

Desarrollo de un modelo predictivo de las propiedades mecánicas del suelo usando redes neuronales artificiales

Development predictive model of the mechanical properties of soil using artificial neural networks

Frank Jesús Valderrama-Purizaca*, **Heber Ivan Mejía-Cabrera****,
Sócrates Pedro Muñoz Pérez***, **Víctor A. Tuesta-Monteza******

(Recibido el 18-07-2021. Aprobado el 30-08-2021. Publicado 24-11-2021)

Estilo de citación de artículo:

F. J. Valderrama-Purizaca, H. I. Mejía-Cabrera, S. P. Muñoz Pérez y V. A. Tuesta-Monteza, "Desarrollo de un modelo predictivo de las propiedades mecánicas del suelo usando redes neuronales artificiales", *Lámpsakos*, no. 26, pp. 1-20, 2021. DOI: 10.21501/21454086.4042

Resumen

Determinar las propiedades del suelo es una tarea necesaria pero costosa en el diseño de pavimentos, por dicha razón, en este estudio se desarrollaron cuatro redes neuronales artificiales (RNA) basadas en perceptrón multicapa para predecir la máxima densidad seca (MDD), el óptimo contenido de humedad (OMC), el valor de la relación de soporte de California (CBR) al 95% de la MDD y el CBR al 100% de la MDD, respectivamente. El método considera un dataset con 285 ejemplos, definición de arquitectura base mediante optimización bayesiana y validación cruzada, modificación de la arquitectura y los hiperparámetros para mejorar el desempeño. Las RNA se entrenaron considerando 3000 épocas, función ReLU, tasa de aprendizaje, dropout; fueron evaluadas con el coeficiente de correlación (R) y el error cuadrático medio (MSE) y predijeron la MDD con $R=0,90$, OMC con $R=0,87$, CBR al 95% con $R=0,92$, CBR al 100% con $R=0,89$, respectivamente, demostrando que los modelos son eficientes para predecir las propiedades del suelo.

Palabras clave:

Redes neuronales; Perceptrones multicapa; Neuronas prealimentadas; Propiedades del suelo; Humedad del suelo; Métodos de predicción; Modelos de predicción; Inteligencia artificial; Carreteras; Ingeniería civil.

* Ingeniero civil, Universidad Señor de Sipán, Pimentel-Perú. Contacto: vpurizacafrankj@crece.uss.edu.pe, <https://orcid.org/0000-0002-2701-1151>

** Maestro en ingeniería de sistemas con mención en gerencia de tecnologías de la información y gestión del software, Universidad Señor de Sipán, Pimentel-Perú. Contacto: hmejiaac@crece.uss.edu.pe, <https://orcid.org/0000-0002-0007-0928>

*** Doctor en Gestión Pública y Gobernabilidad, Universidad Señor de Sipán, Pimentel-Perú. Contacto: msocrates@crece.uss.edu.pe, <https://0000-0003-3182-8735>

**** Magíster en administración de negocios, Universidad Señor de Sipán, Pimentel-Perú. Contacto: vtuesta@crece.uss.edu.pe, <https://orcid.org/0000-0002-5913-990X>

Abstract

Determining soil properties is important in pavement design, for this reason, 4 artificial neural networks based on multilayer Perceptron were developed in this study to predict the maximum dry density (MDD), optimum moisture content (OMC), California bearing ratio (CBR) at 95 % MDD and CBR at 100 % MDD respectively. The method considers a dataset with 285 examples, definition of base architecture through Bayesian optimization and cross-validation, modification of the architecture and hyperparameters to improve performance. The models were trained considering 3000 epochs, RELU function, learning rate, dropout, and were evaluated using the Correlation Coefficient (R) and Mean Squared Error (MSE). MDD was predicted with $R=0,90$, OMC with $R=0,87$, CBR at 95% with $R=0,92$, CBR at 100% with $R=0,89$ respectively, showing that the models are efficient in predicting soil properties.

Keywords:

Neural networks; Multilayer perceptrons; Feedforward neural; Soil properties; Soil moisture; Prediction methods; Predictive models; Artificial intelligence; Roads; Civil engineering.

DOI: <https://doi.org/10.21501/21454086.4042>

1. INTRODUCCIÓN

Para que un país pueda prosperar debe contar con adecuadas infraestructuras y redes de carreteras, por ende, las naciones invierten en vías de comunicación para asegurar su desarrollo, por ejemplo, Camerún invierte el 28% de los fondos que recibe del Banco Mundial en el sector transporte [1]. En contraste, en el Perú, el sector construcción disminuyó en 67,2% debido a la disminución de la actividad productiva por efectos de la pandemia [2]. Si bien la inversión en obras viales es importante, de igual modo lo es la calidad del diseño del pavimento. Se entiende por pavimento a toda la estructura de la vía, desde las capas inferiores hasta la capa de asfalto o concreto, sobre la que rueda el tránsito, por ello se deben tomar en cuenta asuntos como el volumen del tráfico, el uso que tendrá la vía, el tipo de vehículo que transitará y, sobre todo, tener un conocimiento profundo de los factores que rigen el comportamiento del suelo debido a que este no es uniforme [3]. Por consiguiente, el estudio del suelo es indispensable para garantizar la vida útil del pavimento, puesto que permite conocer las propiedades del suelo y determinar su comportamiento, en caso contrario se construirán carreteras que más tarde presentarán problemas como hundimientos y daños a la capa asfáltica [4].

El estudio del suelo comprende el análisis de características físicas como: a) la granulometría, b) el contenido de humedad, c) los límites de consistencia; propiedades mecánicas como: d) el valor de la relación de soporte de California (CBR); y aquellas que ayudan a mejorar las propiedades del suelo como, (e) la compactación [5].

La granulometría mide la distribución (en porcentaje) del tamaño de las partículas, para ello, el ensayo de análisis granulométrico determina esta característica haciendo pasar una muestra de suelo por una sucesión de tamices que retienen una cantidad de suelo [3].

Los límites de consistencia o límites de Atterberg (propuestos a principios del siglo XX) definen el estado mecánico del suelo y su capacidad para soportar cargas externas [6], [7]. Para este propósito se requiere realizar varias mediciones; en la Fig. 1 se muestran como

los límites ayudan a conocer la respuesta del suelo en función de su contenido de humedad y se considera: el límite líquido (LL), que se realiza para evaluar la cantidad de humedad necesaria para que el suelo cambie de un estado semilíquido a uno plástico; el límite plástico (PL), que se realiza para hallar la cantidad de humedad necesaria para convertir el estado del suelo de plástico a semisólido; el límite de contracción (SL), que se requiere para hallar el contenido de humedad de manera que el suelo cambie de semisólido a sólido; y el índice de plasticidad (IP), que se calcula como la diferencia entre el LL y el PL [3].

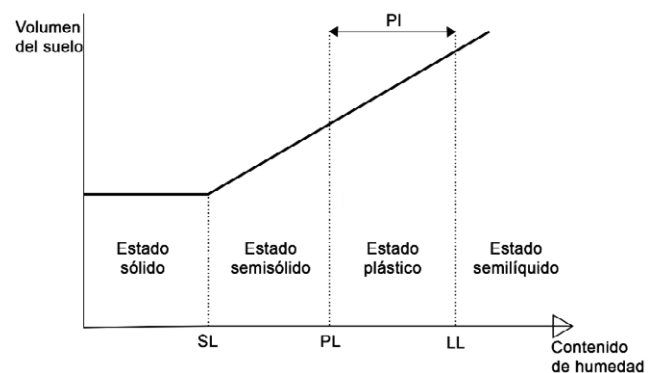


Fig. 1 Límites de consistencia del suelo o límites de Atterberg.

El CBR se usa para calcular la resistencia característica de la subrasante, la misma que sirve para determinar los requisitos mínimos del pavimento y evaluar si el material a usar es el adecuado [1], [8-11]. En específico, el ensayo de CBR se usa para determinar el espesor de los pavimentos flexibles [12], evaluar la capacidad portante y la resistencia a la deformación de la subrasante, la subbase, los materiales de base, así como, los materiales reciclados usados en los pavimentos [13]. Es importante mencionar que cualquier cambio en el contenido de humedad puede tener un impacto en la capacidad portante del suelo [14]. En efecto, cuando un suelo carece de capacidad portante, el valor del CBR será bajo y viceversa [15]. Si bien es cierto que el ensayo de CBR es aceptado para el diseño de pavimentos, no siempre es posible elaborarlo [9], debido al tiempo que requiere su realización (aproximadamente 4 días) [11], [16], el costo (135 dólares en promedio) [17] y la poca disposición de tiempo y limitaciones económicas

en etapas previas al proyecto [18]. Frente a esta situación lo que normalmente se realiza en los proyectos es calcular un valor estimado representativo de CBR para diseñar el pavimento [19].

