

# 5

## *Predicción De La Capacidad De Carga En Pilotes Cortos A Tracción Perforados En Suelo Cohesivo Aplicando Algoritmos De Inteligencia Artificial*

*Prediction Of The Uplift Capacity Of Short  
Bored Piles In Cohesive Soil Using Artificial  
Intelligence Algorithms*

### **Autores**

---

**Sudelys Regalado López**

Ing. Civil, Universidad Tecnológica de La Habana “José Antonio Echeverría”  
[sudelysre@civil.cujae.edu.cu](mailto:sudelysre@civil.cujae.edu.cu)  
<http://orcid.org/0009-0007-8069-9825>

---

**Willian D. Cobelo Cristiá**

Ing. Civil , Universidad Tecnológica de La Habana “José Antonio Echeverría”  
[wcobelo@civil.cujae.edu.cu](mailto:wcobelo@civil.cujae.edu.cu)  
<http://orcid.org/0009-0003-1532-8167>

---

**Jonathan Vázquez García**

Ing. Civil, Universidad Tecnológica de La Habana “José Antonio Echeverría”  
[jonathanvazgar@civil.cujae.edu.cu](mailto:jonathanvazgar@civil.cujae.edu.cu)  
<https://orcid.org/0009-0006-7893-9036>

---

**Alejandro Rosete**

Dr. , Universidad Tecnológica de La Habana “José Antonio Echeverría”  
[rosete@ceis.cujae.edu.cu](mailto:rosete@ceis.cujae.edu.cu)  
<https://orcid.org/0000-0002-4579-3556>

---

# 5

## *Predicción De La Capacidad De Carga En Pilotes Cortos A Tracción Perforados En Suelo Cohesivo Aplicando Algoritmos De Inteligencia Artificial*

### *Resumen*

La estimación de la capacidad de carga a tracción en pilotes cortos perforados en suelo cohesivo representa un desafío en la ingeniería geotécnica debido a la complejidad de la interacción suelo-pilote y a las estimaciones de los métodos tradicionales de cálculo. El objetivo principal es evaluar y comparar el desempeño de distintos algoritmos de aprendizaje automático para la predicción de la capacidad de carga a tracción, a partir de una base de datos generada mediante el Método de los Elementos Finitos. Se incluye la modelación numérica de pilotes cortos sometidos a tracción en suelo cohesivo utilizando PLAXIS 2D con la implementación de un modelo axial-simétrico, y la definición, entrenamiento, prueba y validación de modelos predictivos en la plataforma KNIME Analytics Platform mediante métricas estadísticas y esquemas de validación cruzada y externa. Los algoritmos evaluados fueron Regresión Lineal, Redes Neuronales Artificiales, Árbol de Decisión, Bosque Aleatorio y Conjunto de Árboles. Los resultados evidencian que los modelos de aprendizaje automático generan con alta precisión la respuesta numérica del sistema suelo-pilote, destacándose las Redes Neuronales Artificiales con un 99%. Estos resultados confirman el potencial del uso combinado de modelación numérica y aprendizaje automático como una herramienta eficiente y confiable para el análisis de cimentaciones profundas.

**Palabras Clave:** aprendizaje automático, capacidad de carga a tracción, modelación numérica, pilotes cortos perforados.

### *Abstract*

Estimating of the uplift capacity of short bored piles in cohesive soil represents a significant challenge in geotechnical engineering due to the complexity of soil–pile interaction and the uncertainties associated with traditional calculation methods. The main objective of this study is to evaluate and compare the performance of different machine learning algorithms for predicting uplift capacity using a database generated with the Finite Element Method. The study includes the numerical modeling of piles subjected to tensile loading in cohesive soil performed using PLAXIS 2D with an axisymmetric approach, as well as the development, training, and validation of predictive models within the KNIME Analytics Platform employing statistical metrics and both cross-validation and external validation schemes. The algorithms evaluated in this study include Linear Regression, Artificial Neural Networks, Decision Tree, Random Forest and Tree Ensemble models. The results show that machine learning models accurately reproduce the numerical response of the soil–pile system, with Artificial Neural Networks achieving the best performance, reaching an accuracy of 99%. These findings clearly confirm the potential of combining numerical modeling and machine learning as both an efficient and reliable tool for the analysis of deep foundations.

