

Algoritmo de aprendizaje computacional mediante redes neuronales artificiales aplicado al diseño geotécnico de cimentaciones superficiales

Freddy Arias¹, Edison Ávila¹, Jaime Bojorque^{1,2}

¹Escuela Superior Politécnica del Litoral (ESPOL)

²Universidad de Cuenca

Abstract

This paper presents the development of a machine learning algorithm based on artificial neural networks (ANN), for the assistance and validation of bearing capacity and settlement results, focused on shallow foundations for buildings. By collecting and processing 100 geotechnical case studies from the provinces of Azuay and Pichincha, a database was generated according to their structuring, based on the guidelines of the Ecuadorian Construction Standard. Complementarily, to compare the settlement values recorded in the database, a connection algorithm written in Python was assembled to estimate settlements with the assistance of PLAXIS 2D software, thus establishing a final data structure, which was subsequently used for the training, validation, and correction campaign of the artificial neural network (ANN). The most accurate results for the prediction of bearing capacity and settlement (ANN target variables) were obtained by separating the input variables (physical-mechanical parameters of soils, foundation data and structural load) by province. This study can be used as a guide to mature a neural network, which may be implemented throughout the Ecuadorian territory as an assistant in making adequate design decisions in soil mechanics for buildings.

Keywords: geotechnical database, Artificial Neural Networks, Machine Learning, Python, shallow foundations, numerical modeling, PLAXIS 2D.

Resumen

En este documento se presenta el desarrollo de un algoritmo de aprendizaje computacional basado en redes neuronales artificiales (RNA), para la asistencia y validación de resultados de capacidad de carga y asentamientos, enfocado a cimentaciones superficiales para edificaciones. Mediante la recopilación y procesamiento de 100 casos de estudio geotécnicos de las provincias de Azuay y Pichincha, se generó una base de datos acorde a su estructuración, basada en los lineamientos de la Norma Ecuatoriana de la Construcción. De manera complementaria, con el objetivo de comparar los valores de asentamientos registrados en la base de datos, se ensambló un algoritmo de conexión escrito en Python para estimar asentamientos con asistencia del software PLAXIS 2D, estableciéndose así una estructura de datos final, que posteriormente fue utilizada para la campaña de entrenamiento, validación y corrección de la red neuronal artificial (RNA). Los resultados más precisos para la predicción de capacidad de carga admisible y asentamiento (variables objetivo de la RNA) se obtuvieron al separar las variables de ingreso (parámetros físicos – mecánicos de los suelos, datos de cimentación y carga estructural) por provincia. Este estudio puede ser utilizado como una guía para madurar una red neuronal, que pueda implementado a lo largo del territorio ecuatoriano como un asistente en la adecuada toma de decisiones de diseño en mecánica de suelos para edificaciones.

Palabras clave: base de datos geotécnicos, Redes Neuronales Artificiales, Machine Learning, Python, cimentaciones superficiales, modelación numérica, PLAXIS 2D.

1. Introducción

La geotecnia se enfrenta continuamente al desafío de crear modelos que se aproximen de manera adecuada al verdadero comportamiento del suelo y su interacción con las estructuras. Dos características cruciales que el profesional geotécnico debe considerar en la toma de decisiones corresponden a la seguridad y economía, con el propósito de resolver una variedad de casos de estudio complejos. Entre los problemas más complejos se tiene el diseño geotécnico de cimentaciones superficiales [1].

Con el paso del tiempo, la aplicación de nuevas tecnologías en la ingeniería geotécnica ha permitido un notable avance. Un claro ejemplo es la aplicación de técnicas de inteligencia artificial en la creación de modelos predictivos geotécnicos, implementadas con éxito en las dos últimas décadas. En particular, los modelos basados en redes neuronales artificiales, programación genética y regresión polinomial evolucionaria han producido los resultados más satisfactorios [2], [3], [4].

En la modelación y análisis geotécnico de los suelos, la complejidad y la incertidumbre ha sido un tema relevante en la predicción de las respuestas provocadas por las cargas estructurales en los sistemas de cimentación superficial [5]. En muchos casos, los modelos matemáticos han subestimado los resultados, lo que ha provocado problemas en obras de ingeniería geotécnica [6]. Por esta razón, es esencial utilizar técnicas innovadoras, como las redes neuronales artificiales [2], para asistir en las decisiones de análisis y diseño geotécnico de proyectos, tales como las cimentaciones superficiales de edificaciones.

El Machine Learning y, en específico, las redes neuronales, han demostrado tener un gran potencial para promover el análisis de datos y el modelamiento enfocado en diversos problemas, dada su flexibilidad y escalabilidad. En años recientes, se ha desarrollado una amplia gama de librerías de software enfocadas en redes neuronales, lo que ha facilitado y acelerado la investigación y aplicación de este tipo de modelos [7].

2. Estado del arte

El análisis geotécnico enfocado a cimentaciones para edificaciones es crucial para el diseño de estas estructuras, con el afán de garantizar su estabilidad y seguridad. El diseño de cimentaciones abarca la selección del tipo de elementos de cimentación y profundidad a la que deben ser ubicadas, tomando consideraciones como el proceso constructivo, el costo y la proyección de la obra [8]. En general, los sistemas de cimentación se clasifican en superficiales y profundas.

Las cimentaciones superficiales son mecanismos que transfieren las fuerzas ejercidas por una estructura de edificación hacia el suelo. Esto abarca varios tipos, como zapatas aisladas, corridas, combinadas y losas de cimentación [9]. En la subestructura de un edificio, estos sistemas de cimentación son apropiados para suelos que pueden soportar cargas sin sufrir asentamientos excesivos o deformaciones. El proceso de diseño implica la valoración de parámetros tales como la capacidad de carga del suelo, el peso de la estructura, las cargas aplicadas y las condiciones del lugar [10].

Por consiguiente, al llevar a cabo estudios geotécnicos centrados en el análisis y diseño de cimentaciones superficiales, el proceso estándar para verificar la seguridad se fundamenta en los conceptos de estados límite último y de servicio [11], [12]. Con el fin de abordar el estado límite último, se han utilizado ecuaciones analíticas, mientras que, para el caso del estado de servicio, actualmente se cuenta con programas computacionales basados en elementos finitos que dan resultados adecuados.

2.1. Método de elementos finitos

El método de elementos finitos (MEF) es una técnica utilizada para abordar problemas de ingeniería que involucran ecuaciones diferenciales parciales con condiciones de borde complejas. Este método resuelve estos problemas al dividir el dominio espacial en elementos discretos [13], [14]. La discretización se efectúa de manera local en regiones pequeñas, logrando así áreas en las cuales se puede considerar que las propiedades son uniformes. Este proceso genera ecuaciones matriciales que conectan la entrada en puntos específicos de los elementos (nodos) con la salida en esos mismos puntos [15], [16].

Previo al inicio del proceso de modelación, es crucial llevar a cabo una investigación geotécnica del sitio para comprender las condiciones específicas. Se deben definir las condiciones de carga y la geometría básica, las cuales suelen estar directamente relacionadas con las características del proyecto. Además, es necesario tener información sobre las propiedades y la estratigrafía del suelo. Otras variables que deben ser definidas incluyen el nivel freático, la locación y profundidad de estructuras cercanas, la rigidez del suelo y cualquier restricción que pueda surgir de las condiciones locales del sitio de construcción [17].

Es adecuado emplear el método de elementos finitos cuando se requiere tener en cuenta cualquiera de los aspectos enumerados a continuación [18]:

- Complejidad en el comportamiento del suelo, incluyendo aspectos como la rigidez no lineal, endurecimiento, anisotropía, creep, entre otros.
- Configuración geométrica atípica.
- Condiciones relacionadas a elementos hidráulicos complejos.
- Cargas complejas.
- Interacción del suelo con la estructura, fuerzas internas en estructuras complicadas o interacciones con estructuras vecinas.
- Efectos de las fases de construcción y el procedimiento constructivo.

Para la aplicación del MEF se requiere de los siguientes pasos:

- Discretización de elementos: Proceso de dividir un dominio continuo en una serie de subregiones más pequeñas llamadas "elementos finitos". Estos elementos están caracterizados por puntos de conexión, o nodos, ubicados en sus extremos o en su interior.
- Aproximación a la variable primaria: Requiere la elección de una variable (desplazamientos, esfuerzos, entre otros) y la definición de su comportamiento dentro de un elemento finito específico. Esta conducta se describe en función de los valores en los nodos. En el ámbito de la geotecnia, los desplazamientos suelen ser la variable principal seleccionada.
- Ecuaciones elementales: Para derivar las ecuaciones elementales se requiere del uso de un principio variacional adecuado:

$$[K_e]\{\Delta d_e\} = \{\Delta R_e\} \quad (1)$$

Donde:

- $[K_e]$: Matriz de rigidez del elemento
 - $\{\Delta d_e\}$: Vector de incremento de desplazamientos nodales en cada elemento
 - $\{\Delta R_e\}$: Vector de incremento de fuerzas nodales en cada elemento
- Combinación de las ecuaciones elementales para crear las ecuaciones globales:

$$[K_G]\{\Delta d_G\} = \{\Delta R_G\} \quad (2)$$

Donde:

- $[K_G]$: Matriz de rigidez global
 - $\{\Delta d_G\}$: Vector de incremento de todos los desplazamientos nodales
 - $\{\Delta R_G\}$: Vector de incremento de todas las fuerzas nodales
- Formulación de condiciones de borde y ajuste de ecuaciones globales. Las cargas (cargas puntuales, cargas lineales, presiones, etc.) afectan a $\{\Delta R_G\}$, en tanto que los desplazamientos afectan a $\{\Delta d_G\}$.
 - Se procede a resolver las ecuaciones globales, las cuales consisten en un conjunto extenso de ecuaciones simultáneas, para determinar los desplazamientos $\{\Delta d_G\}$ en todos los nodos. A partir de estos desplazamientos, se calculan parámetros secundarios como los esfuerzos y las deformaciones [19].