Y la compactación es una propiedad vinculada a la resistencia del suelo y se produce cuando la cantidad de aire en el suelo disminuye [3]. Esta densificación del suelo mejora las características físicas y mecánicas del suelo, trayendo como consecuencia el aumento de su capacidad de carga [20], [21]. Para esto se requiere un ensayo de Proctor con el que se obtienen dos parámetros de compactación: (1) la máxima densidad seca (MDD), que es el estado del suelo cuando alcanza su punto máximo de densificación [22] y (2) el óptimo contenido de humedad (OMC), que es la cantidad de agua necesaria para alcanzar la máxima densidad seca [23].

Por otra parte, las redes neuronales artificiales (RNA) se han aplicado como métodos de predicción para estimar el CBR (con un coeficiente de correlación, $R = 0,998$) [24], [25] y los parámetros de compactación del suelo [26], [27]. Con resultados similares, se han usado RNA para predecir el CBR de suelos estabilizados con desechos industriales [28], suelos compactados [29], arenas limosas estabilizadas con micro sílice y cal [30], arenas del Egeo [31] y cenizas estabilizadas con cal [32], además, su aplicación también es posible en otras disciplinas de la ingeniería civil [33]. En contraste, se usan métodos numéricos para investigar la relación entre las propiedades del suelo [34] y desarrollar ecuaciones de regresión [35]; sin embargo, debido a las variaciones de las propiedades del suelo, los métodos numéricos requieren de parámetros complejos de obtener [4], [20], los mismos que están propensos a incertidumbre [26]. A diferencia de los métodos convencionales, las RNA brindan resultados en menos tiempo [36] y tienen la ventaja de ser modelos de predicción con capacidad de aprender y mejorar [37].

Las RNA, también conocidas como redes prealimentadas, están inspiradas en el funcionamiento de la neurona biológica, es decir, una RNA está formada por unidades de procesamiento (neuronas artificiales) conectadas por coeficientes (pesos) [38]. Dos tipos

de RNA son frecuentes: (a) el perceptrón, que se destaca por su simplicidad, creado por Frank Rosenblatt en 1958, y (b) el perceptrón multicapa, que es una de las RNA más utilizadas y está formado por tres partes: una capa de entrada, una o más ocultas y una de salida [39] – [42]. Se debe agregar que, entre los componentes del perceptrón multicapa están las funciones de transferencia, de pérdida y de activación [43], [44].

En definitiva, las diversas investigaciones realizadas en varios países son una buena referencia para predecir las propiedades del suelo usando RNA. Sin embargo, los suelos tienen características diferentes en cada latitud del planeta, por consiguiente, se requiere de estudios específicos para afirmar que las RNA también pueden usarse para predecir propiedades de los suelos peruanos. Debido a que no se encontraron publicaciones científicas sobre la predicción del CBR y los parámetros de compactación usando RNA para suelos peruanos, el objetivo de esta investigación es desarrollar un modelo predictivo de las propiedades del suelo usando RNA del tipo perceptrón multicapa, con el propósito de buscar predecir de forma individual: (1) el CBR al 100% de la MDD, (2) el CBR al 95% de la MDD, (3) la MDD y (4) el OMC usando como variables de entrada propiedades como el contenido de humedad, el contenido de sales, la granulometría y los límites de consistencia. Asimismo, en este documento se detalla la preparación del conjunto de datos, el proceso de construcción de la arquitectura de las RNA, las pruebas para ajustar los parámetros; a fin de lograr los mejores resultados de estimación de las variables.

2. METODOLOGÍA

El proceso general seguido en esta investigación se muestra en la Fig. 2. Por lo que se refiere al conjunto de datos, estuvo compuesto por 285 muestras de suelo pertenecientes a expedientes técnicos de obras de carreteras peruanas [45]. Para la implementación de las RNA se empleó el lenguaje de programación Python v.3.8.8 junto a las librerías Keras v.2.4.3 y Tensor Flow v.2.3.1. Se usaron las librerías Pandas v.1.1.4 y Matplotlib v.3.3.3 para manipular y graficar los datos. Se

DOI: <https://doi.org/10.21501/21454086.4042>

utilizó Scikit-learn v.0.23.2 para la implementación de la optimización bayesiana. El programa fue ejecutado en un computador con CPU Intel(R) Core(TM), i3-5005U 2.00GHz x 4 de 64 bits y 4GB de RAM en el entorno Windows 10.

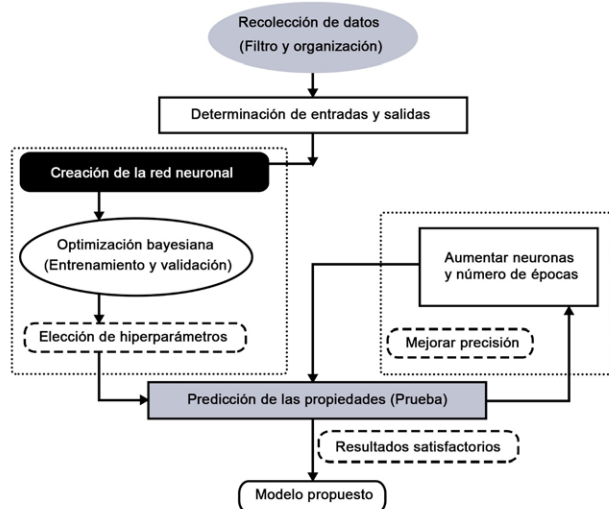


Fig. 2. Proceso para el desarrollo de modelos de RNA para la estimación de propiedades de suelo.

Construcción del conjunto de datos

Se recopilaron 285 muestras de suelo de expedientes técnicos que incluían los resultados de los ensayos de laboratorio de mecánica de suelos. Los expedientes fueron descargados del Sistema Electrónico de Contrataciones del Estado Peruano (SEACE) [45] y corresponden a proyectos de pavimentación realizados en las provincias de Chiclayo, Ferreñafe y Lambayeque. Ahora bien, se consideraron nueve expedientes técnicos de obras que ingresaron al proceso de licitación en el año 2019, veintiséis expedientes del año 2020 y un expediente técnico del año 2021.

Con respecto al proceso de selección, se incluyeron aquellas muestras de suelo con resultados de los siguientes ensayos de laboratorio: (a) contenido de humedad, (b) contenido de sales, (c) granulometría, (d) límites de consistencia, (e) clasificación SUCS y

AASTHO, (f) compactación y (g) CBR; se excluyeron las muestras de suelo de proyectos que no correspondían a obras de carreteras.

Entradas y salidas de los modelos

Es necesario subrayar que durante los ensayos de laboratorio se obtuvieron en total 12 variables, así: una variable del contenido de humedad, una variable del contenido de sales, tres variables de la granulometría (grava, arena y finos), tres variables de los límites de consistencia (límite líquido, límite plástico e índice de plasticidad), dos variables de la compactación (MDD y OMC) y dos variables del CBR (CBR al 95% y CBR al 100%). Las 12 variables fueron analizadas para ser usadas como entradas de las RNA y se descartaron las variables de la clasificación SUCS y AASTHO por ser poco significativas para la estimación.

Con respecto a las salidas, los cuatro modelos propuestos de RNA se desarrollaron para predecir: (1) el CBR al 100% de la MDD, (2) el CBR al 95% de la MDD, (3) la MDD y (4) el OMC. Como se puede observar, se propone estimar un único valor en cada modelo, similar a una regresión, por lo que se tiene una sola neurona en la capa de salida [46].

Cada predicción requiere un diseño de RNA, por ello se usaron 8 variables de entrada para predecir la MDD y el OMC, a saber, el contenido de humedad (H), el contenido de sales (S), el contenido de grava (G), el contenido de arena (A), el contenido de finos (F), el límite líquido (LL), el límite plástico (PL) y el índice de plasticidad (PI). La arquitectura requerida se muestra en la Fig. 3.

En cambio, para predecir el CBR al 100% de la MDD y el CBR al 95% de la MDD, en una primera instancia se utilizaron las ocho variables de entrada que se observan en la Fig. 3, y en un segundo momento fueron agregados dos nuevas variables, la MDD y el OMC, obtenidos de los expedientes técnicos, calculando un total de 10 variables, como se muestra en la Fig. 4.




Fig. 3. Estructura base de las RNA usando 8 variables de entrada.




Fig. 4. Estructura base de las RNA usando 10 variables de entrada.

Para determinar si una variable era usada como entrada o salida del modelo, se revisaron diez estudios previos [24]–[32], [47] y se siguió lo indicado en [48], donde se señala que el número de variables de entrada se decide en función del número de características del conjunto de datos.

División del conjunto de datos

Para el presente trabajo, los modelos de RNA se construyeron usando la librería Keras. Para el entrenamiento, se seleccionó al azar un conjunto equivalente al 80% del total de ejemplos; mientras que para la prueba, el 20% de los ejemplos, siguiendo el principio de Pareto.