**Keywords:** machine learning, uplift capacity, numerical modeling, short bored piles.

**Nota Editorial: Recibido: 23 de febrero 2026 Aceptado: 24 de marzo 2026**

## 1. INTRODUCCIÓN

La ingeniería de cimentaciones enfrenta importantes desafíos en la estimación precisa de la capacidad de carga a tracción de pilotes de hormigón armado perforados en suelo cohesivo, debido a la compleja interacción suelo-pilote y al comportamiento no lineal y heterogéneo del suelo de soporte, característico de este tipo de material [1]. Los métodos tradicionales de cálculo, basados en formulaciones empíricas, suelen presentar limitaciones significativas al no representar adecuadamente los mecanismos reales de transferencia de carga, lo que conduce a resultados conservadores o con altos niveles de incertidumbre.

En particular, la evaluación de la capacidad de carga a tracción resulta más compleja que la de compresión, dado que el mecanismo resistente está dominado principalmente por la adherencia desarrollada a lo largo del fuste del pilote y por la movilización del suelo alrededor del pilote durante el proceso de tracción. Estudios experimentales y numéricos han demostrado que la capacidad de carga a tracción suele ser inferior a la de compresión y altamente sensible a parámetros como la cohesión no drenada, la geometría del pilote y las condiciones de instalación [2]. Estas características hacen que los métodos empíricos tradicionales, presenten una variabilidad considerable en sus resultados cuando se aplican al suelo cohesivo [3].

Ante estas limitaciones, la modelación numérica mediante el Método de los Elementos Finitos (MEF) se ha consolidado como una herramienta eficaz para analizar el comportamiento de pilotes bajo diferentes condiciones de carga. El uso de softwares especializados como PLAXIS 2D permite simular de forma detallada la interacción suelo-pilote, incorporando modelos constitutivos avanzados y representando adecuadamente los estados de esfuerzo y deformación del sistema [4, 5]. No obstante, la confiabilidad de los resultados numéricos depende críticamente de la correcta selección y calibración de los parámetros geotécnicos, lo cual puede resultar complejo cuando la información disponible es limitada o incierta [6].

En paralelo, el desarrollo de la inteligencia artificial y, en particular, del aprendizaje automático, ha abierto nuevas oportunidades para abordar problemas geotécnicos caracterizados por relaciones altamente no lineales entre múltiples variables. Diversos estudios han demostrado que algoritmos como las Redes Neuronales Artificiales y los métodos de ensamble pueden ofrecer predicciones precisas y eficientes en problemas de capacidad de carga y comportamiento del suelo [7-9]. Estas técnicas permiten aprender patrones complejos directamente a partir de los datos, reduciendo la dependencia de hipótesis simplificadoras propias de los métodos clásicos.

Sin embargo, no existe un consenso claro sobre qué algoritmo de aprendizaje automático ofrece el mejor desempeño para la predicción de la capacidad de carga a tracción de pilotes, especialmente cuando los datos de entrenamiento provienen de simulaciones numéricas en lugar de ensayos de campo o laboratorio. Aunque algunos estudios han integrado el aprendizaje automático con resultados de modelación numérica para mejorar la predicción de la capacidad última de pilotes, la mayoría se ha centrado en cargas de compresión, dejando un vacío importante en el análisis de pilotes sometidos a tracción en suelo cohesivo [10, 11].

Se considera que el desempeño de los modelos de aprendizaje automático depende no solo del algoritmo seleccionado, sino también de la naturaleza del conjunto de datos, la selección de variables de entrada y los criterios utilizados para evaluar la precisión y la capacidad de generalización del modelo. La comparación sistemática de diferentes algoritmos empleando métricas estadísticas resulta esencial para identificar enfoques confiables aplicables a problemas geotécnicos reales [12, 13].

El objetivo de este artículo es desarrollar y evaluar modelos de aprendizaje automático para la predicción de la capacidad de carga última a tracción de pilotes cortos de hormigón armado perforados en suelo cohesivo, utilizando como base de entrenamiento una base de datos generada mediante modelación numérica con el Método de los Elementos Finitos. Asimismo, se realiza una comparación del desempeño de diferentes algoritmos, con el propósito de identificar el modelo que ofrezca mayor precisión y confiabilidad, contribuyendo al mejoramiento de las herramientas de análisis y diseño de cimentaciones profundas frente a las limitaciones de los métodos empíricos tradicionales.