La utilización del MEF a menudo implica un mayor costo computacional que los métodos convencionales. A pesar de esto, este tipo de análisis ofrece una precisión y detalle que son difíciles de alcanzar por otro medio, lo que puede resultar en diseños más eficientes y mejor optimizados [18].

Los principios básicos del cálculo por el método de elementos finitos son tomados del modelo constitutivo con el que se modela el suelo. El modelo de Mohr – Coulomb, escogido para este trabajo, es un modelo lineal elasto – plástico perfecto, reconocido y ampliamente utilizado en todo el mundo. La parte lineal elástica está basada en la ley de Hooke de elasticidad isotrópica, mientras que la parte perfectamente plástica se fundamenta en el criterio de falla de Mohr – Coulomb [20].

Los parámetros fundamentales para el modelamiento de un problema geotécnico utilizando el modelo de Mohr – Coulomb son 5 en total: 2 parámetros de rigidez y 3 de resistencia [20].

Parámetros de rigidez:

- Módulo de Young, E
- Relación de Poisson, ν

Parámetros de resistencia:

- Cohesión, c
- Ángulo de fricción, ϕ
- Ángulo de dilatancia, ψ

2.2. Modelo de redes neuronales

La utilización de técnicas de inteligencia artificial y modelos de Machine Learning en la Ingeniería Civil ha incrementado exponencialmente, potenciado por los continuos avances en estas tecnologías. Estas técnicas han empezado a revolucionar la forma en que se diseña, construye y mantiene estructuras e infraestructuras, permitiendo a los ingenieros llevar a cabo decisiones mejor informadas, generando prácticas más eficientes y sostenibles [21].

Las redes de neuronas artificiales son una forma de inteligencia artificial que intenta imitar el funcionamiento del cerebro humano y el sistema nervioso [22]. Generalmente, la arquitectura de los modelos de redes neuronales consiste en una serie de elementos procesadores o nodos, que se arreglan en una serie de capas: una capa de ingreso, una de salida, y una o más capas ocultas [2]. Esta tecnología está diseñada para reconocer patrones y relaciones intrincadas en los datos, y resultan eficaces en funciones como clasificación, agrupamiento, detección de patrones y predicción [3].

El procesamiento de los datos en una red neuronal se da en forma de lotes (batches) y épocas (epochs). Los lotes tienen un tamaño definido y están compuestos por la cantidad de muestras que pasarán por la red neuronal antes de que se actualicen los parámetros internos del modelo. El número de épocas, a su vez, se refiere al número de veces que el algoritmo de aprendizaje recorrerá la base de datos de entrenamiento por completo [23]. A cada ingreso proveniente de cada nodo, x_i , se le aplica un multiplicador ajustable que lo pondera, w_{ji} . A este valor ponderado se le suma un valor independiente, θ_j , con lo que se obtiene el ingreso combinado I_j . Este ingreso combinado es posteriormente procesado a través de una función de activación no lineal, $f(\cdot)$, para producir la salida del nodo, y_j . Una de las funciones de activación más comúnmente utilizadas es la Unidad Lineal Rectificada (ReLU).

La salida, a su vez, se convierte en el ingreso para el nodo de la siguiente capa, volviéndose una sucesión de operaciones consecutivas [2]. Este proceso se puede resumir en las ecuaciones (3) y (4):

$$I_j = \sum w_{ji}x_i + \theta_j \quad (3)$$

$$y_j = f(I_j) \quad (4)$$

Donde la ecuación (3) refleja la combinación de los ingresos, y la (4) la transformación hacia los egresos.

Estas operaciones son realizadas por cada una de las neuronas que conforman una capa de la red neuronal (capa densa) y sus egresos pasan a ser, a su vez, los ingresos de la siguiente capa densa.

Además de las capas de neuronas artificiales, un modelo de aprendizaje computacional puede ser enriquecido mediante la implementación de otros tipos de capas que cumplen funciones específicas, tal como:

- Capa de normalización de lotes (Batch Normalization): Capa que utiliza la distribución de los datos de un lote para calcular una media y varianza, utilizadas para normalizar los datos ingresados a cada neurona de manera particular [24].
- Capa de eliminación (Dropout): Capa que elimina datos de un lote aleatoriamente, lo cual evita la absorción de información de relaciones entre datos apócrifas o casuales ("overfitting") [25].

La efectividad de una red neuronal es evaluada a través de una función de pérdida (loss function), la cual es una expresión matemática que mide la diferencia o error entre las predicciones de un modelo y los valores verdaderos correspondientes. Una de las funciones de pérdida más utilizadas es el MAE (Error Medio Absoluto), la cual mide la diferencia absoluta media entre los valores verdaderos y los predichos por la red neuronal del

parámetro objetivo de la predicción [26]. Un menor valor de MAE significa una mayor precisión en las predicciones de la red neuronal.

Con el fin de minimizar la función de pérdida se utiliza un optimizador, el cual es una entidad algorítmica cuya función es cambiar los atributos de la red neuronal, es decir, sus ponderadores y su tasa de aprendizaje, de manera que el error medio se reduzca progresivamente. El optimizador "Adam" es uno de los más utilizados debido a su gran capacidad de adaptabilidad [27].

Para lograr el desempeño óptimo y general de las predicciones de la red neuronal, es necesario tomar medidas para evitar el "overfitting", causado por la absorción de información errónea sobre relaciones entre datos inexistentes o producto de la casualidad. Al suceder esto, el error en la etapa de la validación incrementa, incluso si el error de la etapa de entrenamiento continúa disminuyendo. El "early stopping" es una herramienta simple para evitar el "overfitting", ya que detiene el entrenamiento de la red neuronal cuando el procesamiento de nuevas épocas deja de contribuir a la disminución del error en los datos de validación o lo aumenta, guardando además los ponderadores encontrados por la red que produjeron el error mínimo [28].

Una de las herramientas más populares y accesibles para la implementación de redes neuronales es la librería de software TensorFlow, cuya flexibilidad y escalabilidad para computaciones numéricas permite al usuario programar, entrenar y poner en marcha eficientemente una red neuronal u otros modelos de Machine Learning. Los algoritmos centrales de TensorFlow están escritos en C++, y está disponible para varios lenguajes de programación como JavaScript, Java, Go, Swift y Python [7], siendo este último la herramienta escogida para el desarrollo de esta investigación.

3. Metodología

3.1. Estructura de datos

Un estudio de cimentaciones para edificaciones tiene como propósito la identificación de las características del suelo en el sitio de construcción, la determinación de la capacidad de carga del suelo y la evaluación de asentamientos [29].

Para el presente proyecto de investigación se recopilaron 100 estudios de suelos para cimentaciones superficiales con el apoyo de 28 empresas privadas y/o especialistas en el campo de la geotecnia, tanto para la provincia de Pichincha como para el Azuay. En detalle, se procesó:

- Pichincha: 50 estudios, de los cuales 43 corresponden al Distrito Metropolitano de Quito (DMQ), 3 al cantón Rumiñahui, 3 al cantón Cayambe y 1 al cantón Mejía, todos aledaños al DMQ.
- Azuay: 50 estudios, de los que 45 corresponden al cantón Cuenca, 3 a Santa Isabel, 1 a Gualaceo y 1 a Paute.

Los estudios registrados se ubican en la zona UTM 17M y, para Pichincha, sus cotas varían entre los 2340 y 3140 msnm. Por otro lado, para Azuay, sus cotas se encuentran entre los 1319 y los 3080 msnm. El 99% de los datos recolectados proviene de estudios realizados desde el año 2014 hasta el 2024, con una sola excepción, correspondiente a un estudio ejecutado en el 2007.

Para la formulación de una estructura de datos que pueda ser utilizada para la alimentación y entrenamiento de la RNA se analizó el contenido de los informes, los mismos que inician nombrando aspectos generales del proyecto de edificación, como su ubicación, descripción geológica de la zona de implantación, investigación de campo (sondeos y ensayos de laboratorio), análisis de la capacidad de carga y asentamientos y elección del tipo de cimentación, para finalmente emitir las

conclusiones y recomendaciones que puedan ser tomadas en cuenta por el especialista a cargo del diseño de la estructura.

Se establecieron tres campos para la extracción de datos. En primera instancia, los datos generales de cada proyecto: ubicación, geología local, número de sondeos ejecutados, número de estratos definidos, nivel freático, perfil sísmico, tipo y dimensión de cimentación recomendada, capacidad de carga, asentamientos, número de pisos de la edificación proyectada, carga estructural, área del terreno estudiado y recomendaciones enfocadas al mejoramiento de suelos, subestructura, sistemas de drenaje, ejecución de obra y contrapisos.

Para el segundo campo se establecieron datos relacionados a la caracterización del terreno establecida por el especialista, mediante un perfil de estratos característicos, con información sobre el espesor de capas y los parámetros físicos y mecánicos del suelo.

- Parámetros físicos: humedad natural, límite líquido, índice de plasticidad, contenido de finos, Sistema Unificado de Clasificación de Suelos – SUCS, peso específico seco y saturado.
- Parámetros geomecánicos: cohesión, ángulo de fricción, módulo de elasticidad y coeficiente de Poisson.

Para el último campo se levantó información con respecto a los sondeos que fueron ejecutados en cada estudio: su tipo y profundidad. En cuanto al tipo se registraron calcatas, ensayos SPT, perforaciones de roto percusión, y geofísica con ReMi.