Además, se utilizó la prueba U de Mann Whitney para comparar los conjuntos de entrenamiento y prueba, con el fin de garantizar que ambos fueran representativos con base en las propuestas de [44], [49]–[51]. Al final se demostró que existía semejanza significativa entre los conjuntos de entrenamiento y prueba con una confiabilidad del 99%.

Optimización bayesiana

En primer lugar, antes de realizar el entrenamiento de las RNA, se realizó ingeniería de atributos como el escalamiento de datos en sus valores máximos y mínimos, basados en [44], [46], [51]. En segundo lugar, se estableció un rango de búsqueda de hiperparámetros para la optimización bayesiana. Estos rangos se crearon de acuerdo con las recomendaciones obtenidas durante la revisión de la literatura. En la Tabla 1 se puede observar el rango de búsqueda para cada hiperparámetro y la referencia consultada.

Tabla 1. Rango de búsqueda de hiperparámetros

Hiperparámetro	Rango	Estudio
Capas ocultas	1 a 6	[44], [52], [53]
Neuronas por capa oculta	1 a 20	[48]
Función de activación	ReLU	[44], [46], [54]–[57]
Función de salida	Lineal	[54]–[56], [58]–[60]
Tasa de aprendizaje	0,000001 a 1	[61], [62]
Optimizador	Adam	[63], [64]
Épocas	100 a 1500	[65], [70]
Tamaño de lote	16, 32, 64, y 128	[66], [71]
Dropout	0 a 0,5	[72]

En tercer lugar, se aplicó la optimización bayesiana [73], [74] y la validación cruzada, con $K = 10$ durante tres repeticiones [44], [49], [51]. Es necesario recalcar que la optimización bayesiana entrena un número “n” de modelos (iteraciones) usando y probando valores, elegidos al azar, dentro del rango de búsqueda establecido para cada hiperparámetro; al finalizar se obtiene el ranking de cada modelo según su precisión y los hiperparámetros usados [73], [74]. En el presente estudio se realizaron 100 iteraciones por modelo, como se muestra en la Tabla 2. Se obtuvieron 2 modelos para predecir

DOI: <https://doi.org/10.21501/21454086.4042>

el CBR al 100% de la MDD (nombrados como MARK 1 y MARK 3), 2 modelos para predecir el CBR al 95% de la MDD (nombrados como MARK 2 y MARK 4), 1 modelo para predecir la MDD (nombrado como MARK 5) y 1 modelo para predecir el OMC (nombrado como MARK 6). Se debe recordar que para predecir el CBR se diseñó una RNA con 8 variables y otra con 10 variables de entrada. La elección del mejor modelo se hizo en función del error cuadrático medio (MSE) [49].

Tabla 2. Mejores modelos obtenidos después de la aplicación de la optimización bayesiana

RNA	Salida	Entradas	Iteraciones
MARK 1	CBR al 100 % de la MDD	8	100
MARK 2	CBR al 95 % de la MDD	8	100
MARK 3	CBR al 100 % de la MDD	10	100
MARK 4	CBR al 95 % de la MDD	10	100
MARK 5	MDD	8	100
MARK 6	OMC	8	100

Predicción de las propiedades del suelo

Los modelos de RNA, considerados en la Tabla 2, se entrenaron utilizando los mejores hiperparámetros conseguidos con la optimización bayesiana y todo el conjunto de datos, previamente separado en entrenamiento y prueba. Luego, utilizando el conjunto de prueba se obtuvo la precisión del modelo. Según la precisión lograda, se seleccionó el modelo que pasaría a una segunda prueba, en la cual fue ajustado en busca de una mejor precisión.

Segunda prueba: mejora de los modelos

De los modelos MARK 1 y MARK 3 se seleccionó al que tuvo mejor precisión para predecir el CBR al 100% de la MDD. De los modelos MARK 2 y MARK 4 se seleccionó al que mejor predijo el CBR al 95% de la MDD. Se seleccionó el MARK 5 para predecir la MDD y el modelo

MARK 6 para el OMC (ver Tabla 3). A continuación, los modelos seleccionados se utilizaron como modelos base para entrenar cuatro modelos más, por propiedad, para buscar una mejora en la precisión. Para ello, se aumentó el número de épocas y el número de neuronas en cada capa oculta.

Finalmente, entre el modelo base y los cuatro modelos, se seleccionó al modelo con mayor precisión. De esta manera, se propone un modelo de RNA con mejor desempeño para cada propiedad a predecir.

Análisis estadístico

Para comparar los conjuntos de entrenamiento y prueba, se realizó un análisis estadístico mediante la prueba de Mann-Whitney con RStudio. Igualmente, el rendimiento de los modelos creados se evaluó mediante la correlación de Pearson (R), para comparar los datos estimados con los reales.

3. DESARROLLO

Predicción del CBR al 100% de la MDD

Según los resultados de la optimización bayesiana, con respecto a las 100 primeras iteraciones, el modelo de la iteración dos, MARK 1, es el mejor usando 8 variables de entrada. Con respecto a las otras 100 iteraciones, el modelo de la iteración ochenta y dos, MARK 3, es el mejor usando 10 variables de entrada. Ambos modelos utilizan un valor para cada hiperparámetro dentro de los rangos de búsqueda ya mencionados. La lista de hiperparámetros óptimos de ambos modelos se muestran en la Tabla 3.

Tabla 3. Hiperparámetros utilizados en los modelos de RNA para predecir el CBR al 100% de la MDD

Hiperparámetros	MARK 1	MARK 3	MARK 7	MARK 8	MARK 9	MARK 10
Neuronas de entrada	8	10	8	8	8	8
Neuronas de salida	1	1	1	1	1	1
Capas ocultas	2	1	2	2	2	2
Neuronas ocultas	23	16	23	60	80	120
Arquitectura	8-5-18-1	10-16-1	8-5-18-1	8-30-30-1	8-40-40-1	8-60-60-1
Función de activación	ReLU	ReLU	ReLU	ReLU	ReLU	ReLU
Tasa de aprendizaje	0,0004	0,001	0,0004	0,0004	0,0004	0,0004
Optimizador	Adam	Adam	Adam	Adam	Adam	Adam
Número de épocas	820	235	3000	3000	3000	3000
Tamaño de lote	16	32	16	16	16	16
Dropout	0,2	0,3	0,2	0,2	0,2	0,2
Precisión (R)	0,8739	0,8313	0,8768	0,8863	0,8844	0,8754

En la Tabla 4 se muestra que el modelo MARK 1 tiene mejor rendimiento en comparación con el modelo MARK 3, por esta razón, se tomó el primero como base para entrenar cuatro modelos más, con el fin de mejorar la precisión de las predicciones. Los siguientes cuatro modelos (MARK 7, MARK 8, MARK 9 y MARK 10) se entrenaron usando los mismos hiperparámetros del modelo MARK 1, pero ampliando el número de épocas a 3000 y el número de neuronas por capa oculta, como se muestra en la Tabla 3. Según los resultados, hay correlaciones entre 0,75 interpretadas como “considerables” y 0,90 como “muy fuertes” [75] entre los valores reales de CBR y los valores predichos. En general, el orden de los modelos desarrollados, de mayor a menor, según su precisión es: (1) MARK 8, (2) MARK 9, (3) MARK 7, (4) MARK 10, (5) MARK 1 y (6) MARK 3.

Tabla 4. Rendimiento de los modelos al predecir el CBR al 100% de la MDD

RNA	Arquitectura	MSE (%)	MAE (%)	R
MARK 1	8-5-18-1	22,13	3,27	0,8739
MARK 3	10-16-1	29,41	4,05	0,8313
MARK 7	8-5-18-1	31,90	3,41	0,8768
MARK 8	8-30-30-1	21,80	2,79	0,8863
MARK 9	8-40-40-1	20,42	2,79	0,8844
MARK 10	8-60-60-1	22,27	2,79	0,8754

En la Fig. 5 se muestra la comparación entre el modelo MARK 1 y sus cuatro variantes, también se muestra que el número de neuronas ocultas varía de 23 a 120. Según los resultados, el aumento del número de épocas ayuda a mejorar la precisión de la estimación de los modelos de RNA, como es el caso del modelo MARK 7, que predice mejor los valores de CBR, en comparación del modelo MARK 1. De igual manera, el aumento del número de neuronas ocultas y el número de épocas ayudan a mejorar la exactitud de las predicciones, como es el caso del modelo MARK 8. Asimismo, se puede observar que mientras el número de neuronas en cada capa oculta aumenta, la precisión del modelo disminuye; esto se ve reflejado en los modelos MARK 9 y MARK 10, que tienen un menor rendimiento. Si bien es cierto, la precisión de estos últimos modelos disminuyó, en general, los cuatro modelos son mejores que el modelo inicial MARK 1.