## 2. MATERIALES Y MÉTODOS

### 2.1. MODELACIÓN NUMÉRICA MEDIANTE EL MÉTODO DE LOS ELEMENTOS FINITOS

La modelación numérica constituye el eje metodológico de esta investigación, ya que permite cuantificar con detalle el comportamiento de pilotes cortos perforados en suelo con comportamiento cohesivo sometidos a tracción bajo condiciones reales de interacción suelo-pilote. El objetivo principal de la modelación consiste en reproducir el desarrollo de los esfuerzos cortantes a lo largo del fuste, la evolución del campo de deformaciones durante la tracción, y la aparición del mecanismo de falla que define la capacidad de carga última

## 2.2. REPRESENTACIÓN AXIAL-SIMÉTRICA

Debido a la geometría circular de los pilotes y la aplicación de cargas axiales centradas, se utilizó un modelo axial-simétrico implementado en PLAXIS 2D. Este enfoque simplificado permite reproducir el comportamiento tridimensional con un menor costo computacional, siempre que las condiciones del problema (homogeneidad del suelo y carga axial) lo permitan, ver Figura 1.




Fig. 1- Modelo axial-simétrico de un pilote sometido a carga axial de tracción.

## 2.3. DEFINICIÓN DE LA GEOMETRÍA

Se consideró un elemento de cimentación de hormigón armado, caracterizado por una sección transversal circular y fuste recto. La geometría del pilote se definió mediante la combinación de 7 longitudes ( $L_p = 1,20; 1,50; 1,80; 2,10; 2,40; 2,70; 3,00$  m) y 3 diámetros ( $D_p = 0,20; 0,25; 0,30$  m), lo que permitió abarcar un rango representativo de condiciones de diseño para el empleo de esta solución de cimentaciones en estructuras ligeras sometidas a cargas de vientos extremos, como sucede en la estructura de soporte de paneles solares colocados en tierra, donde predominan las cargas de tracción en la unión estructura-pilote.

## 2.4. EXTENSIÓN DEL DOMINIO DE SUELO CIRCUNDANTE

Se realizó un proceso de calibración del dominio de suelo para seleccionar dimensiones óptimas que garantizaran la confiabilidad de la capacidad de carga obtenida ( $Q_u$ ) y un bajo costo computacional. La calibración matemática se llevó a cabo considerando inicialmente la dimensión más desfavorable del problema (definida para una longitud del pilote de 3,00 m combinada con un diámetro de 0,20 m). El proceso se desarrolló en dos etapas: primero con elementos finitos triangulares de 6 nodos y posteriormente con elementos de 15 nodos, evaluando tres dimensiones del dominio ( $1,5L_p \times 2,5L_p; 2L_p \times 2,5L_p; 3L_p \times 2,5L_p$ ) y tres niveles de refinamiento de malla (media, fina y muy fina). A partir del análisis comparativo, se muestra en la Tabla 1, que a medida que se incrementa la extensión del dominio y se refina a malla, los valores de  $Q_u$  tienden a estabilizarse, siendo esta tendencia más marcada en los modelos con elementos de 15 nodos y malla muy fina. Asimismo, se confirmó que el incremento del dominio más allá de ciertas dimensiones no produce variaciones significativas en los resultados, lo que evidencia que se ha eliminado la influencia de los bordes del modelo, por lo que se adoptó como configuración definitiva: elemento finito triangular de 15 nodos, malla muy fina y dimensiones del dominio de  $2L_p \times 2,5L_p$ .

**Tabla 1-** Calibración de las dimensiones del dominio suelo con elementos finitos triangulares de 6 y 15 nodos.

Dimensiones del dominio suelo	Mallado	Fy (kN/rad)	Qu (kN)
<b>Elemento finito triangular de 6 nodos</b>			
1,5Lp x 2,5Lp (4,5 x 7,5 m)	Medio	7,53	47,3
	Fino	7,34	46,1
	Muy fino	7,37	46,3
2Lp x 2,5Lp (6 x 7,5 m)	Medio	8,04	50,5
	Fino	7,58	47,6
	Muy fino	7,67	48,2
3L x 2,5Lp (9 x 7,5 m)	Medio	8,10	50,9
	Fino	7,41	46,5
	Muy fino	7,61	47,8
<b>Elemento finito triangular de 15 nodos</b>			
1,5Lp x 2,5Lp (4,5 x 7,5 m)	Medio	7,03	44,1
	Fino	6,97	43,8
	Muy fino	6,98	43,8
2Lp x 2,5Lp (6 x 7,5 m)	Medio	6,92	43,5
	Fino	6,96	43,7
	Muy fino	6,97	43,8
3L x 2,5Lp (9 x 7,5 m)	Medio	7,24	45,5
	Fino	6,96	43,7
	Muy fino	7,07	44,4