3.2. Software de elementos finitos – PLAXIS 2D

En la estructura de datos se cuenta con los asentamientos calculados por los especialistas, mediante las consideraciones establecidas por la teoría de la elasticidad para el cálculo de asentamientos inmediatos, y para el caso de asentamientos a largo plazo mediante los criterios de consolidación para arcillas [30]. Sin embargo, dichos datos registrados de los informes son variables, por lo que, como parte de la investigación, se optó por comparar dicha información con la calculada por elementos finitos con la herramienta computacional PLAXIS 2D [31].

Diversos autores han comparado los asentamientos obtenidos con PLAXIS 2D con los observados en campo o en modelos físicos, a raíz de lo cual han concluido que el software produce resultados adecuados, tanto en modelos drenados como no drenados, con un alto grado de concordancia a los asentamientos reales [32], [33].

Para el modelo de elementos finitos, se consideró un modelo de deformación plana de 15 nodos y una región rectangular de 20 m en horizontal y 10 m en vertical.

Para automatizar los procesos de cálculo de todos los estudios, se utilizó las opciones de “Experto” de PLAXIS, que permiten la conexión y control del software mediante comandos escritos en el lenguaje de programación Python, utilizando para ello la librería “plxscripting.easy” como puente de vinculación entre los paquetes de software.

Para la creación del algoritmo se partió del planteamiento de un modelo geotécnico, basado en la proyección de una carga estructural en el terreno. Para lograr esto, en PLAXIS 2D se siguieron los siguientes pasos:

- a. Definición del perfil estratigráfico, nivel freático y caracterización del suelo. Se consideraron los métodos drenado y no drenado tipo C, de acuerdo con las características friccionales o cohesivas del suelo, respectivamente. Para el método C se considera que el comportamiento del material es no drenado y que la rigidez y la resistencia se definen en términos de valores no drenados. El análisis se realiza en tensiones

totales, por lo que no se calculan explícitamente las presiones de poro en exceso ni las tensiones efectivas. Para este método, dado que la ecuación constitutiva está vinculada a los esfuerzos totales, el esfuerzo de corte no drenado es un input, y el coeficiente de Poisson debe tener un valor menor a 0.5 (0.499) para evitar singularidades del método en el software.

- b. Aplicación de carga estructural con la herramienta “lineload”.
- c. Selección de malla de tamaño medio (valor numérico: 0.06).
- d. Definición de una fase inicial sin carga, y una segunda fase con aplicación de la carga estructural.

Finalmente, con el algoritmo base de automatización para el ingreso de un grupo de variables correspondientes a un estudio, se completó el código con un proceso iterativo para la recolección de datos y generación del cálculo del asentamiento producido en el punto medio de aplicación de la carga, para cada uno de los estudios.

3.3. Modelo de redes neuronales

Para el desarrollo del modelo de redes neuronales se utilizó el lenguaje de programación Python, con las siguientes librerías:

- NumPy: Librería utilizada como estándar para el trabajo con datos numéricos en Python. Contiene estructuras para datos matriciales y arreglos multidimensionales [34].
- Matplotlib: Librería enfocada en la creación de visualizaciones estáticas, animadas e interactivas en Python, con posibilidades de customización y exportación a diversos formatos [35].
- Pandas: Librería que provee estructuras de datos de alto rendimiento y facilidad de utilización para el análisis de datos utilizando el lenguaje Python [36].
- Scikit-learn: Librería que contiene herramientas simples, eficientes y accesibles para el análisis de datos predictivo [37].
- TensorFlow: Librería que facilita la construcción y entrenamiento de modelos de aprendizaje profundo, mediante la API de alto nivel Keras [38].

La estructura de datos fue transformada a una estructura tipo DataFrame de la librería de Pandas para el lenguaje Python. Con los datos en este formato, fue posible estudiarlos preliminarmente con las herramientas de análisis proporcionados por la misma librería, y preprocesarlos con ayuda de la librería Scikit-learn, con el objetivo de normalizarlos. Este es un procedimiento vital para la efectividad de la red neuronal artificial, que colabora ampliamente a acelerar el proceso de aprendizaje computacional [39].

Se utilizó la herramienta StandardScaler, la cual centra y escala una serie de datos a una media de 0 y una desviación estándar de 1 [40].

El proceso de enseñanza del algoritmo informático se generó separando el 80 % de los datos registrados para utilizarlos en su entrenamiento, y el 20% de datos restantes en la calibración y validación de la eficacia de la red generada.

Para la compilación del modelo, se decidió utilizar el optimizador “Adam” y la función de pérdida incorporada fue el Error Medio Absoluto (MAE). Además, se incluyó un algoritmo de “early stopping” para el detenimiento del modelo en el número de épocas óptimo y el guardado de los ponderadores más adecuados para el modelo. En las pruebas hechas con la estructura de datos completa se encontró que el tamaño de lote (batch size) que entregó mejores resultados fue de 85 datos, mientras que en las pruebas con la base de datos dividida por provincia el tamaño de lote óptimo fue de 40 datos.

Se generaron gráficas de error para apreciar el proceso de aprendizaje computacional y se extrajeron los ponderadores más idóneos encontrados durante el entrenamiento. Estos se utilizaron para realizar una predicción final de capacidad de

carga y asentamientos para la estructura de datos completa, con la que se obtuvieron gráficas de comparación entre los valores reales y los predichos con el modelo.

4. Resultados y discusiones

4.1 Análisis de la información proveniente de estudios

Con base en la información de los estudios de mecánica de suelos levantada y registrada se tiene que, en la ciudad de Quito, hay una presencia predominante de arenas de grano fino y limos de baja plasticidad pertenecientes a la formación Cangahua; observándose también la existencia de sedimentos volcánicos en forma de suelos lacustres y fluviales, provenientes del volcán Cotopaxi.

Por otro lado, en Cuenca se tiene la presencia de las formaciones Loyola, Biblián, Tarqui, Turi, Célica, Azogues, Tutupamba, Plancharumi y Las Trancas. Hay una presencia considerable de depósitos de piemonte, coluviales y terrazas aluviales.

En la Figura 1 se puede notar que, en la ciudad de Cuenca, se ejecutan usualmente de 2 a 4 sondeos como parte de la investigación de campo. Sin embargo, en la ciudad de Quito el mínimo número de sondeos es 3, con un máximo de 18 sondeos realizados para extensiones de terreno de 20 000 a 30 000 m².

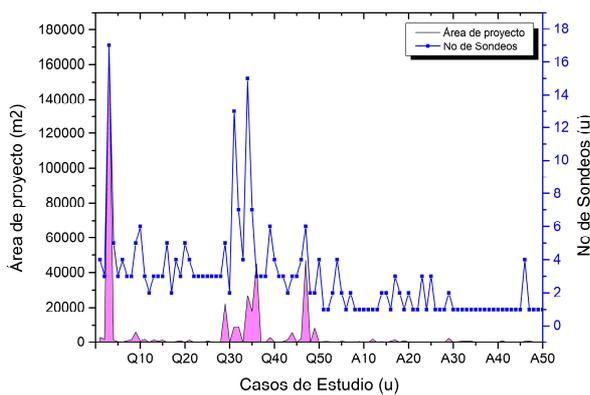


Figura 1. Área del proyecto y número de sondeos ejecutados.

En la ciudad de Quito se evidencia que para edificaciones residenciales, comerciales, industriales y/o educativas, el mínimo número de sondeos que se planifican en una investigación geotécnica es de 3.

De acuerdo con la información registrada de los sistemas de cimentación superficial planteados por los especialistas, se tiene que el 93% corresponde a zapatas aisladas con vigas de amarre arriostradas en ambas direcciones, un 5% a zapatas corridas y el 2% a losas de cimentación.

Así también, como se puede ver en la Figura 2, en el 76% de los informes procesados se presenta como un requisito fundamental el efecto del suelo en el comportamiento sísmico de las estructuras, determinado mediante el perfil del suelo, denominado según la Norma Ecuatoriana de la construcción (NEC) [12]. En la ciudad de Quito, 38 de los 50 estudios clasificaron al suelo como rígido, de tipo D. Para Cuenca, la mayoría de sus suelos se clasifican en perfiles tipo C y D, es decir, en suelos densos y rígidos, respectivamente.

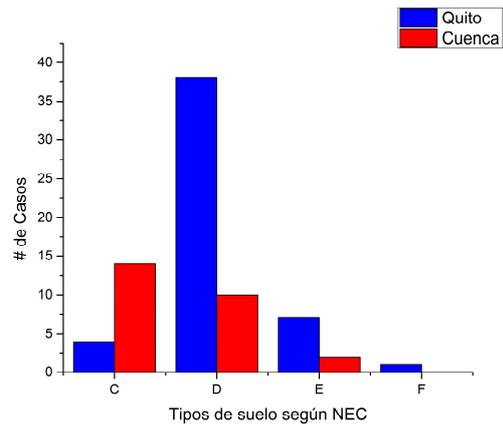


Figura 2. Perfil sísmico

En la Figura 3 se presenta la capacidad admisible reportada por cada uno de los estudios procesados, enumerados del 1 al 50 para las dos locaciones estudiadas. Como se puede apreciar, las resistencias admisibles de los suelos varían en un rango desde los 0.3 hasta los 4.5 kg/cm² (30 a 440 kN/m²). Los valores de resistencia menores a 1 kg/cm² (98 kN/m²) se asocian a materiales arcillosos y limosos de baja y alta plasticidad.