DOI: <https://doi.org/10.21501/21454086.4042>

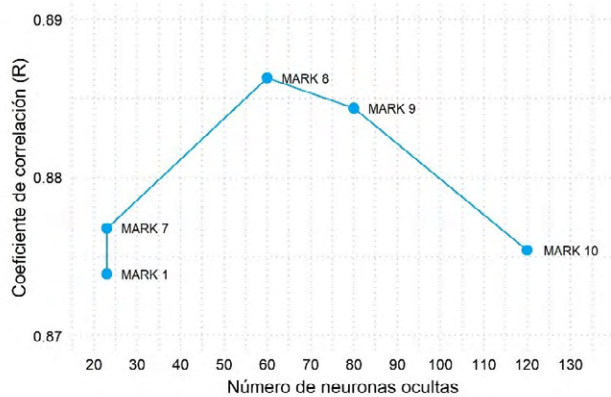


Fig. 5. Precisión de los modelos de RNA para el CBR al 100% de la MDD según el número de neuronas ocultas

Con respecto al número de conexiones que hay entre las neuronas de cada capa y sus sesgos, el número de pesos de los modelos de RNA varía entre 172 y 4261. Estos resultados son importantes porque el consumo de recursos computacionales está en función de la cantidad de conexiones, que en la práctica se almacenan como variables en memoria.

Es importante considerar el tiempo de entrenamiento de los modelos, debido a que si es extenso podría no ser práctico para el uso de estas técnicas. Además, tiene proporción con las cantidades de neuronas, ejemplos del conjunto de datos y parámetros de la red. En la Fig. 6 se muestra el tiempo de entrenamiento de los modelos construidos para predecir el CBR al 100% de la MDD y se corrobora que el modelo MARK 8 tiene los mejores resultados a nivel de precisión y en cuanto a tiempo de entrenamiento, en comparación con las cuatro variantes.

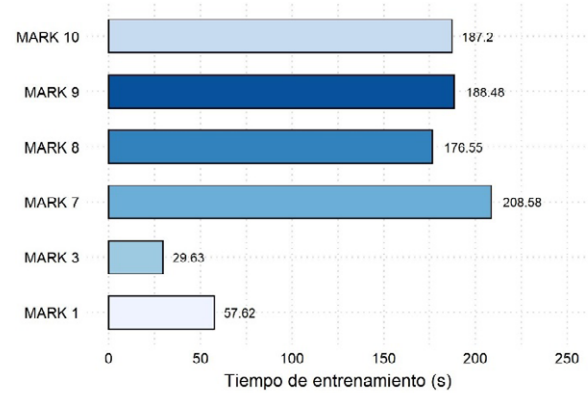


Fig. 6. Tiempo de entrenamiento de los modelos de RNA para predecir el CBR al 100% de la MDD

Predicción del CBR al 95% de la MDD

Según los resultados de la optimización bayesiana, con respecto a las 100 primeras iteraciones, el modelo, de la iteración cuarenta y tres, MARK 2, es el mejor usando 8 variables de entrada. En cuanto a las otras 100 iteraciones, el modelo de la iteración cuarenta y siete, MARK 4, es el mejor modelo usando 10 variables de entrada. De igual manera, ambos modelos de RNA usan un valor para cada hiperparámetro dentro de los rangos de búsqueda ya mencionados. La lista de hiperparámetros óptimos obtenidos luego de aplicar la optimización bayesiana se muestran en la Tabla 5.

Tabla 5. Hiperparámetros utilizados en los modelos de RNA para predecir el CBR al 95% de la MDD

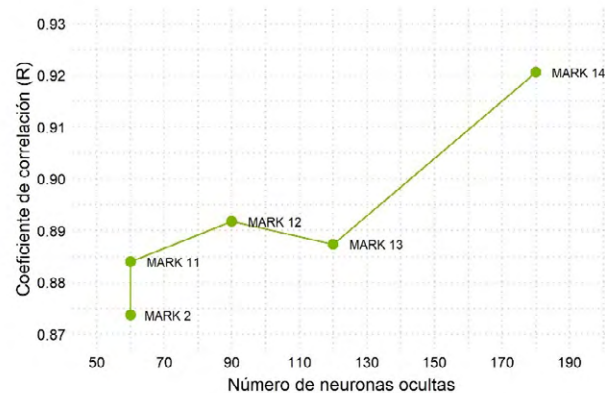
Hiperparámetros	MARK 2	MARK 4	MARK 11	MARK 12	MARK 13	MARK 14
Neuronas de entrada	8	10	8	8	8	8
Neuronas de salida	1	1	1	1	1	1
Capas ocultas	3	3	3	3	3	3
Neuronas ocultas	60	60	60	90	120	180
Arquitectura	8-20-20-20-1	10-20-20-20-1	8-20-20-20-1	8-30-30-30-1	8-40-40-40-1	8-60-60-60-1
Función de activación	ReLU	ReLU	ReLU	ReLU	ReLU	ReLU
Tasa de aprendizaje	0,00004	0,003	0,00004	0,00004	0,00004	0,00004
Optimizador	Adam	Adam	Adam	Adam	Adam	Adam
Número de épocas	1333	100	3000	3000	3000	3000
Tamaño de lote	32	64	32	32	32	32
Dropout	0,1	0,1	0,1	0,1	0,1	0,1
Precisión (R)	0,8737	0,8355	0,8840	0,8918	0,8874	0,9206

En la Tabla 6 se observa que el modelo MARK 2 tiene mejor precisión en comparación con el modelo MARK 4, por esta razón, se tomó el MARK 2 como base para entrenar cuatro modelos más para mejorar la precisión. Es importante mencionar que los cuatro modelos (MARK 11, MARK 12, MARK 13 y MARK 14) se entrenaron usando los mismos hiperparámetros del modelo MARK 2, pero incrementando el número de épocas a 3000 y el número de neuronas en cada capa oculta, como se muestra en la Tabla 5. Según los resultados, existen correlaciones entre 0,75 interpretadas como “considerable” y 0,90 entendidas como “muy fuerte” [75]. En general, el orden de los modelos desarrollados, de mayor a menor, según su precisión es: (1) MARK 14, (2) MARK 12, (3) MARK 13, (4) MARK 11, (5) MARK 2 y (6) MARK 4.

Tabla 6. Rendimiento de los modelos para predecir el CBR al 95% de la MDD

RNA	Arquitectura	MSE (%)	MAE (%)	R
MARK 2	8-20-20-20-1	10,54	2,12	0,8737
MARK 4	10-20-20-20-1	13,23	2,11	0,8355
MARK 11	8-20-20-20-1	13,88	2,21	0,8840
MARK 12	8-30-30-30-1	11,18	2,09	0,8918
MARK 13	8-40-40-40-1	10,60	1,96	0,8874
MARK 14	8-60-60-60-1	6,35	1,65	0,9206

En la Fig. 7 se muestra la comparación entre el modelo MARK 2 y sus cuatro variaciones. También se puede observar que el número de neuronas ocultas varía entre 60 y 180. Según los resultados, el aumento del número de épocas contribuye a mejorar la precisión, como es el caso del modelo MARK 11, que supera al modelo MARK 2. El aumento de las neuronas junto al número de épocas también contribuye a mejorar la precisión, es el caso de los modelos MARK 12, MARK 13 y MARK 14. En general, los cuatro modelos presentan un mejor rendimiento que el modelo inicial, MARK 2, por lo que se pudo mejorar la precisión de las predicciones.

**Fig. 7.** Precisión de los modelos de RNA para el CBR al 95% de la MDD según el número de neuronas ocultas.

DOI: <https://doi.org/10.21501/21454086.4042>

Con respecto al número de conexiones que hay entre las neuronas de cada capa y sus sesgos, varía entre 1041 y 7921 entre los seis modelos de RNA creados.

En la Fig. 8 se muestra el tiempo de entrenamiento de los modelos construidos para predecir el CBR al 95% de la MDD. Además, corrobora que el modelo MARK 14 tiene los mejores resultados a nivel de precisión, sin embargo, debido a su arquitectura, es el que mayor tiempo toma para su entrenamiento.

Predicción de la máxima densidad seca, MDD

Para predecir la MDD se realizaron 100 iteraciones y se utilizó la optimización bayesiana con la finalidad de encontrar los mejores hiperparámetros. Según los resultados, el modelo de la iteración diez, MARK 5, es el mejor usando 8 variables de entrada. La lista de los mejores hiperparámetros se muestra en la Tabla 7.