## 2.5. CARACTERIZACIÓN DE LOS MATERIALES

Se definieron siete tipos de suelo cohesivo (arcilla) con valores de cohesión ( $C$ ), peso específico ( $\gamma$ ), módulo de elasticidad ( $E$ ) y coeficiente de Poisson ( $\nu$ ), que se presentan en la Tabla 2. El suelo se representó mediante el modelo elasto-plástico *Mohr-Coulomb*.

**Tabla 2-** Propiedades de los suelos empleados en la modelación numérica.

Tipo de suelo	$C$ (kPa)	$\gamma$ (kN/m <sup>3</sup> )	$E$ (kPa)	$\nu$
Arcilla	30	16	6000	0,27
	35	16	7000	0,27
	40	16	8000	0,27
	45	16	9000	0,30
	50	16	10000	0,30
	55	17	12000	0,35
	60	17	13000	0,35

Para modelar el comportamiento del material de los pilotes se utilizó un modelo de daño plástico específico para el hormigón (*Concrete Model*). Los parámetros adoptados fueron: peso específico ( $\gamma$ ), módulo de elasticidad ( $E$ ), coeficiente de Poisson ( $\nu$ ), resistencia característica a compresión ( $f'_c$ ) y tracción ( $f'_t$ ) y energía de fractura a compresión ( $G_c$ ) y tracción ( $G_t$ ), como se presenta en la Tabla 3.

**Tabla 3-** Propiedades del hormigón para el modelo de daño plástico.

Material	Modelo	$\gamma$ (kN/m <sup>3</sup> )	$E$ (kN/m <sup>2</sup> )	$\nu$	$f'_t$ (kN/m <sup>2</sup> )	$G_t$ (kN/m)	$f'_c$ (kN/m <sup>2</sup> )	$G_c$ (kN/m)
Hormigón	Concrete	24	28000000	0,2	2200	0,05	25000	30

## 2.6. PROPIEDADES DE LA INTERFAZ SUELO-ESTRUCTURA

La interacción entre el fuste y el suelo se modeló con elementos de interfaz. En PLAXIS, los parámetros resistentes de la interfaz se definen a partir de los del suelo mediante el factor de reducción  $R_{inter}$ . Para suelo con comportamiento cohesivo puro ( $\varphi=0$ ), por lo que la resistencia al corte de la interfaz queda gobernada exclusivamente por la cohesión:  $t_{max}=c_i=R_{inter}\cdot C$ . En esta investigación se adoptó  $R_{inter}=0,5$ , lo cual implica  $c_i=0,5\cdot C$ .

## 2.7. APLICACIÓN DE CARGAS

Se adoptó un procedimiento de análisis controlado por desplazamientos prescritos. El análisis se desarrolló en cuatro fases de cálculo: una primera fase de estado inicial del suelo, y tres fases adicionales en las que se aplicaron desplazamientos verticales prescritos en la cabeza del pilote de 15 mm, 25 mm y 35 mm, este último valor garantiza el desarrollo de la curva carga-deformación tanto en la etapa elástica como en la elastoplástica del comportamiento de los materiales.

## 2.8. METODOLOGÍA PARA LA ESTIMACIÓN DE LA CAPACIDAD DE CARGA ÚLTIMA A TRACCIÓN

La identificación de la capacidad o resistencia última en una curva carga-asentamiento sigue siendo difícil de alcanzar. Se reconocen internacionalmente muchos criterios para interpretar la capacidad de carga última en cimentaciones profundas y su evolución sugiere que no existe un consenso concluyente sobre el uso de estos criterios. Para esta investigación se adoptó el criterio basado en la deformación por su simplicidad, considerando el valor tradicional de desplazamiento vertical en la cabeza del pilote correspondiente al 10% del diámetro del pilote. Se reconoce que este criterio puede conllevar en algunos casos a valores que superan a los determinados en pruebas de cargas estáticas [10], aspecto que puede ser atenuado en la selección de la seguridad del diseño.