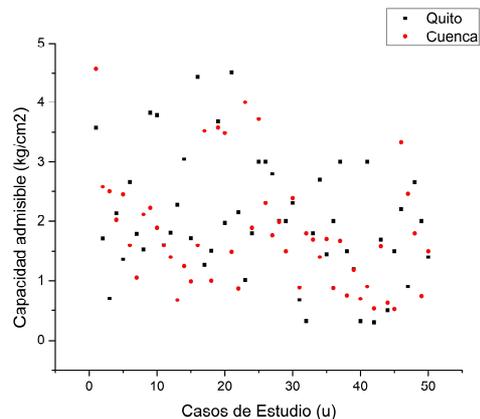


Figura 3. Capacidad de carga admisible proveniente de la información procesada.

En la Figura 4 se muestra el asentamiento reportado de cada estudio procesado, enumerado del 1 al 50 para ambas locaciones estudiadas. Aquí se evidencia que existen asentamientos totales de entre 6 a 8 cm, a excepción de 3 locaciones dentro de la ciudad de Cuenca que presentaron valores en el orden de los 14 cm, los mismos que están relacionados a suelos arcillosos de alta plasticidad, con valores de cohesión del orden de los 45 a 200 kPa, con módulos de elasticidad de 7 a 40 MPa, y recomendaciones de mejoramiento del suelo de fundación con material de mejoramiento y/o hormigón ciclópeo.

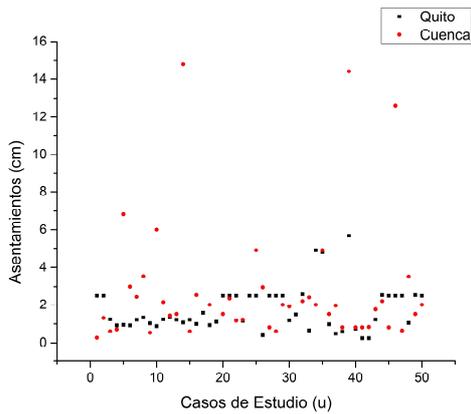


Figura 4. Asentamientos provenientes de la información procesada.

Como un análisis complementario, se generaron mapas de zonificación de acuerdo con las capacidades admisibles registradas en la estructura de datos, con ayuda del software ArcGIS. En la

Figura 5 se presenta el mapa de Azuay, en el que se puede observar que las capacidades están en el rango de 0.5 a 4.5 kg/cm² (30 a 440 kN/m²). Los sitios en donde se localizan los valores de capacidad menores a 1 kg/cm² (98 kN/m²) corresponden a áreas dentro de las parroquias del Valle, Paccha, Baños y Sinincay. En las parroquias de Cuenca y Ricaurte se tienen valores de capacidad mayores a 2 kg/cm². Para la mayoría de las parroquias aledañas a la ciudad de Cuenca se tienen capacidades entre 1 a 2 kg/cm² (98 a 196 kN/m²).

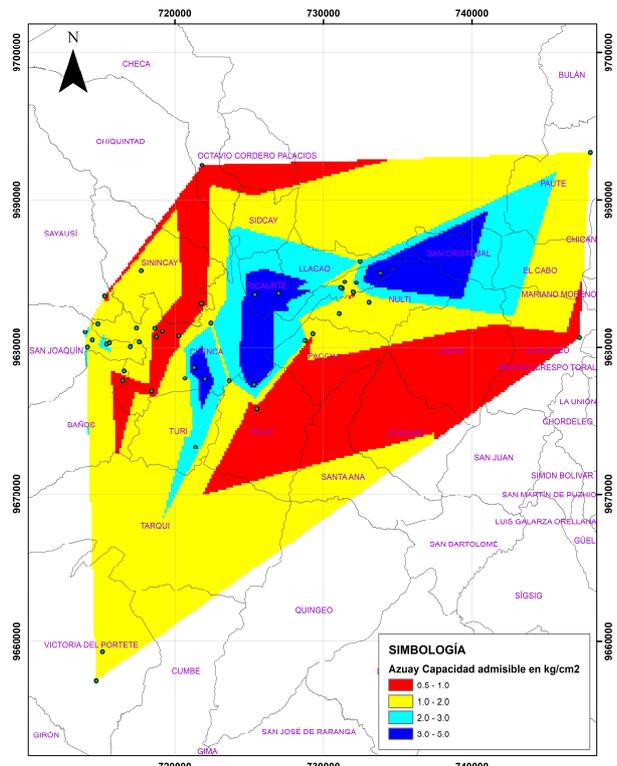


Figura 5. Mapa de zonificación de Azuay según capacidad admisible, con la división parroquial.

En el mapa generado para la provincia de Pichincha (Figura 6), los valores de capacidad fluctúan entre los 0.3 hasta los 4.5 kg/cm² (30 a 440 kN/m²). Existen sectores en Amaguaña y en el DMQ con capacidades menores a 1 kg/cm² (98 kN/m²). Además, en parroquias como Conocoto, Cumbayá, Nayón, Zámbez o Calderón se tienen valores mayores a 2 kg/cm² (196 kN/m²). Para el resto de las áreas, específicamente dentro del DMQ, se

registran capacidades en el orden de 1 a 2 kg/cm² (98 a 196 kN/m²).

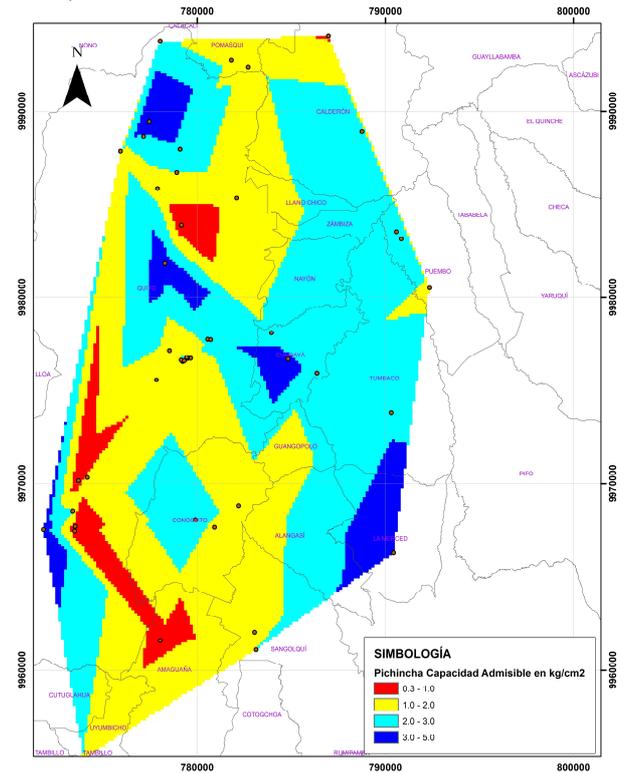


Figura 6. Mapa de zonificación de Pichincha según capacidad admisible, con la división parroquial.

A partir de la data registrada en los estudios, se generaron ciertas recomendaciones:

En Quito, el 40% de los estudios especifican que el mejoramiento del suelo de subsanste para la construcción de la cimentación no es necesario. Sin embargo, dejan a la elección del ingeniero a cargo la implementación de, por lo general, capas de 20 cm de material tipo subbase clase 3, compactada al 95% de su densidad máxima. Para Cuenca, por otro lado, todos los estudios procesados recomiendan la colocación de material de mejoramiento previo a la construcción de la fundación, utilizando el mismo suelo del sitio compactado al 95% de la densidad máxima u otros materiales, como subbases clase 3 o pedraplenes, en espesores que van desde los 30 hasta los 100 cm.

Subestructura: En el caso de Quito, todos los estudios determinaron la colocación de zapatas aisladas, recomendando su conexión con columnas de amarre en un 63% de las ocasiones. Así mismo, un 52% de los estudios señala que debe diseñarse una cimentación tipo rígida. En dos estudios se recomendó la construcción de una losa de cimentación. Para el caso de Cuenca, las recomendaciones indican la necesidad de construcción de zapatas aisladas con vigas de amarre arriostradas en ambas direcciones. En ciertos estudios se recomendaron las zapatas corridas unidireccionales y las losas de cimentación.

Drenaje: El 92% de los estudios recopilados de la ciudad de Quito y sus alrededores no cuenta con recomendaciones de drenaje. Sin embargo, en un estudio se menciona la necesidad de conexión de las bajantes a la red de alcantarillado, y en otro se sugiere la implementación de sistemas de drenaje superficiales e internos para evitar el empozamiento o infiltración de las aguas lluvias o servidas. En Cuenca, las recomendaciones de drenaje estuvieron presentes en un 88% de los estudios, pero son descritas de forma generalizada, dejando el detalle en manos del constructor. Hubo solo un 18% de estudios que detallaron las dimensiones de las tuberías y los detalles de filtros, geotextiles u otros elementos específicos.

Ejecución de obra: En general, tanto las recomendaciones de Quito como las de Cuenca se enfocaron en la necesidad de reducir el tiempo de exposición de los taludes de excavación a fenómenos naturales como lluvia o viento, que pueden provocar su debilitamiento.

Contrapiso: Los estudios recopilados de la ciudad de Quito no incluyen recomendaciones centradas en la construcción del contrapiso. Para la ciudad de Cuenca, este tipo de recomendaciones estuvieron presentes en el 38% de los estudios consultados. En estas se habla, generalmente, de la reposición del terreno natural con material pétreo, en capas de máximo 20 cm. En uno de los estudios se recomendó dejar un espacio libre debajo de la losa de contrapiso para permitir libremente la expansión o contracción del suelo.