Fig. 8. Tiempo de entrenamiento de los modelos de RNA para predecir el CBR al 95% de la MDD

Tabla 7. Hiperparámetros utilizados en los modelos de RNA para predecir la MDD

Hiperparámetros	MARK 5	MARK 15	MARK 16	MARK 17	MARK 18
Neuronas de entrada	8	8	8	8	8
Neuronas de salida	1	1	1	1	1
Capas ocultas	4	4	4	4	4
Neuronas ocultas	69	69	120	160	240
Arquitectura	8-15-18-18-18-1	8-15-18-18-18-1	8-30-30-30-30-1	8-40-40-40-40-1	8-60-60-60-60-1
Función de activación	ReLU	ReLU	ReLU	ReLU	ReLU
Tasa de aprendizaje	0,03	0,03	0,03	0,03	0,03
Optimizador	Adam	Adam	Adam	Adam	Adam
Número de épocas	1218	3000	3000	3000	3000
Tamaño de lote	64	64	64	64	64
Dropout	0,0	0,0	0,0	0,0	0,0
Precisión (R)	0,8848	0,7893	0,8216	0,9022	0,8329

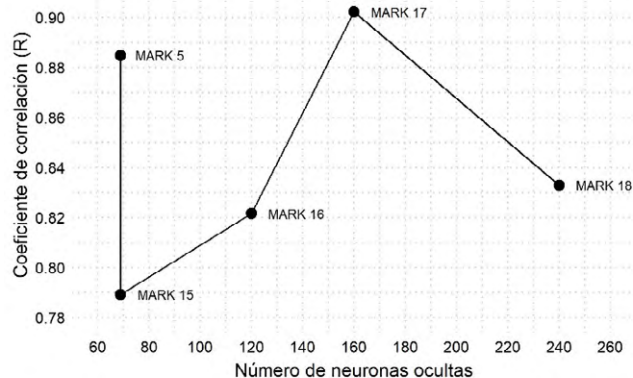
La Tabla 8 muestra el resumen del rendimiento de los modelos desarrollados para predecir la MDD. Asimismo, se tomó el modelo obtenido en la optimización bayesiana, MARK 5, como base para entrenar cuatro modelos más en busca de una mejora de la precisión. Los cuatro modelos (MARK 15, MARK 16, MARK 17 y MARK 18) fueron entrenados utilizando los mismos hiperparámetros del modelo MARK 5, pero aumentando el número de épocas a 3000 y el número de neuronas

en cada capa oculta, como se muestra en la Tabla 7. Los resultados indican correlaciones entre 0,75 interpretadas como “considerables” y 0,90 como “muy fuertes” [75] entre los valores reales de CBR y los valores predichos por los modelos de RNA. En general, el orden de los modelos desarrollados, de mayor a menor, según su precisión es: (1) MARK 17, (2) MARK 5, (3) MARK 18, (4) MARK 16, (5) y MARK 15.

Tabla 8. Rendimiento de los modelos en la etapa de prueba para predecir la MDD


RNA	Arquitectura	MSE (g/cm ³)	MAE (g/cm ³)	R
MARK 5	8-15-18-18-18-1	0,003	0,038	0,8848
MARK 15	8-15-18-18-18-1	0,005	0,050	0,7893
MARK 16	8-30-30-30-30-1	0,005	0,046	0,8216
MARK 17	8-40-40-40-40-1	0,003	0,035	0,9022
MARK 18	8-60-60-60-60-1	0,005	0,043	0,8329

En la Fig. 9 se muestra la comparación de la exactitud entre el modelo MARK 5 y sus cuatro variaciones, también evidencia que el número de neuronas ocultas está comprendido entre 69 y 240. Según los resultados, el aumento del número de épocas disminuye la precisión, como ocurrió con el modelo MARK 15, en comparación con el modelo MARK 5; igualmente, el aumento de neuronas junto con el número de épocas ayuda a mejorar la exactitud de las predicciones, como es el caso del modelo MARK 16; no obstante, estos modelos son inferiores al modelo MARK 5. Se aumentó el número de neuronas para el modelo MARK 17 y aumentó la precisión, superando al modelo inicial. Ahora bien, se puede observar que cuando el número de neuronas en cada capa oculta aumenta, la precisión del modelo disminuye, como es el caso del MARK 18. En resumen, un modelo tuvo mejor precisión en comparación tanto con modelo inicial como con el resto, por debajo de la exactitud esperada.

**Fig. 9.** Precisión de los modelos de RNA para la MDD según el número de neuronas ocultas

El costo computacional está en función del uso de CPU y el consumo de memoria RAM; por ello, es importante el número de variables internas que la red manipula. Teniendo en cuenta los cinco modelos desarrollados, el número de pesos de los modelos de RNA varía entre 1126 y 11 581.

Aunque el tiempo de entrenamiento tiene proporción con la cantidad de neuronas y la cantidad de ejemplos del conjunto de datos, en la Fig. 10 se muestra que el tiempo de entrenamiento de MARK 17 es menor, en comparación con las cuatro variantes.

**Fig. 10.** Tiempo de entrenamiento de los modelos de RNA para predecir la MDD

Predicción del óptimo contenido de humedad, OMC

Para la predicción de esta propiedad se realizaron 100 iteraciones empleando la optimización bayesiana. Según los resultados, el modelo de la iteración cincuenta y ocho, MARK 6, es el mejor usando 8 variables de entrada. La lista de los mejores hiperparámetros para este modelo se muestra en la Tabla 9.

DOI: <https://doi.org/10.21501/21454086.4042>

Tabla 9. Hiperparámetros utilizados en los modelos de RNA para predecir el OMC

Hiperparámetros	MARK 6	MARK 19	MARK 20	MARK 21	MARK 22
Neuronas de entrada	8	8	8	8	8
Neuronas de salida	1	1	1	1	1
Capas ocultas	2	2	2	2	2
Neuronas ocultas	39	39	60	80	120
Arquitectura	8-19-20-1	8-19-20-1	8-30-30-1	8-40-40-1	8-60-60-1
Función de activación	ReLU	ReLU	ReLU	ReLU	ReLU
Tasa de aprendizaje	0,0007	0,0007	0,0007	0,0007	0,0007
Optimizador	Adam	Adam	Adam	Adam	Adam
Número de épocas	188	3000	3000	3000	3000
Tamaño de lote	32	32	32	32	32
Dropout	0,2	0,2	0,2	0,2	0,2
Precisión (R)	0,7520	0,7770	0,7873	0,8700	0,7859

En la Tabla 10 se muestra el resumen del rendimiento de los modelos desarrollados para predecir el OMC. Tomando como base las optimizaciones logradas con el modelo MARK 6, se hicieron cuatro modelos adicionales (MARK 19, MARK 20, MARK 21 y MARK 22) y se entrenaron aumentando el número de épocas a 3000 y el número de neuronas por capa oculta, como se muestra en la Tabla 9. Según los resultados, hay correlaciones entre 0,75 interpretadas como “considerables” y 0,90 como “muy fuertes” [75]. En general, el orden de los modelos desarrollados, de mayor a menor, según su precisión es: (1) MARK 21, (2) MARK 20, (3) MARK 22, (4) MARK 19, (5) y MARK 6.

Tabla 10. Rendimiento de los modelos en la etapa de prueba para predecir OMC

RNA	Arquitectura	MSE (%)	MAE (%)	R
MARK 6	8-19-20-1	4,11	1,54	0,7520
MARK 19	8-5-18-1	3,86	1,40	0,7770
MARK 20	8-30-30-1	3,89	1,38	0,7873
MARK 21	8-40-40-1	2,42	1,13	0,8700
MARK 22	8-60-60-1	4,16	1,44	0,7859

En la Fig. 11 se muestra la comparación entre la exactitud de las predicciones hechas por los modelos MARK 6 y sus cuatro variaciones. También se observa que el número de neuronas ocultas varía de 39 a 120. Según los resultados, el aumento del número de épocas ayuda a mejorar la precisión, como es el caso del mode-

lo MARK 19 que supera al modelo MARK 6. Asimismo, el aumento de neuronas en las capas ocultas junto al número de épocas, ayuda a mejorar la exactitud de las predicciones, como es el caso del MARK 20 y MARK 21. De igual manera, se puede observar que cuantas más neuronas se utilicen en cada capa oculta, la precisión de los modelos de RNA disminuye, como es el caso del modelo MARK 22. Es importante mencionar que para esta propiedad, todas las variaciones realizadas superan al modelo inicial, MARK 6.

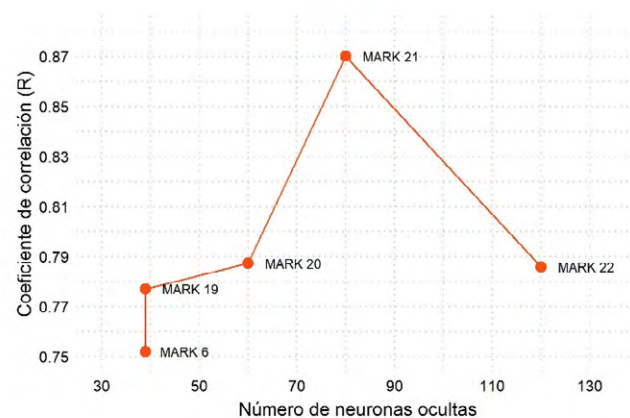


Fig. 11. Gráfico de dispersión de los valores reales de OMC y los valores predichos por los modelos de RNA

Con respecto al número de conexiones que hay entre las neuronas de cada capa y sus sesgos, teniendo en cuenta los cinco modelos desarrollados, el número de pesos sinápticos de los modelos varía entre 592 y 4261, esto es relevante debido al costo computacional.