## 2.9. GENERACIÓN DE LA BASE DE DATOS

Se construyó una base de datos a partir de las variables geométricas del pilote (longitud y diámetro) y las propiedades del suelo (cohesión, peso específico, módulo de elasticidad y coeficiente de Poisson), la cual integró 147 registros, producto de combinar 7 longitudes de pilote, 3 diámetros y 7 tipos de suelo cohesivo, tal como se muestra en la Figura 2. Para todas las configuraciones estudiadas, la capacidad de carga última a tracción aumenta de manera casi lineal con el incremento de la cohesión del suelo. Este comportamiento puede atribuirse a la relación directa existente entre la cohesión del suelo y la resistencia por adherencia movilizada a lo largo del fuste del pilote, la cual constituye el principal mecanismo resistente frente a la carga de tracción en suelo cohesivo. Asimismo, se evidencia que, para un mismo valor de cohesión, los pilotes de mayor longitud presentan valores superiores de  $Q_u$ , lo cual se explica por el aumento de la superficie de contacto suelo-pilote disponible para la movilización de la resistencia por adherencia. De igual forma, al comparar las curvas correspondientes a diferentes diámetros, se aprecia que el incremento del diámetro del pilote conlleva también un aumento de la capacidad de carga última, aunque manteniendo una tendencia similar en cuanto a la pendiente de las curvas.

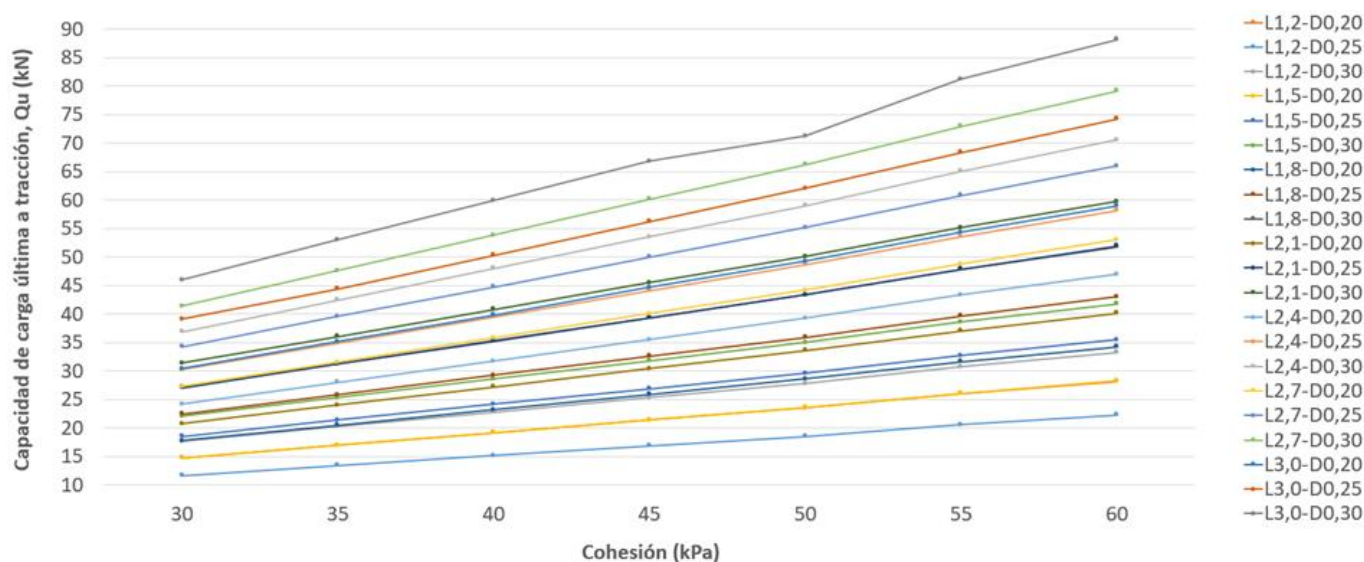


Fig. 2- Capacidad de carga última a tracción obtenida de la modelación numérica.

## 2.10. EMPLEO DE MODELOS DE APRENDIZAJE AUTOMÁTICO

Para el procedimiento de calibración, entrenamiento y validación de los algoritmos que se implementan en este estudio, se utilizó la plataforma *KNIME Analytics Platform* [14]. El conjunto de datos numéricos generados en el modelo de elementos finitos se dividió en 85% para el entrenamiento y prueba, implementado mediante una validación cruzada de 10 particiones, como se hizo en el estudio [15]. Se reservó un 15% aleatoriamente como conjunto de validación externa para evaluar el desempeño final de cada modelo con datos no utilizados durante ninguna etapa de entrenamiento, procedimiento empleado en [16].