4.2. Cálculo por elementos finitos con PLAXIS 2D

Como detalle práctico para el análisis interno realizado por PLAXIS, se tomó uno de los informes, correspondiente a un estudio localizado en la ciudad de Cuenca, en el sector Colinas del Paraíso. Según los datos previstos del estudio se requieren zapatas aisladas de 1.2 x 1.2 m, con proyección de una vivienda de 2 niveles, cuya carga estructural estimada según la NEC sería de 278 kPa. De acuerdo con la investigación de campo, el suelo de fundación está formado por materiales limosos de alta plasticidad, sin presencia de nivel freático, con una resistencia no drenada de 72 kPa, peso específico de 16 kN/m³, módulo de elasticidad de 6 327 kPa y coeficiente de Poisson de 0.35. Con dichos parámetros el asentamiento previsto por el especialista fue de 6 cm.

Al realizar el ingreso automático de los datos en PLAXIS 2D a través de Python, se generó el modelo geotécnico de "input". En la Figura 7 se presenta el modelo resuelto como "output", del que se obtiene un valor de asentamiento en el centro de la carga estructural de 11.75 cm.

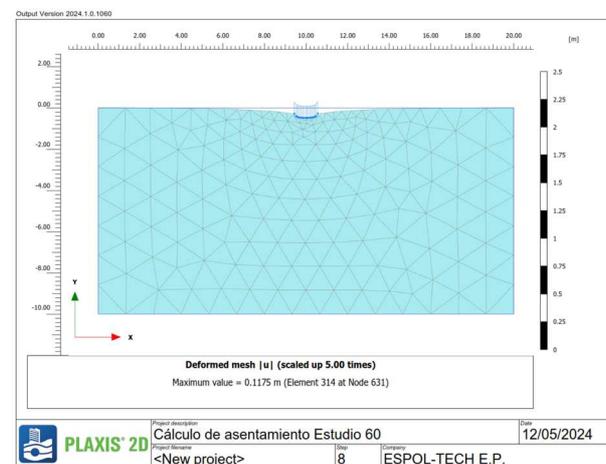


Figura 7. Cálculo de asentamientos en PLAXIS 2D. Output.

El asentamiento calculado por PLAXIS 2D para este caso particular fue un 95% mayor al presentado en el estudio geotécnico, lo que permite comprender que el criterio de deformaciones calculadas por MEF exige una mayor atención a los asentamientos esperados por proyección de cargas estructurales.

Al correr el algoritmo generalizado para el 100% de los datos recolectados, el tiempo de cálculo iterativo fue de aproximadamente 35 minutos.

En la

Figura 8 se muestra una comparación de los asentamientos (S) previstos en los estudios versus los asentamientos estimados por el software. Tal como se puede evidenciar, los valores calculados por MEF, en la mayoría de los casos, tienden

a ser mayores a los establecidos dentro de los informes (promedio de asentamiento por MEF equivalente a 2.86 del promedio de asentamientos de los informes), alcanzando en tres casos particulares valores entre 30 a 45 cm, los que al revisarse de manera puntual están asociados a materiales arcillosos y limosos de alta plasticidad con módulos de elasticidad menores a 8 000 kPa.

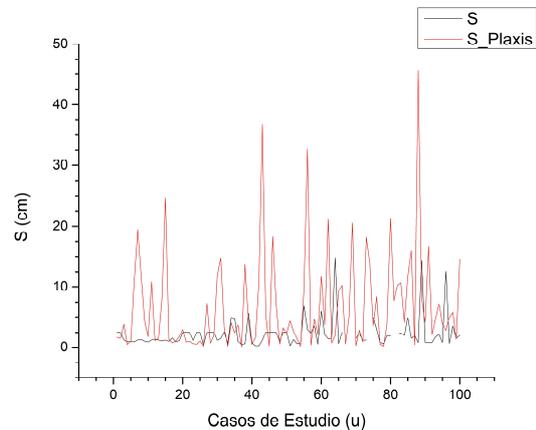


Figura 8. Comparación de los asentamientos especificados en los estudios con los calculados con PLAXIS 2D.

4.3. Red neuronal para predicción de parámetros geotécnicos

4.3.1. Estructura de datos sin separación por provincias

Se llevó a cabo una campaña de desarrollo de modelos de redes neuronales artificiales, con el objetivo de encontrar el conjunto de parámetros de entrada, la distribución de los datos de ingreso y la estructura y algoritmos que conlleven a las predicciones de capacidades de carga y asentamientos más precisas posibles.

Se incorporaron al modelo los datos generales del proyecto, además de las propiedades índice y mecánicas del estrato en el que, según cada estudio de mecánica de suelos, la cimentación se asentaría.

Al analizar la totalidad de los datos de la estructura, sin separarlos por provincia, los mejores resultados de predicción de capacidad de carga se consiguieron al incorporar como entrada del modelo los siguientes parámetros:

- Provincia
- Área del proyecto
- Cantidad de sondeos realizados
- Presencia de nivel freático
- Perfil sísmico
- Tipo de cimentación
- Profundidad de desplante de la cimentación
- Ancho de la cimentación
- Largo de la cimentación
- Carga estructural
- Índice plástico
- Contenido de finos
- Clasificación SUCS
- Peso específico
- Peso específico saturado
- Cohesión
- Ángulo de fricción
- Módulo de elasticidad
- Coeficiente de Poisson

Al entrenar el modelo con estos parámetros, se obtuvo la curva de error presentada en la Figura 9 (a).

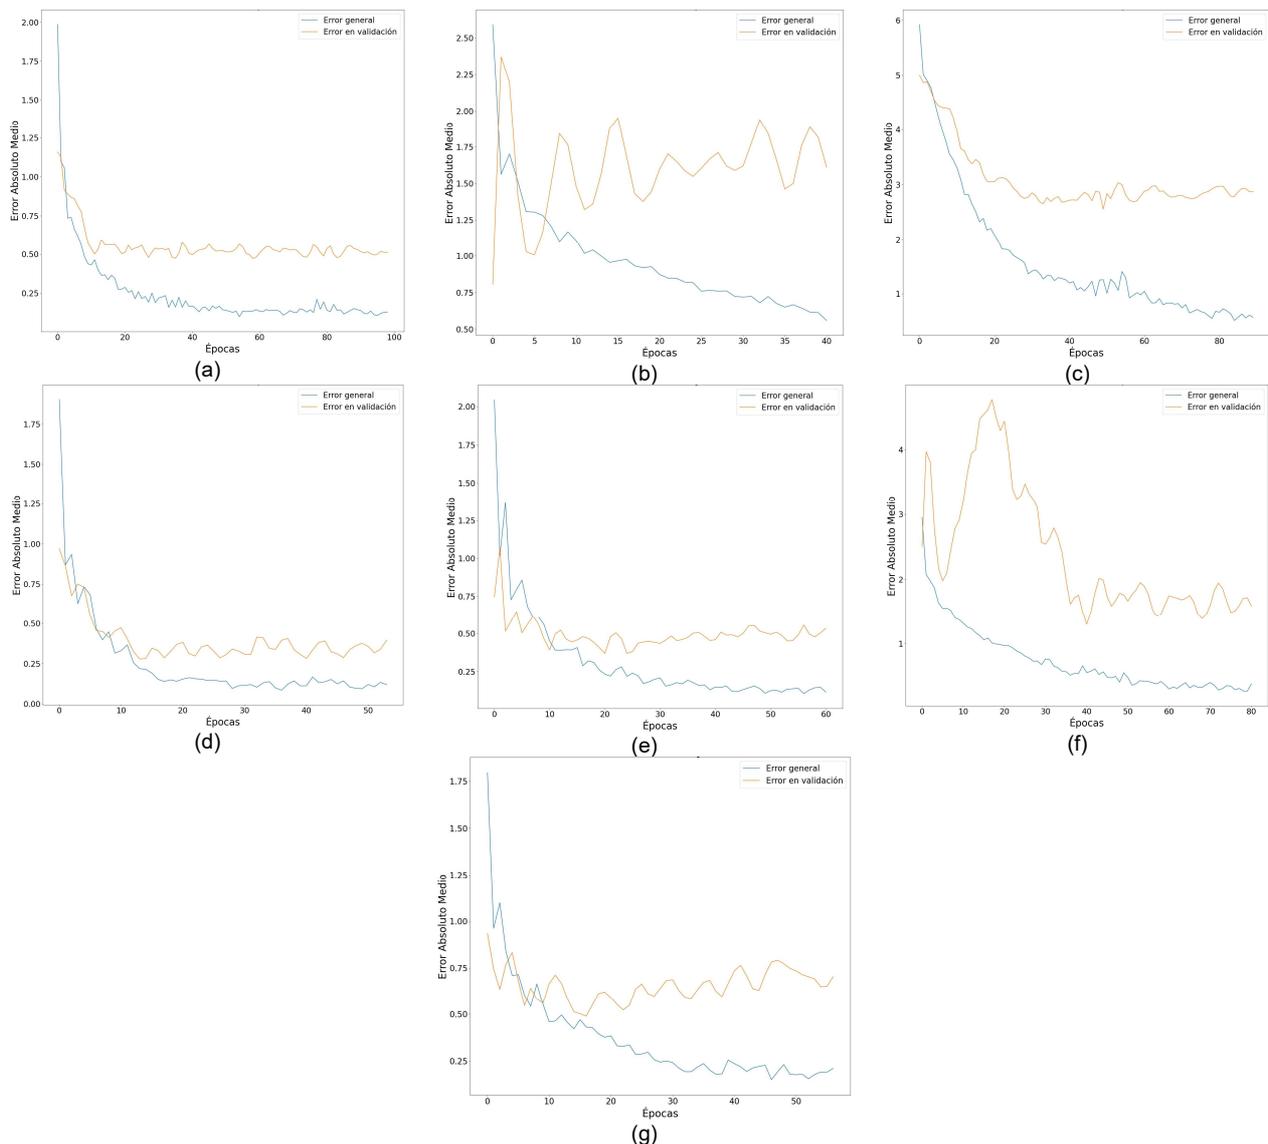


Figura 9. Evolución del error en la predicción de: (a) capacidad de carga, utilizando los datos de Azuay y Pichincha; (b) asentamientos, utilizando los datos de Azuay y Pichincha; (c) asentamientos calculados con PLAXIS 2D, utilizando los datos de Azuay y Pichincha; (d) capacidad de carga, utilizando los datos de Azuay; (e) capacidad de carga, utilizando los datos de Pichincha; (f) asentamientos, utilizando los datos de Azuay; (g) asentamientos, utilizando los datos de Pichincha.