El tiempo de entrenamiento tiene proporción con la cantidad de neuronas y la cantidad de ejemplos del conjunto de datos, así como con los parámetros de la red. En la Fig. 12 se muestra el tiempo de entrenamiento de los modelos construidos para predecir el OMC y se puede observar que el modelo MARK 21 obtuvo los mejores resultados a nivel de precisión, pero requiere mayor cantidad de tiempo de entrenamiento comparado con el MARK 22, que es una RNA más grande.




Fig. 12. Tiempo de entrenamiento de los modelos de RNA para predecir el OMC

4. TRABAJOS FUTUROS

A partir de los resultados de esta investigación, se puede ver el potencial que tiene el desarrollo de modelos de RNA para la predicción de las propiedades del suelo. Por esta razón, se espera que en trabajos futuros se puedan mejorar los modelos propuestos en este estudio mediante el aumento de la cantidad de ejemplos en el conjunto de datos. Asimismo, se pueden hacer modelos de RNA utilizando otras funciones de activación en las capas ocultas y distintos optimizadores, incluso, buscar otras propiedades físicas que puedan ser utili-

zadas como variables de entrada para la predicción del CBR, la MDD y el OMC. También se podrían ensamblar las RNA con otras técnicas de predicción resultando en modelos híbridos que mejoren la precisión de los resultados y aplicar modelos de RNA con la finalidad de realizar menos ensayos de laboratorio.

Por otra parte, se espera que se apliquen modelos de RNA en otras disciplinas de la ingeniería civil. De esta manera, se puede facilitar la obtención de resultados que demanden de una gran cantidad de tiempo y dinero.

5. CONCLUSIONES

La composición del suelo afecta su comportamiento, haciendo que estimar sus propiedades se torne complicado. Es posible predecir las características del suelo en poco tiempo gracias a avances científicos como la creación de modelos de RNA. Los resultados de esta investigación coinciden con los estudios realizados por [24]–[32], que muestran a los modelos de RNA haciendo buenas predicciones de CBR y los parámetros de compactación.

En esta investigación se corrobora que las propiedades físicas del suelo pueden ser utilizadas para predecir otras como el CBR y los parámetros de compactación, puesto que utilizando características como el contenido de humedad, el contenido de sales, el porcentaje de grava, el porcentaje de arena, el porcentaje de finos, el límite líquido, el límite plástico y el índice de plasticidad del suelo, se puede prever el CBR y los parámetros de compactación aplicando modelos de RNA.

Se observa que el aumento del número de neuronas en cada capa oculta de la RNA mejora la precisión de las predicciones. Sin embargo, un aumento excesivo de estas puede hacer que se consiga el efecto contrario, disminuyendo la precisión de los modelos. Ahora bien, en este estudio se utilizó la fórmula de Stathakis' presentada en [48] para determinar el máximo de neuronas en cada capa oculta, la misma que sirvió como límite

DOI: <https://doi.org/10.21501/21454086.4042>

para la búsqueda de los hiperparámetros utilizados en la optimización bayesiana. Según los resultados, en su mayoría los modelos encontrados utilizan el límite máximo del rango de neuronas, y cuando se entrenaron otros modelos con un número de neuronas mayor a las calculadas con la fórmula, se obtuvieron mejores rendimientos en los modelos. Del mismo modo, se pudo verificar que un aumento del tiempo de entrenamiento hace que mejore el rendimiento del modelo, aunque un exceso podría hacer lo contrario e impactar el costo computacional. Estos resultados indican que se pueden utilizar las recomendaciones de los diversos estudios como punto de partida, ya que en el desarrollo de modelos de RNA no existe fórmula mágica para tener el mejor modelo, esto dependerá muchas veces de las características y número de los ejemplos, así como de los parámetros y arquitectura de la RNA.

Asimismo, el tiempo de entrenamiento es un factor importante a considerar, debido a que está asociado con el costo computacional y la facilidad de uso; se pudo observar que el modelo MARK 21 fue el modelo con mayor tiempo de entrenamiento alcanzando 212,88 segundos para predecir el OMC.

En suma, en este estudio se predicen las propiedades del suelo en el territorio peruano, específicamente en la región norteña de Lambayeque, usando modelos de RNA. Para ello, se utilizaron propiedades fáciles de medir como variables de entrada de los modelos, de tal manera que se obtuvieron buenos resultados y buscando el menor tiempo posible. En total se proponen cuatro modelos de RNA: (1) el modelo MARK 8 para predecir el CBR al 100% de la MDD con un R del 0,89; (2) el modelo MARK 13 para hacer predicciones del CBR al 95% de la MDD, este modelo tuvo un valor de R del 0,92; (3) el modelo MARK 17 para predecir la MDD con un valor de R igual a 0,90; y (4) el modelo MARK 21 para predecir el OMC con un valor de R de 0,87.

AGRADECIMIENTOS

Se agradece la colaboración del Laboratorio de mecánica de suelos y pavimentos de la Universidad Señor de Sipán durante el desarrollo de la presente investigación.

CONFLICTO DE INTERESES

Los autores declaran que no tienen conflictos de intereses financieros o de otro tipo con ninguna institución o grupo comercial.

6. REFERENCIAS

- [1]. V. Y. Katte, S. M. Mfoyet, B. Manefouet, A. S. L. Wouatong, and L. A. Bezeng, "Correlation of California Bearing Ratio (CBR) Value with Soil Properties of Road Subgrade Soil," *Geotech. Geol. Eng.*, vol. 37, no. 1, pp. 217–234, Jan. 2019, doi: 10.1007/s10706-018-0604-x.
- [2]. Instituto Nacional de Estadística e Informática, "Informe Técnico N° 03 -Indicador de la Actividad Productiva Departamental: Segundo Trimestre 2020," 2020. [Online]. Available: <https://www.inei.gob.pe/biblioteca-virtual/boletines/produccion-nacional-departamental-9836/1/>.
- [3]. B M. Das and N. Sivakugan, *Principles of Foundation Engineering*, 9th ed. USA: Cengage Learning, 2019.
- [4]. A. Özyankı, "Soil classification by using artificial neural networks," Master's thesis, Near East University, Nicosi, 2019.
- [5]. A. Carrillo gil, "Comportamiento del suelo tropical peruano," *Perfiles Ing.*, vol. 12, no. 12, pp. 27–35, Aug. 2017, doi: 10.31381/perfiles_ingenieria.v12i12.809.

- [6]. A. Raad Al-Adhath, H. Kadhém Sakban, and Z. Tawfiq Naeem, "Effect of Method of Soil Drying On Atterberg Limits and Soil Classification," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 739, no. 1, Feb. 2020, doi: 10.1088/1757-899X/739/1/012044.
- [7]. B. Zhou and N. Lu, "Correlation between Atterberg Limits and Soil Adsorptive Water," *J. Geotech. Geoenvironmental Eng.*, vol. 147, no. 2, Feb. 2021, doi: 10.1061/(ASCE)GT.1943-5606.0002463.
- [8]. S. Al-Busultan, G. K. Aswed, R. R. A. Almuhanana, and S. E. Rasheed, "Application of Artificial Neural Networks in Predicting Subbase CBR Values Using Soil Indices Data," in *IOP Conference Series: Materials Science and Engineering*, Jan. 2020, vol. 671, no. 1, doi: 10.1088/1757-899X/671/1/012106.
- [9]. E. A. Sandoval Vallejo y W. A. Rivera Mena, "Correlación del CBR con la resistencia a la compresión inconfnada," *Cienc. e Ing. Neogranadina*, vol. 29, no. 1, pp. 135–152, Aug. 2019, doi: 10.18359/rcin.3478.
- [10]. G. Verma and B. Kumar, "Prediction of compaction parameters for fine-grained and coarse-grained soils: a review," *Int. J. Geotech. Eng.*, vol. 14, no. 8, pp. 970–977, Nov. 2020, doi: 10.1080/19386362.2019.1595301.
- [11]. Ministerio de Transportes y Comunicaciones, "Manual de ensayo de materiales". Perú, 2016. Disponible en: https://portal.mtc.gob.pe/transportes/caminos/normas_carreteras/manuales.html.
- [12]. T. Li, L. Kong, and B. Liu, "The California Bearing Ratio and Pore Structure Characteristics of Weakly Expansive Soil in Frozen Areas," *Appl. Sci.*, vol. 10, no. 21, pp. 1–22, Oct. 2020, doi: 10.3390/app10217576.
- [13]. X. Ji et al., "A Prediction Method for the California Bearing Ratio of Soil-Rock Mixture Based on the Discrete Element Method and CT Scanning," *Adv. Civ. Eng.*, vol. 2020, pp. 1–12, Sep. 2020, doi: 10.1155/2020/9794756.
- [14]. R. Nini, "Effect of Soaking Period of Clay on its California Bearing Ratio Value," in *The 4th World Congress on Civil, Structural, and Environmental Engineering*, Apr. 2019, doi: 10.11159/icgre19.162.
- [15]. E. Mina, R. I. Kusuma, and N. Ulfah, "Utilization of steel slag and fly ash in soil stabilization and their effect to californa bearing ratio (CBR) value. (Case study: Kp. Kadusentar road Medong village Mekarjaya Subdistrict Pandeglang District)," in *IOP Conference Series: Materials Science and Engineering*, Dec. 2019, vol. 673, no. 1, doi: 10.1088/1757-899X/673/1/012034.
- [16]. Z. U. Rehman, U. Khalid, K. Farooq, and H. Mujtaba, "Prediction of CBR value from index properties of different soils," *Tech. J. Univ. Eng. Technol. Taxila, Pakistan*, vol. 22, no. 2, 2017.
- [17]. Universidad Nacional de Ingeniería, "Tarifa de ensayos de laboratorio", Lima, 2019. [En línea]. Disponible en: <http://www.lms.uni.edu.pe/lab-suelos/tarifa/tarifa-general-2019.pdf>.
- [18]. G. O. Bogado, N. A. Pintos, H. O. Reinert, and D. A. Bressan, "Correlación entre parámetros de compactación y propiedades geotécnicas en suelos tropicales misioneros," *Rev. Geol. Apl. a la Ing. y al Ambient.*, vol. 39, pp. 19–26, 2017.
- [19]. Ministerio de Transportes y Comunicaciones, "Manual de carreteras–Suelos, Geología, Geotécnia y Pavimentos. Sección: Suelos y Pavimentos". Perú, 2014.