Los modelos empleados en este estudio fueron: Regresión Lineal, Redes Neuronales Artificiales, Árbol de Decisión (*Decision Tree*), Bosque Aleatorio (*Random Forest*) y Conjunto de Árboles (*Tree Ensemble*). Luego de definir el flujo de trabajo en la plataforma *KNIME Analytics Platform* correspondiente a cada algoritmo, se realizó un proceso de calibración con el objetivo de obtener el mejor ajuste posible para la predicción de la capacidad de carga última a tracción. Esta calibración se llevó a cabo a partir de los valores obtenidos en la modelación numérica, ajustando los parámetros de cada modelo para optimizar su capacidad predictiva y su desempeño en términos de precisión y generalización. Para evaluar su desempeño se utilizaron el coeficiente de determinación ajustado ( $R^2$  ajustado), el error absoluto medio (*Mean Absolute Error*, MAE) y la raíz del error cuadrático medio (*Roof of the Mean Square Error*, RMSE).

En cuanto al preprocesamiento, se normalizaron (escalando entre 0 y 1) aquellos algoritmos sensibles a la magnitud de las variables, como la Regresión Lineal y las Redes Neuronales Artificiales. Para los algoritmos basados en estructuras de árboles (Árbol de Decisión, Bosque Aleatorio y Conjunto de Árboles) no se normalizaron..

## 2.11. GENERACIÓN DE DATOS SINTÉTICOS

A partir de los resultados obtenidos con los datos de modelación numérica, se procedió a la generación de una nueva base de datos donde se modifican las variables de entrada asociadas a la geometría del pilote y a las propiedades del suelo densificadas mediante incrementos uniformes (de 0,05 m para las longitudes del pilote y 2 kPa para la cohesión del suelo). Una vez definidas las nuevas combinaciones de entrada, estas se introdujeron en los modelos de aprendizaje automático previamente calibrados, los cuales generaron valores sintéticos de la carga última a tracción (Qu). La integración de todas las predicciones permitió construir una base de datos ampliada que totalizó 8436 registros

## 2.12. DISEÑO EXPERIMENTAL

Se desarrolló un esquema experimental basado en tres pruebas diferenciadas:

Prueba 1 (Datos de la modelación numérica): Evaluación del desempeño de los algoritmos utilizando únicamente los datos obtenidos de las simulaciones numéricas (147 registros).

Prueba 2 (Datos sintéticos): Ampliación de la base de datos mediante la generación de datos sintéticos por cada uno de los algoritmos, conservando la distribución estadística de las variables originales, y evaluación de los modelos con este conjunto ampliado (8436 registros).

Prueba 3 (Datos sintéticos sin Bosque Aleatorio y Conjunto de Árboles): Evaluación de los algoritmos utilizando únicamente los datos sintéticos generados, excluyendo los resultados de Bosque Aleatorio y Conjunto de Árboles para analizar si la eliminación de los datos generados por algoritmos de ensamble contribuye a mejorar la estabilidad y generalización de los modelos (4218 registros).

# 3. RESULTADOS

## 3.1. ANÁLISIS DE LOS RESULTADOS DE LAS PRUEBAS

En la Tabla 4 se presentan los resultados obtenidos a partir de la aplicación de los algoritmos calibrados sobre la base de datos original, conformada exclusivamente por los registros derivados de las simulaciones numéricas. En los modelos se realiza una calibración interna con el conjunto de datos de entrenamiento y posteriormente se evalúan mediante validación externa utilizando datos independientes, con el objetivo de verificar su capacidad de generalización.

