validación de las RNAs creadas se utilizaron 5 obras en donde los modelos generados lograron predecir la productividad laboral con mayor eficacia y precisión que los métodos tradicionales.

REFERENCES

- [1] J. Silva, J. Hennings, and V. Echevarria, “Análisis Macroeconómico del Sector Construcción en el Perú,” *Quipukamayoc*, vol. 25, no. 47, pp. 95-100, Agosto 2017.
- [2] F. Álvarez, M. Eslava, P. Sanguinetti, M. Toledo, G. Alves, C. Daude, and L. Allub, “Instituciones para la productividad: hacia un mejor entorno empresarial,” *RED 2018*, no. 1343, pp. 1-30, Noviembre 2018.
- [3] G. Heravi and E. Eslamdoost, “Applying Artificial Neural Networks for Measuring and Predicting Construction-Labor Productivity,” *Journal of Construction Engineering and Management*, vol. 141, pp. 04015032, Mayo 2015.
- [4] L. Song and A. Simaan, “Measuring and Modeling Labor Productivity Using Historical Data,” *Journal of Construction Engineering and Management*, vol. 134, no. 10, pp. 786-794, Octubre 2008.
- [5] K. Gafel, “Productivity Estimation Model for Bracklayer in Construction Projects Using Neural Network,” *Al-Qadisiyah Journal For Engineering Sciences*, vol. 9, no 2, pp. 183-199, Enero 2018.
- [6] M. Al-Zwainy, H. Rasheed, and H. Ibraheem, “Development of the Construction Productivity Estimation Model Using Artificial Neural Network for Finishing Works for Floors with Marble,” *ARNP Journal of Engineering and Applied Sciences*, vol. 7, no. 6, pp. 714-722, Junio 2012.
- [7] M. Abambres, K. Rajana, K. Tsavdaridis, and T. Ribeiro, “Neural Network-Based Formula for the Buckling Load Prediction of I-Section Cellular Steel Beams,” *Computers*, vol. 8, no. 1, p. 2, Diciembre 2018.

- [8] A. Dantas, M. Batista Leite, and K. de Jesus Nagahama, "Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks," *Construction and Building Materials*, vol. 38, no. 26, pp. 717-722, Setiembre 2013.
- [9] A. Ezeldin, and L. Sharara, "Neural networks for estimating the productivity of concreting activities," *Journal of Construction Engineering and Management*, vol. 132, pp. 650-656, Junio 2006.
- [10] E. Haddad, "Construction Productivity Estimation Model Using Artificial Neural Network for Foundations Works in Gaza Strip Construction Sites," *International Journal of Advanced Engineering Research and Science*, vol. 4, no. 7, pp. 50-62, Enero 2017.
- [11] E. Serna, E. Acevedo and A. Serna, "Principios y características de las redes neuronales artificiales," *Desarrollo e Innovación en Ingeniería*, 2nd. ed. Instituto Antioqueño de Investigación, 2017, pp. 173-182.
- [12] S. Ebragimi, "Developing Hybrid Intelligence Model for Construction Labour Productivity Prediction and Optimization," M.S. thesis, University of Alberta, 2021.
- [13] K. El-Gohary, R. Aziz, and H. Abdel-Khalek, "Engineering Approach Using ANN to Improve and Predict Construction Labor Productivity under Different Influences," *Journal of Construction Engineering and Management*, vol. 143, pp. 04017045, Agosto 2017.
- [14] L. Gonzáles, "Herramientas avanzadas de análisis de datos de aplicación en ingeniería civil," M.S. thesis, Universidad de Santander, 2017.
- [15] M. Lazarevska, M. Knezevic, M. Cvetkovska, and A. Trombeva-Gavriloska, "Application of artificial neural networks in civil engineering," *Tehnicki Vjesnik*, vol. 21, no. 6, pp. 1353-1359, Diciembre 2014.
- [16] F. Mirahadi, and T. Zayed, "Simulation-based construction productivity forecast using Neural-Network-Driven Fuzzy Reasoning," *Autom Constr.*, vol. 65, no. 10, pp. 102-115, Enero 2016.
- [17] S. Muqeem, M. Idrus, and F. Khamidi, "Construction labor production rates modeling using artificial neural network," *Journal of Information Technology in Construction*, vol. 16, no. 42, pp. 713-726, Junio 2011.
- [18] J. Rabuña, "Uso de técnicas de inteligencia artificial en ingeniería civil," Lic. thesis, Universidad de Coruña, España, 2008.
- [19] H. Salehi, and R. Burgueño, "Emerging artificial intelligence methods in structural engineering," *Engineering Structures*, vol. 171, pp. 170 - 189, Setiembre 2018.
- [20] M. Villegas, "Aplicación de redes neuronales para la predicción de la resistencia a la compresión del concreto según el ensayo de Esclerometría," Lic. thesis, Universidad de Peruana de Ciencias Aplicadas, Perú, 2019.
- [21] M. Díaz, "Uso de las redes neuronales artificiales en el modelado del ensayo de resistencia a compresión de concreto de construcción según la norma ASTM C39/C 39M", Lic. thesis, Universidad Nacional de Cajamarca, Perú, 2017.
- [22] H. Demuth, M. Beale, and M. Hagan, "Neural network toolbox 6 user's guide," *MathWorks, Natick, MA*, 2009.
- [23] R. Hernández, C. Fernández and P. Baptista, *Metodología de la Investigación*, 6ta, México, ed. Mc Graw Hill, 2014.
- [24] D. Matich. "Redes Neuronales: Conceptos Básicos y Aplicaciones," *Universidad Tecnológica Nacional - Facultad Regional Rosario Departamento de Ingeniería Química Grupo de Investigación Aplicada a la Ingeniería Química (GIAIQ)*, 2001.
- [25] M. Tamayo, *El proceso de la investigación científica.*, 4ta, México, ed. Limusa, 2003.
- [26] B. Murga, D. Luna "Nivel de Predicción de la Productividad Laboral en el Sector Construcción Utilizando un Modelo de Red Neuronal Artificial, Cajamarca 2022", Lic. thesis, Universidad Privada del Norte, Perú, 2022.