- [20]. E. Özgan, S. Serin, and İ. Vural, "Multi-faceted investigation and modeling of compaction parameters for road construction," *J. Terramechanics*, vol. 60, pp. 33–42, Aug. 2015, doi: 10.1016/j.jterra.2015.02.005.
- [21]. O. Vafoeva, "Hydromechanical Method of Soil Compaction," in *IOP Conference Series: Materials Science and Engineering*, Jul. 2020, vol. 883, no. 1, doi: 10.1088/1757-899X/883/1/012061.
- [22]. J. C. Chirinos Quispe, "Efecto de la energía de compactación en la densidad seca máxima y contenido óptimo de humedad del suelo granular de la cantera El Gavilán, 2015", Tesis de licenciatura, Universidad Privada del Norte, 2016.
- [23]. E. Millan-Romero and C. Millan-Paramo, "Relationship of water parameters with the optimum moisture content in clay soils," *ARPN J. Eng. Appl. Sci.*, vol. 15, no. 15, pp. 1666–1671, 2020.
- [24]. A. R. Tenpe and A. Patel, "Application of genetic expression programming and artificial neural network for prediction of CBR," *Road Mater. Pavement Des.*, vol. 21, no. 5, pp. 1183–1200, Jul. 2020, doi: 10.1080/14680629.2018.1544924.
- [25]. S. K. Alam, A. Mondal, and A. Shiuly, "Prediction of CBR Value of Fine Grained Soils of Bengal Basin by Genetic Expression Programming, Artificial Neural Network and Krigging Method," *J. Geol. Soc. India*, vol. 95, no. 2, pp. 190–196, Feb. 2020, doi: 10.1007/s12594-020-1409-0.
- [26]. A. Ardakani and A. Kordnaeij, "Soil compaction parameters prediction using GMDH -type neural network and genetic algorithm," *Eur. J. Environ. Civ. Eng.*, vol. 23, no. 4, pp. 449–462, Apr. 2019, doi: 10.1080/19648189.2017.1304269.
- [27]. B. S. Albusoda, D. A. Al-Hamdani, and M. F. Abbas, "Dry Density Based on Soil Index Properties by Using Expert System," *Key Eng. Mater.*, vol. 857, pp. 266–272, Aug. 2020, doi: 10.4028/www.scientific.net/KEM.857.266.
- [28]. C. Rajakumar and G. Reddy Babu, "Experimental study and neural network modelling of expansive sub grade stabilized with industrial waste by-products and geogrid," *Mater. Today Proc.*, Aug. 2020, doi: 10.1016/j.matpr.2020.06.578.
- [29]. T. Fikret Kurnaz and Y. Kaya, "Prediction of the California bearing ratio (CBR) of compacted soils by using GMDH-type neural network," *Eur. Phys. J. Plus*, vol. 134, no. 7, Jul. 2019, doi: 10.1140/epjp/i2019-12692-0.
- [30]. A. Ghorbani and H. Hasanzadehshooili, "Prediction of UCS and CBR of microsilica-lime stabilized sulfate silty sand using ANN and EPR models; application to the deep soil mixing," *Soils Found.*, vol. 58, no. 1, pp. 34–49, Feb. 2018, doi: 10.1016/j.sandf.2017.11.002.
- [31]. Y. Erzin and D. Turkoz, "Use of neural networks for the prediction of the CBR value of some Aegean sands," *Neural Comput. Appl.*, vol. 27, no. 5, pp. 1415–1426, Jul. 2016, doi: 10.1007/s00521-015-1943-7.
- [32]. M. Suthar and P. Aggarwal, "Predicting CBR Value of Stabilized Pond Ash with Lime and Lime Sludge Using ANN and MR Models," *Int. J. Geosynth. Gr. Eng.*, vol. 4, no. 1, p. 6, Mar. 2018, doi: 10.1007/s40891-017-0125-3.
- [33]. F. J. Valderrama Purizaca, D. A. Chávez Barturen, S. P. Muñoz Pérez, V. A. Tuesta-Monteza, and H. I. Mejía-Cabrera, "Importance of artificial neural networks in civil engineering: a systematic review of the literature," *ITECKNE*, vol. 18, no. 1, 2020, doi: 10.15332/iteckne.v18i1.2542.

- [34]. S. Khuntia, H. Mujtaba, C. Patra, K. Farooq, N. Sivakugan, and B. M. Das, "Prediction of compaction parameters of coarse grained soil using multivariate adaptive regression splines (MARS)," *Int. J. Geotech. Eng.*, vol. 9, no. 1, pp. 79–88, Feb. 2015, doi: 10.1179/1939787914Y.0000000061.
- [35]. U. Khalid and Z. ur Rehman, "Evaluation of compaction parameters of fine-grained soils using standard and modified efforts," *Int. J. Geo-Engineering*, vol. 9, no. 1, Art. no. 15, Dec. 2018, doi: 10.1186/s40703-018-0083-1.
- [36]. I. Taleb Bahmed, K. Harichane, M. Ghrici, B. Boukhatem, R. Rebouh, and H. Gadouri, "Prediction of geotechnical properties of clayey soils stabilised with lime using artificial neural networks (ANNs)," *Int. J. Geotech. Eng.*, vol. 13, no. 2, pp. 191–203, Mar. 2019, doi: 10.1080/19386362.2017.1329966.
- [37]. P. Tizpa, R. Jamshidi Chenari, M. Karimpour Fard, and S. Lemos Machado, "ANN prediction of some geotechnical properties of soil from their index parameters," *Arab. J. Geosci.*, vol. 8, no. 5, pp. 2911–2920, May 2015, doi: 10.1007/s12517-014-1304-3.
- [38]. S. Shanmuganathan, "Artificial Neural Network Modelling: An Introduction," in *Studies in Computational Intelligence*, vol. 628, Springer Verlag, 2016, pp. 1–14.
- [39]. F. Ecer, S. Ardabili, S. S. Band, and A. Mosavi, "Training Multilayer Perceptron with Genetic Algorithms and Particle Swarm Optimization for Modeling Stock Price Index Prediction," *Entropy*, vol. 22, no. 11, Art. no. 1239, Oct. 2020, doi: 10.3390/e22111239.
- [40]. A. Jassam Mohammed, M. Hameed Arif, and A. Adil Ali, "A multilayer perceptron artificial neural network approach for improving the accuracy of intrusion detection systems," *IAES Int. J. Artif. Intell.*, vol. 9, no. 4, pp. 609–615, Dec. 2020, doi: 10.11591/ijai.v9.i4.pp609-615.
- [41]. K. Ncibi, T. Sadraoui, M. Faycel, and A. Djenina, "A Multilayer Perceptron Artificial Neural Networks Based a Preprocessing and Hybrid Optimization Task for Data Mining and Classification," *Int. J. Econom. Financ. Manag.* Vol. 5, 2017, Pages 12-21, vol. 5, no. 1, 2017, doi: 10.12691/ijefm-5-1-3.
- [42]. S. Saha, G. C. Paul, B. Pradhan, K. N. Abdul Maulud, and A. M. Alamri, "Integrating multilayer perceptron neural nets with hybrid ensemble classifiers for deforestation probability assessment in Eastern India," *Geomatics, Nat. Hazards Risk*, vol. 12, no. 1, pp. 29–62, Jan. 2021, doi: 10.1080/19475705.2020.1860139.
- [43]. A. Escamilla-García, G. M. Soto-Zarazúa, M. Toledano-Ayala, E. Rivas-Araiza, and A. Gastélum-Barrios, "Applications of Artificial Neural Networks in Greenhouse Technology and Overview for Smart Agriculture Development," *Appl. Sci.*, vol. 10, no. 11, Art. no. 3835, May 2020, doi: 10.3390/app10113835.
- [44]. I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. 2016.
- [45]. Sistema Electrónico de Contrataciones del Estado, "Buscador público." <https://prodapp2.seace.gob.pe/seacebus-uiwd-pub/buscadorPublico/buscadorPublico.xhtml>.
- [46]. J. Casas Roma, A. Bosch Rue, and T. Lozano Bagen, *Deep learning: principios y fundamentos*. Editorial UOC, 2019.
- [47]. M. Manrique Dávila, "Predicción de propiedades mecánicas de suelos utilizando redes neuronales artificiales," Tesis de grado, Universidad Continental, Huancayo, 2019.