**Tabla 4-**Métricas de desempeño para la primera prueba.

Algoritmo	Datos de la modelación numérica					
	Calibración interna			Validación externa		
	R <sup>2</sup> ajustado	MAE	RMSE	R <sup>2</sup> ajustado	MAE	RMSE
Regresión Lineal	0,94	2,86	4,17	0,93	2,87	3,16
RNA	0,99	0,97	1,70	0,99	0,79	1,17
Árbol de Decisión	0,84	5,91	7,22	0,83	5,69	6,16
Bosque Aleatorio	0,87	4,42	6,02	0,90	3,74	4,78
Conjunto de Árboles	0,87	4,35	5,95	0,88	4,14	5,05

Los resultados indican que la RNA fue el modelo con mejor desempeño global en esta prueba, alcanzando valores de R<sup>2</sup> ajustado superiores a 0,99 y los errores (MAE y RMSE) más bajos tanto en calibración interna como externa. El modelo lineal mostró un rendimiento sólido y comparable, con un buen equilibrio entre ajuste y generalización. Por el contrario, los algoritmos basados en árboles presentaron valores de R<sup>2</sup> ajustado más bajos y los errores más altos, indicando una capacidad predictiva limitada con el conjunto de datos original de tamaño reducido, aunque igualmente cuentan con buena precisión.

En la Tabla 5 se presentan los resultados correspondientes a la segunda prueba experimental, en la cual los algoritmos fueron evaluados empleando la base de datos ampliada que incorpora registros sintéticos.

**Tabla 5-** Métricas de desempeño para la segunda prueba.

Algoritmo	Datos sintéticos					
	Calibración interna			Validación externa		
	R <sup>2</sup> ajustado	MAE	RMSE	R <sup>2</sup> ajustado	MAE	RMSE
Regresión Lineal	0,94	2,36	3,22	0,95	2,60	3,24
RNA	0,95	2,09	2,80	0,97	1,83	2,37
Árbol de Decisión	0,92	2,29	3,55	0,88	4,00	5,18
Bosque Aleatorio	0,93	2,32	3,31	0,90	3,49	4,55
Conjunto de Árboles	0,93	2,34	3,36	0,89	3,77	4,86

La ampliación de los datos produjo efectos diferenciados. La RNA mantuvo un excelente desempeño, logrando el mejor R<sup>2</sup> ajustado en validación externa (0,97) y los errores más bajos. La regresión lineal mostró estabilidad y equilibrio con los resultados de la primera prueba. El Árbol de Decisión mejoró su calibración interna, pero su rendimiento en validación externa decayó significativamente. Los algoritmos de ensamble mejoraron sus métricas de calibración interna, pero su generalización se mantuvo por debajo de los modelos lineales y la RNA.

En la Tabla 6 se presentan los resultados de la tercera prueba experimental, desarrollada a partir de la base de datos depurada.

**Tabla 6.** Métricas de desempeño para la tercera prueba.

Algoritmo	Datos sintéticos sin Bosque Aleatorio y Conjunto de Árboles					
	Calibración interna			Validación externa		
	R <sup>2</sup> ajustado	MAE	RMSE	R <sup>2</sup> ajustado	MAE	RMSE
Regresión Lineal	0,92	2,67	3,93	0,94	2,87	3,39
RNA	0,97	1,56	2,17	0,98	1,34	1,71
Árbol de Decisión	0,92	2,76	3,89	0,98	1,17	1,80
Bosque Aleatorio	0,94	2,57	3,34	0,94	2,52	3,49
Conjunto de Árboles	0,95	2,49	3,25	0,94	2,53	3,44

Los resultados confirman el beneficio de utilizar una base de datos sintética seleccionada. La RNA consolidó su posición como el modelo más estable, alcanzando el  $R^2$  ajustado más alto en todas las pruebas y los errores más bajos. El Árbol de Decisión experimentó una mejora significativa en su capacidad de generalización, logrando un  $R^2$  ajustado externo de 0,98, muy cercano al de la RNA, con errores ligeramente superiores, lo que sugiere que, aunque en promedio su ajuste es excelente, puede presentar errores puntuales. Los modelos de ensamble, ahora evaluados con una base sintética que no incluye sus propias generaciones, mostraron una generalización consistente, pero sin superar a los mejores modelos.

Según los resultados obtenidos se evidencia que, aunque las Redes Neuronales Artificiales presentan el mayor nivel de precisión en la predicción de la capacidad de carga a tracción, los otros modelos considerados en el estudio también ofrecen aportes relevantes para el análisis del problema. En particular, enfoques como la Regresión Lineal y el Árbol de Decisión, aun cuando presentan errores ligeramente superiores, poseen una mayor interpretabilidad estructural, lo que permite identificar con mayor claridad la influencia de las variables de entrada sobre la respuesta del sistema suelo-pilote.