El mínimo error medio absoluto obtenido fue de 0.472 kg/cm^2 (46.29 kN/m^2), conseguido en la época N°58, a pesar de que el modelo llega a una pseudo – estabilidad después de las 15 épocas. Al utilizar los ponderadores óptimos para predecir las capacidades de carga para toda la base de datos y compararlos con los valores reales, se obtuvo la Figura 10.

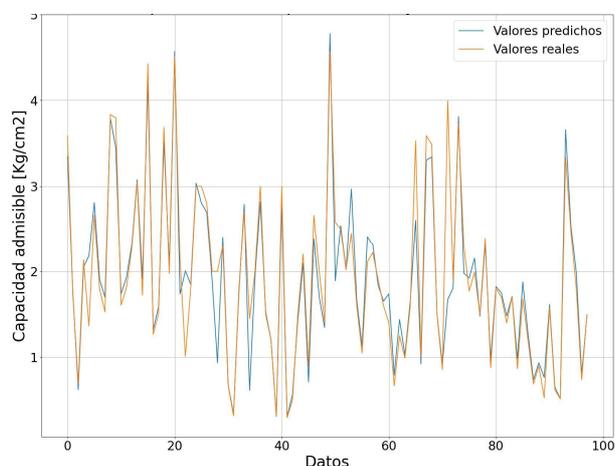


Figura 10. Comparación entre predicciones y valores reales de capacidad de carga, utilizando los datos de Azuay y Pichincha.

En la Figura 10 se puede observar que la serie de datos predichos se corresponde de manera adecuada con la de datos reales. Si bien el error mínimo conseguido es importante, es notable que éste incrementa por la presencia de ciertos puntos específicos en que el valor predicho es considerablemente distinto al real. A pesar de esto, en la mayoría de la serie los resultados obtenidos son muy similares.

De manera paralela, se encontraron los parámetros con los que se logró una mejor predicción de los asentamientos, tanto de los estudios de mecánica de suelos como de los obtenidos con el software PLAXIS 2D.

En la predicción de los asentamientos de los estudios de mecánica de suelos y de los calculados mediante PLAXIS 2D, se obtuvo los mejores resultados ingresando al modelo únicamente la siguiente lista de parámetros:

- Provincia
- Nivel freático
- Ancho de la zapata
- Carga estructural
- Contenido de finos
- Peso específico
- Peso específico saturado
- Cohesión
- Ángulo de fricción
- Módulo de elasticidad

- Coeficiente de Poisson

La curva de error obtenida con estos parámetros se presenta en la Figura 9 (b), donde se observa que el mínimo error medio absoluto al que el modelo llega es de 0.805 cm, un valor alto, que revela una alta variabilidad en los resultados de asentamientos obtenidos por los especialistas, misma que se confirma por la inestabilidad de la curva de error en validación, que no logra disminuir con el paso progresivo de las épocas. Utilizando los ponderadores óptimos obtenidos en el entrenamiento de la red, se obtuvo la Figura 11.

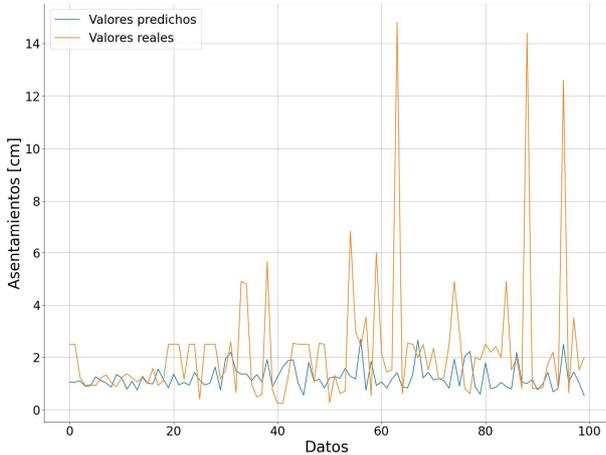


Figura 11. Comparación entre predicciones y valores reales de asentamientos, utilizando los datos de Azuay y Pichincha.

La correspondencia lograda entre la serie de valores predichos y reales es notablemente menor que para las capacidades de carga. Se observa especialmente la presencia de ciertos picos en la serie de valores reales, que resultan muy lejanos a las predicciones del modelo y aumentan considerablemente el error medio absoluto.

La curva de error obtenida se muestra para la predicción de asentamientos estimados por PLAXIS 2D se muestra en la Figura 9 (c). En esta se observa que la curva de error producida es más estable y, a pesar de que el mínimo error medio absoluto conseguido, de 2.552 cm (0.025 m), es mayor que para el caso anterior, la Figura 12 demuestra que la eficiencia de las predicciones para este caso fue mucho mayor. Esto permite comprender que, en el caso del cálculo de asentamientos hecho por los especialistas, existe variabilidad en la obtención de este parámetro.

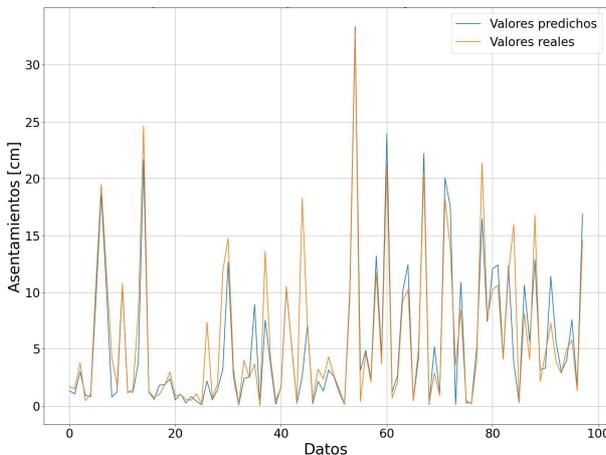


Figura 12. Comparación entre predicciones y valores reales de asentamientos calculados con PLAXIS 2D, utilizando los datos de Azuay y Pichincha.

El error de 2.552 cm proviene de ciertos puntos aislados en los que el valor real de asentamiento calculado con PLAXIS 2D es muy alto, por lo que la distancia con respecto a su predicción correspondiente es grande. A pesar de esto, es notable la

disminución de la variabilidad en los resultados de asentamientos, al tener una correspondencia aceptable entre las dos series de datos.

4.3.2. Estructura de datos con separación por provincias

Para el caso del análisis de los datos correspondientes a cada provincia de manera separada, los parámetros de entrada que produjeron las predicciones más acertadas fueron los mismos que anteriormente arrojaron los valores predichos más cercanos a los reales al utilizar la estructura de datos completa.

El análisis con los datos de la provincia de Azuay arrojó como resultado la curva de error de la Figura 9 (d), de donde se tiene que el mínimo error medio absoluto conseguido por el modelo fue de 0.278 kg/cm² (46.29 kN/m²), notablemente menor que el obtenido utilizando la estructura de datos completa.

La diferencia entre las series de datos predichos y reales es mínima, como se puede observar en la Figura 13. Esto revela la mejoría en la capacidad de predicción del modelo de redes neuronales al utilizar un grupo de datos que, a pesar de ser más reducido, facilita el hallazgo de relaciones más sólidas y generales entre los datos.

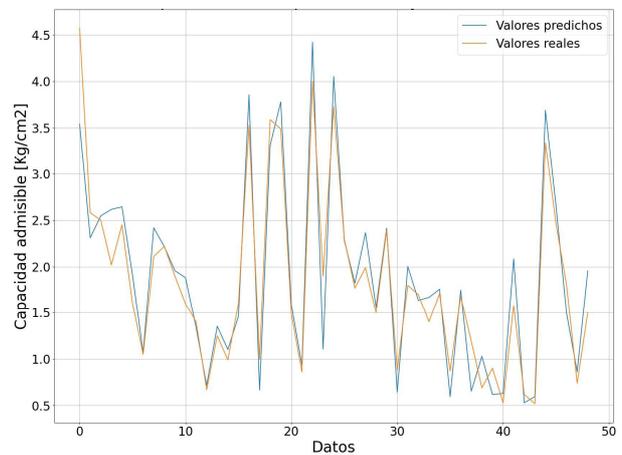


Figura 13. Comparación entre predicciones y valores reales de capacidad de carga, utilizando los datos de Azuay.

Para el caso de Pichincha, la curva de error obtenida se muestra en la Figura 9 (e). El mínimo error absoluto medio conseguido por el modelo fue de 0.369 kg/cm² (36.19 kN/m²), más alto que para Azuay, pero menor al encontrado utilizando la estructura de datos completa. De igual manera que para la predicción de los parámetros para Azuay, las diferencias entre las series de datos predichos y reales son pequeñas (véase Figura 14).