DOI: <https://doi.org/10.21501/21454086.4042>

- [48]. L. C. P. Velasco, R. P., M. Shahin, B. F., and J. C., "Performance Analysis of Multilayer Perceptron Neural Network Models in Week-Ahead Rainfall Forecasting," *Int. J. Adv. Comput. Sci. Appl.*, vol. 10, no. 3, pp. 578–588, 2019, doi: 10.14569/IJACSA.2019.0100374.
- [49]. François Chollet, *Deep Learning with Python*. Shelter Island, NY: Manning Publications, 2017.
- [50]. G. Singh and A. K. Singh, "A study on precursors leading to geomagnetic storms using artificial neural network," *J. Earth Syst. Sci.*, vol. 125, no. 5, pp. 899–908, Jul. 2016, doi: 10.1007/s12040-016-0702-1.
- [51]. A. C. Müller and S. Guido, *Introduction to machine learning with Python: a guide for data scientists*. O'Reilly Media, Inc., 2016.
- [52]. L. C. P. Velasco, C. R. Villezas, P. N. C. Palahang, and J. A. A. Dagaang, "Next day electric load forecasting using Artificial Neural Networks," in *2015 International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)*, Dec. 2015, pp. 1–6, doi: 10.1109/HNICEM.2015.7393166.
- [53]. L. C. P. Velasco, D. Lou, G. Paolo, M. Bryan, and F. B., "Load Forecasting using Autoregressive Integrated Moving Average and Artificial Neural Network," *Int. J. Adv. Comput. Sci. Appl.*, vol. 9, no. 7, pp. 23–29, 2018, doi: 10.14569/IJACSA.2018.090704.
- [54]. C. Nwankpa, W. Ijomah, A. Gachagan, and S. Marshall, "Activation Functions: Comparison of trends in Practice and Research for Deep Learning," Nov. 2018. Disponible en: <http://arxiv.org/abs/1811.03378>.
- [55]. P. Ramachandran, B. Zoph, and Q. V. Le, "Searching for Activation Functions," Oct. 2017. Available: <http://arxiv.org/abs/1710.05941>.
- [56]. T. Szandała, "Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks," in *Studies in Computational Intelligence*, vol. 903, 2021, pp. 203–224.
- [57]. Y. Wang, Y. Li, Y. Song, and X. Rong, "The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition," *Appl. Sci.*, vol. 10, no. 5, Art. no. 1897, Mar. 2020, doi: 10.3390/app10051897.
- [58]. L. B. Godfrey and M. S. Gashler, "A continuum among logarithmic, linear, and exponential functions, and its potential to improve generalization in neural networks," in *IC3K 2015—Proceedings of the 7th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management*, 2015, vol. 1, pp. 481–486, doi: 10.5220/0005635804810486.
- [59]. S. Sharma, S. Sharma, and A. Athaiya, "Activation Functions in Neural Networks," *Int. J. Eng. Appl. Sci. Technol.*, vol. 04, no. 12, pp. 310–316, May 2020, doi: 10.33564/IJEAST.2020.v04i12.054.
- [60]. V. Vijayashanthar, J. Qiao, Z. Zhu, P. Entwistle, and G. Yu, "Modeling Fecal Indicator Bacteria in Urban Waterways Using Artificial Neural Networks," *J. Environ. Eng.*, vol. 144, no. 6, Art. no. 05018003, Jun. 2018, doi: 10.1061/(ASCE)EE.1943-7870.0001377.
- [61]. S. Lathuiliere, P. Mesejo, X. Alameda-Pineda, and R. Horaud, "A Comprehensive Analysis of Deep Regression," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 42, no. 9, pp. 2065–2081, Sep. 2020, doi: 10.1109/TPAMI.2019.2910523.
- [62]. C. Pack, S. Shin, H.-D. Choi, S.-I. Jeon, and J. Kim, "Optimized multilayer perceptron using dynamic learning rate based microwave tomography breast cancer screening," in *Proceedings of the 31st Annual ACM Symposium on Applied Computing*, Apr. 2016, vol. 04-08-April, pp. 2171–2175, doi: 10.1145/2851613.2851825.

- [63]. Y. Wang, J. Liu, J. Misić, V. B. Misić, S. Lv, and X. Chang, "Assessing Optimizer Impact on DNN Model Sensitivity to Adversarial Examples," *IEEE Access*, vol. 7, pp. 152766–152776, 2019, doi: 10.1109/ACCESS.2019.2948658.
- [64]. D. Yi, J. Ahn, and S. Ji, "An Effective Optimization Method for Machine Learning Based on ADAM," *Appl. Sci.*, vol. 10, no. 3, Art. no. 1073, Feb. 2020, doi: 10.3390/app10031073.
- [65]. Y. Roy, H. Banville, I. Albuquerque, A. Gramfort, T. H. Falk, and J. Faubert, "Deep learning-based electroencephalography analysis: a systematic review," *J. Neural Eng.*, vol. 16, no. 5, Art. no. 051001, Aug. 2019, doi: 10.1088/1741-2552/ab260c.
- [66]. M. A. Amirabadi, M. H. Kahaei, and S. A. Nezamalhosseini, "Novel suboptimal approaches for hyperparameter tuning of deep neural network [under the shelf of optical communication]," *Phys. Commun.*, vol. 41, Art. no. 101057, Aug. 2020, doi: 10.1016/j.phycom.2020.101057.
- [67]. G. I. Diaz, A. Fokoue-Nkoutche, G. Nannicini, and H. Samulowitz, "An effective algorithm for hyperparameter optimization of neural networks," *IBM J. Res. Dev.*, vol. 61, no. 4/5, Jul. 2017, doi: 10.1147/JRD.2017.2709578.
- [68]. M. Kim, "Supervised learning based DDoS attacks detection: Tuning hyperparameters," *ETRI J.*, vol. 41, no. 5, pp. 560–573, Oct. 2019, doi: 10.4218/etrij.2019-0156.
- [69]. S. Yildirim, "Improving word embeddings projection for Turkish hypernym extraction," *Turkish J. Electr. Eng. Comput. Sci.*, vol. 27, no. 6, pp. 4418–4428, Nov. 2019, doi: 10.3906/elk-1903-65.
- [70]. A. Dinamarca, "Aprendizaje y Análisis de Redes Neuronales Artificiales Profundas," Tesina de grado, Universidad Nacional de Cuyo, 2018.
- [71]. L. Balles, J. Romero, and P. Hennig, "Coupling adaptive batch sizes with learning rates," Dec. 2017. Available: <http://arxiv.org/abs/1612.05086>.
- [72]. X. Wei, L. Zhang, H.-Q. Yang, L. Zhang, and Y.-P. Yao, "Machine learning for pore-water pressure time-series prediction: Application of recurrent neural networks," *Geosci. Front.*, vol. 12, no. 1, pp. 453–467, 2021, doi: 10.1016/j.gsf.2020.04.011.
- [73]. J. Koo, J. Zhang, and S. Chaterji, "Tiresias: Context-sensitive approach to decipher the presence and strength of microRNA regulatory interactions," *Theranostics*, vol. 8, no. 1, 2018, doi: 10.7150/thno.22065.
- [74]. E. Brochu, V. M. Cora, and N. de Freitas, "A Tutorial on Bayesian Optimization of Expensive Cost Functions, with Application to Active User Modeling and Hierarchical Reinforcement Learning," *RI*, Dec. 2010, [Online]. Available: <http://arxiv.org/abs/1012.2599>.
- [75]. R. Hernández-Sampieri and C. P. Mendoza Torres, *Metodología de la investigación: las rutas cuantitativas, cualitativa y mixta*, 1ª ed. McGraw Hill, 2018.