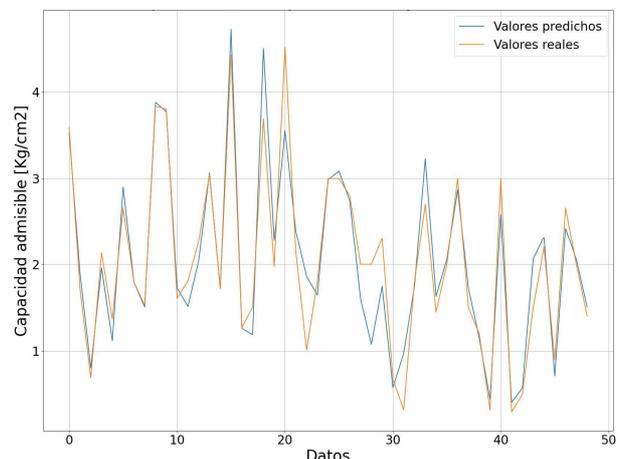


Figura 14. Comparación entre predicciones y valores reales de capacidad de carga, utilizando los datos de Pichincha.

Para la predicción de asentamientos, los parámetros de ingreso óptimos también fueron los mismos que arrojaron los mejores resultados al usar la estructura de datos completa.

El mínimo error medio absoluto obtenido fue de 1.298 cm (0.013 m). A pesar de que la evolución del error es más inestable y el error mínimo es mayor al producido en el análisis de la estructura de datos completa, en la Figura 15 se puede apreciar que la correspondencia entre las series de valores predichos y reales es más alta.

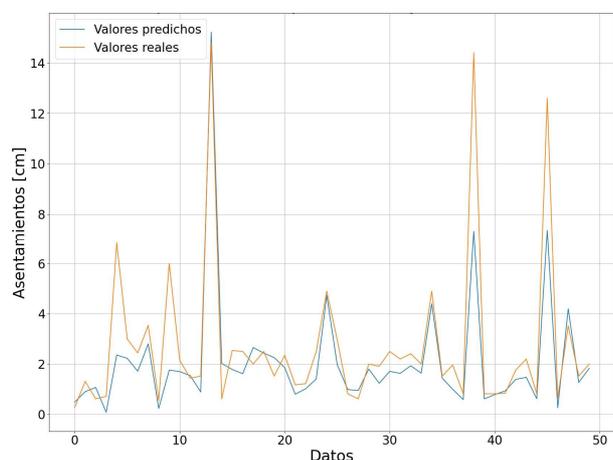


Figura 15. Comparación entre predicciones y valores reales de asentamientos, utilizando los datos de Azuay.

El mayor error medio es ocasionado, una vez más, por ciertos datos puntuales para los que la diferencia entre el valor predicho y el real es muy grande. Para el resto de la serie de datos, los resultados predichos y reales son muy cercanos.

Para el caso de la predicción de asentamientos utilizando únicamente los datos de Pichincha, se obtuvo la curva de error que se puede observar en la Figura 9 (g). La evolución del error es más estable que para la red entrenada con los datos de Azuay, y el mínimo también es más bajo, alcanzando un valor de 0.489 cm (0.0049 m).

Tal como se puede evidenciar en la Figura 16, las series de datos predichos y reales se distinguen claramente una de otra, pero sus diferencias no llegan a ser de magnitud importante, salvo para ciertos datos puntuales, tal como sucedió en los análisis anteriores.

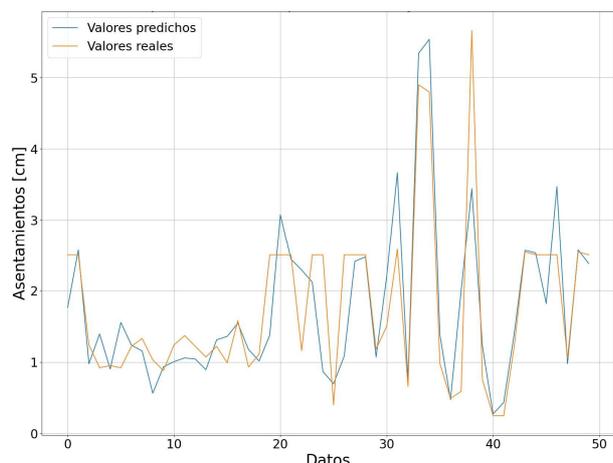


Figura 16. Comparación entre predicciones y valores reales de asentamientos, utilizando los datos de Pichincha.

Los resultados de la predicción de los asentamientos calculados por PLAXIS 2D a partir de la estructura de datos separada por provincias y de su comparación con los resultados de predicción de los asentamientos de los estudios de suelos

son muy similares al caso de análisis utilizando la estructura de datos completa, sin separación por provincias.

5. Conclusiones

La ejecución de estudios de mecánica de suelos enfocados a cimentaciones superficiales para edificaciones se basa en la Norma Ecuatoriana de la Construcción (NEC), por lo que la estructura de datos básica que debe contener cada estudio consiste en la ubicación, proyección de cargas estructurales, geología del lugar, investigación de campo mediante sondeos y ensayos de laboratorio, y determinación de los estados límites de falla (capacidad de carga) y de servicio (asentamientos).

Con la implementación del MEF a través de PLAXIS se concluye que los asentamientos que normalmente son estimados por la teoría de elasticidad deben ser analizados con más detalle, posibilitando además que el especialista geotécnico pueda retroalimentar sus cálculos con cargas estructurales más precisas, que provengan del especialista estructural.

Para la predicción de capacidades de carga, los menores errores, en promedio de 0.32 kg/cm² (31.4 kN/m²), se obtuvieron al dividir la estructura de datos por provincia, realizando un proceso de entrenamiento por separado para los datos de Azuay y para los de Pichincha. El entrenamiento con los datos combinados arrojó un error promedio de 0.47 kg/cm² (46.1 kN/m²).

Los parámetros de entrada que entrenaron al modelo que arrojó las predicciones con menor error medio para capacidades de carga fueron: área del proyecto, cantidad de sondeos realizados, presencia de nivel freático, perfil sísmico, tipo de cimentación, profundidad de desplante, ancho y largo de la cimentación, carga estructural aplicada, índice plástico, contenido de finos, clasificación SUCS, peso específico, peso específico saturado, cohesión, ángulo de fricción, módulo de elasticidad y coeficiente de Poisson.

Para la predicción de asentamientos, los resultados obtenidos de error medio, al utilizar la estructura de datos completa, fue de 0.81 cm. Para el caso de la estructura de datos dividida por provincia, se obtuvo un error medio de 0.489 cm para Pichincha y 1.298 cm para Azuay. A pesar de que el error medio en la predicción enfocada en Azuay fue mayor al de la realizada con la estructura de datos completa, los valores de la serie de asentamientos predichos fueron más cercanos a la de valores reales, como se puede observar en la Figura 15, con la excepción de 4 predicciones específicas. En estas, el asentamiento real es muy alto, de 6 a 14 cm, y la diferencia con el predicho fue de más de 4 cm, lo que ocasionó que el error medio para toda la serie aumente.

Los parámetros de entrada que entrenaron al modelo que arrojó las predicciones con menor error medio para asentamientos fueron aquellos necesarios para el cálculo numérico, que el software PLAXIS 2D utiliza como alimentación para sus cálculos: presencia de nivel freático, ancho de la cimentación, carga estructural aplicada, contenido de finos, peso específico, peso específico saturado, cohesión, ángulo de fricción, módulo de elasticidad y coeficiente de Poisson, además del dato de provincia.

Para lograr el establecimiento del algoritmo de redes neuronales desarrollado como una fuente de comprobación de la calidad de los resultados de un estudio geotécnico, es recomendable realizar una campaña de recolección y procesamiento de estudios de suelos mucho mayor, de tal forma que el entrenamiento y validación del modelo de redes neuronales sea más efectiva, permitiendo reducir los errores medios de las predicciones y se llegue a la madurez del algoritmo.

6. Referencias

- [1] J. L. Briaud, *Geotechnical engineering: unsaturated and saturated soils.*, 2nd ed. Hoboken, New Jersey: John Wiley & Sons, Inc. ISBN: 9781119788706, 2023. doi: <http://dx.doi.org/10.1002/9781119788720>.

- [2] M. A. Shahin, "A review of artificial intelligence applications in shallow foundations," *International Journal of Geotechnical Engineering*, vol. 9, no. 1. Maney Publishing, pp. 49–60, Feb. 08, 2015. doi: 10.1179/1939787914Y.0000000058.
- [3] O. I. Abiodun, A. Jantan, A. E. Omolara, K. V. Dada, N. A. Mohamed, and H. Arshad, "State-of-the-art in artificial neural network applications: A survey," *Heliyon*, vol. 4, no. 11, Nov. 2018, doi: 10.1016/j.heliyon.2018.e00938.
- [4] E. Díaz, V. Brotons, and R. Tomás, "Use of artificial neural networks to predict 3-D elastic settlement of foundations on soils with inclined bedrock," *Soils and Foundations*, vol. 58, no. 6, pp. 1414–1422, 2018, doi: <https://doi.org/10.1016/j.sandf.2018.08.001>.
- [5] B. M. Das and J. Cárdenas León, *Fundamentos de ingeniería de cimentaciones*, 7th ed. México, D.F.: Cengage Learning. ISBN: 9786074817478, 2012.
- [6] H. G. Poulos, "A Framework for Forensic Foundation Engineering," V. V. S. Rao and G. L. Sivakumar Babu, Eds., New Delhi: Springer, New Delhi., 2016, pp. 1–15. doi: 10.1007/978-81-322-2377-1_1.
- [7] B. Pang, E. Nijkamp, and Y. N. Wu, "Deep Learning With TensorFlow: A Review," *Journal of Educational and Behavioral Statistics*, vol. 45, no. 2. SAGE Publications Inc., pp. 227–248, Apr. 01, 2020. doi: 10.3102/1076998619872761.
- [8] R. Salgado, *The engineering of foundations, slopes and retaining structures*, Second ed. Boca Raton, FL: CRC Press Boca Raton, FL. ISBN: 9781315213361, 2022. doi: 10.1201/b22079.
- [9] D. P. Coduto, W. A. Kitch, and M. R. Yeung, *Foundation design: principles and practices*, 3rd ed. Boston: Pearson Education Limited. ISBN: 9780133411898, 2016.
- [10] A.-B. Huang and H.-S. Yu, *Foundation engineering analysis and design*, NV-. Boca Raton: CRC Press. ISBN: 9781351255394, 2018. Accessed: Apr. 22, 2024. [Online]. Available: <https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=1650602>
- [11] L. I. González de Vallejo, *Ingeniería Geológica*. Madrid: Pearson Prentice Hall. ISBN: 8420531049, 2004. Accessed: May 22, 2024. [Online]. Available: <https://worldcat.org/title/503402836>
- [12] MIDUVI and CAMICON, "Norma Ecuatoriana de la Construcción NEC-SE-GE." Ministerio de Desarrollo Urbano y Vivienda (MIDUVI), Cámara de la Industria de la Construcción (CAMICON), Quito, 2014.
- [13] K.-J. Bathe, *Finite Element Procedures in Engineering Analysis*, 2nd ed. New Jersey: Pearson Prentice Hall. ISBN: 9780979004957, 2014. Accessed: May 05, 2024. [Online]. Available: <https://worldcat.org/title/909923976>
- [14] C. T. F. Ross, *Finite Element Programs in Structural Engineering and Continuum Mechanics*, 1st ed. Chichester: Albion Pub. ISBN: 9781898563280, 1996. Accessed: Apr. 17, 2024. [Online]. Available: <https://worldcat.org/title/35115124>
- [15] N. Bradley and D. R. Vandenberge, "Beginner's Guide For Geotechnical Finite Element Analyses," Virginia Polytechnic Institute and State University. Blacksburg: Center for Geotechnical Practice and Research., 2015.
- [16] I. M. Smith, D. V. Griffiths, and L. Margetts, *Programming the finite element method*, 5th ed. Chichester: John Wiley & Sons Ltd. ISBN: 9781119189237, 2014. Accessed: Feb. 21, 2024. [Online]. Available: <http://site.ebrary.com/id/10756551>
- [17] D. M. Potts and L. Zdravković, *Finite element analysis in geotechnical engineering - Theory*, 1st ed. London: Thomas Telford Publishing. ISBN: 9780727727831, 1999.
- [18] A. Lees, *Geotechnical finite element analysis: a practical guide*. London: ICE Publishing. ISBN: 9780727760876, 2016.
- [19] D. M. Potts, L. Zdravkovic, T. I. Addenbrooke, K. G. Higgins, and N. Kovacevic, *Finite element analysis in geotechnical engineering - Application*, 1st ed. London: Thomas Thelford Publishing. ISBN: 0727727834, 2001.
- [20] Bentley Systems Inc, "Plaxis 2D 2024.1 - Material Models Manual 2D," Bentley Systems Inc, Pennsylvania, USA, Dec. 2023.
- [21] V. Plevris, A. Ahmad, and N. D. Lagaros, *Artificial Intelligence and machine learning techniques for civil engineering*, 1st ed. Hershey: IGI Global, 2023.
- [22] P. Isasi Viñuela and I. M. Galván León, *Redes de neuronas artificiales: un enfoque práctico*, 1st ed. Madrid: Prentice Hall. ISBN: 8420540250, 2004. Accessed: Apr. 27, 2024. [Online]. Available: <https://worldcat.org/title/60592052>
- [23] J. Brownlee, "What is the Difference Between a Batch and an Epoch in a Neural Network?" Accessed: May 17, 2024. [Online]. Available: <https://machinelearningmastery.com/difference-between-a-batch-and-an-epoch/>
- [24] J. L. Ba, J. R. Kiros, and G. E. Hinton, "Layer Normalization," *arXiv preprint*, Jul. 2016, doi: <https://doi.org/10.48550/arXiv.1607.06450>.
- [25] N. Srivastava, G. Hinton, A. Krizhevsky, and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *The Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929–1958, 2014, doi: 10.5555/2627435.2627498.
- [26] GitBook, "Loss Functions." Accessed: May 13, 2024. [Online]. Available: <https://edge-impulse.gitbook.io/docs/concepts/ml-concepts/neural-networks/loss-functions>
- [27] GitBook, "Optimizers." Accessed: May 13, 2024. [Online]. Available: <https://edge-impulse.gitbook.io/docs/concepts/ml-concepts/neural-networks/optimizers>
- [28] R. Holbrook and A. Cook, "Overfitting and Underfitting." Accessed: May 13, 2024. [Online]. Available: <https://www.kaggle.com/code/ryanholbrook/overfitting-and-underfitting>
- [29] MIDUVI and CAMICON, "Norma Ecuatoriana de la Construcción NEC-SE-GE." Ministerio de Desarrollo Urbano y Vivienda (MIDUVI), Cámara de la Industria de la Construcción (CAMICON), Quito, 2014.
- [30] R. Salgado, *The engineering of foundations, slopes and retaining structures*, Second ed. Boca Raton, FL: CRC Press Boca Raton, FL. ISBN: 9781315213361, 2022. doi: 10.1201/b22079 LK - <https://worldcat.org/title/1260689409>.
- [31] R. Brinkgreve, "PLAXIS 2D Reference Manual," Delft University of Technology & PLAXIS BV. ISBN 90-808079-8-2, Netherlands, 2004.
- [32] M. El Sawwaf, "Experimental and Numerical Study of Eccentrically Loaded Strip Footings Resting on Reinforced Sand," *Journal of Geotechnical and Geoenvironmental Engineering*, vol. 135, no. 10, pp. 1509–1518, Oct. 2009, doi: 10.1061/(asce)gt.1943-5606.0000093.
- [33] B. Gündüz, "Analysis of settlements of test embankments during 50 years - A Comparison Between Field Measurements and Numerical Analysis," Lund University, Lund, 2008. [Online]. Available: <http://www.byggmek.lth.se>
- [34] NumPy Developers, "NumPy: the absolute basics for beginners." Accessed: Feb. 26, 2024. [Online]. Available: https://numpy.org/doc/stable/user/absolute_beginners.html
- [35] Matplotlib development team, "Matplotlib: Visualization with Python." Accessed: Feb. 26, 2024. [Online]. Available: <https://matplotlib.org/>
- [36] Pandas developers, "Pandas documentation." Accessed: Feb. 26, 2024. [Online]. Available: <https://pandas.pydata.org/docs/index.html>
- [37] Scikit-learn Developers, "Scikit-learn." Accessed: May 12, 2024. [Online]. Available: <https://scikit-learn.org/stable/>
- [38] TensorFlow, "Por qué TensorFlow." Accessed: Feb. 26, 2024. [Online]. Available: <https://www.tensorflow.org/about?hl=es-419>
- [39] S. Bhanja and A. Das, "Impact of Data Normalization on Deep Neural Network for Time Series Forecasting," *arXiv preprint*, 2018.
- [40] Scikit-learn Developers, "Sklearn.preprocessing.StandardScaler." Accessed: May 12, 2024. [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>

CERTIFICACIÓN DE REVISIÓN DE PROYECTO DE TITULACIÓN

Por medio de la presente, Yo Davide Besenzon Venegas, Coordinador del Programa de Maestría en Geotecnia de la Escuela Superior Politécnica del Litoral (ESPOL), certifico que:

Con fecha 22 de enero de 2024, los estudiantes Freddy David Arias Montenegro y Edison Oswaldo Ávila Redrovan con números de identificación 1725668774 y 0106581119, respectivamente, de la Cohorte 5, presentaron la propuesta de su tema de titulación al Comité Académico del programa. Posteriormente, con fecha 31 de mayo de 2024, el Comité revisó y aprobó la propuesta mediante la resolución FICT-CA-GEOTEC-011-2024, cumpliendo con los requisitos establecidos para la aprobación del tema.

A partir de dicha aprobación, los estudiantes mantuvieron reuniones periódicas con el tutor designado, Jaime Asdrúbal Bojorque Iñiguez, para la elaboración y desarrollo de su proyecto de titulación, siguiendo los lineamientos establecidos por el programa. Con fecha 12 de junio de 2024, los estudiantes presentaron y sustentaron su proyecto de titulación ante el tribunal evaluador asignado, cumpliendo con el proceso formal de evaluación académica.

Por lo tanto, en calidad de Coordinador del Programa de Maestría en Geotecnia, certifico que el trabajo de titulación denominado "**Algoritmo de aprendizaje computacional mediante redes neuronales artificiales aplicado al diseño geotécnico de cimentaciones superficiales**", realizado por los estudiantes Freddy David Arias Montenegro y Edison Oswaldo Ávila Redrovan con números de identificación 1725668774 y 0106581119, respectivamente, ha sido revisado y evaluado conforme a los lineamientos y estándares establecidos por el programa.

Debido a circunstancias externas, no ha sido posible obtener las firmas de los involucrados (estudiante, tutor(es) y/o evaluadores). No obstante, en calidad de Coordinador del Programa, certifico que el proyecto cumple con los requisitos académicos y ha sido revisado para su presentación y archivo institucional.

Atentamente,



M. Sc. Davide Besenzon Venegas
Coordinador de la Maestría en Geotecnia