### 3.2. COMPARACIÓN DE LAS PRUEBAS

En la comparación sistemática de los resultados obtenidos en las tres pruebas experimentales, ver Figura 3, se observa que la RNA demostró un desempeño superior y notablemente consistente en todos los escenarios. Con la primera prueba, la RNA mostró una capacidad excepcional para modelar las relaciones del sistema, alcanzando un  $R^2$  ajustado de 0,99 en calibración interna manteniéndose igual en la validación externa. Esta estabilidad inicial con un conjunto de datos limitado es un indicador importante de su eficiencia.

Si bien la ampliación con datos sintéticos permitió mejorar las métricas de ajuste interno de todos los modelos, la RNA mantuvo su ventaja en generalización. Especialmente en la tercera prueba, donde se utilizó una base sintética depurada, la RNA logró el mejor equilibrio global: un  $R^2$  ajustado en validación externa de 0,98, con un MAE de 1,35 kN y un RMSE de 1,72 kN, confirmando su capacidad de extrapolar conocimiento a casos no vistos con alta precisión.

Por el contrario, otros algoritmos como los basados en árboles mostraron una alta sensibilidad al tamaño y composición del conjunto de datos. Aunque el Árbol de Decisión mejoró significativamente con datos sintéticos, su desempeño inicial con datos reales fue moderado. El modelo lineal se comportó de una manera estable en las tres pruebas alcanzando un alto nivel predictivo, pero sin alcanzar el ajuste de la RNA.

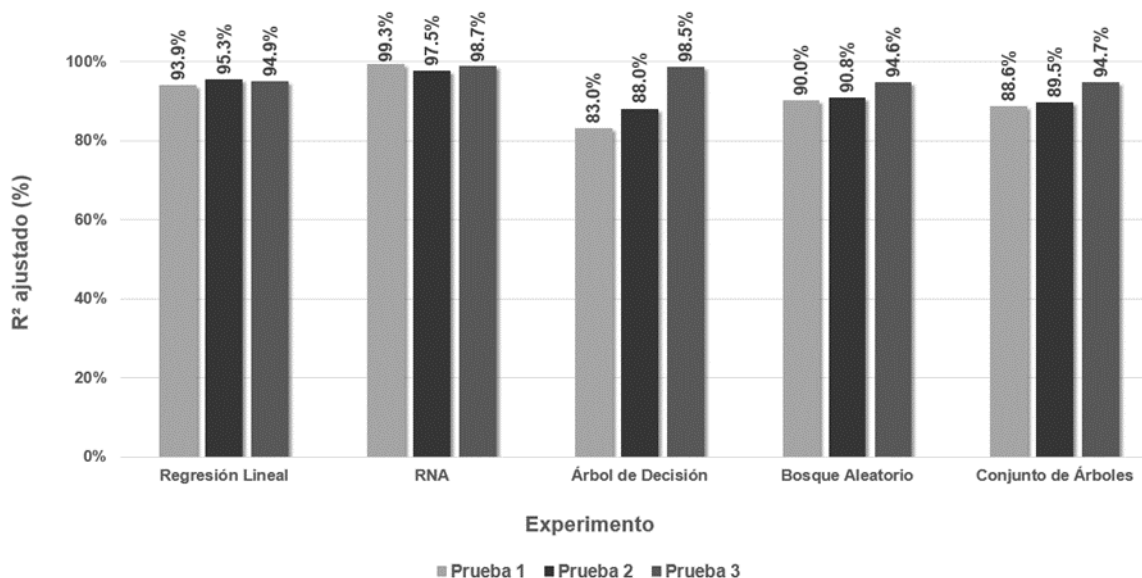


Fig. 3- Comparación en base al  $R^2$  ajustado obtenido en la calibración externa de cada una de las pruebas.

### 3.3. COMPARACIÓN DE LOS RESULTADOS OBTENIDOS MEDIANTE LA MODELACIÓN NUMÉRICA Y FORMULACIONES EMPÍRICAS

Para evaluar los resultados obtenidos por la modelación numérica, se realizaron comparaciones con los resultados obtenidos de aplicar la formulación del método alfa ver ecuación (1) y (2), empleando los mismos datos de los modelos. Para la determinación de la capacidad de carga última a tracción mediante el método empírico propuesto se utilizan las expresiones del coeficiente  $\alpha$  propuestas por Sladen (1992), ver ecuación (3), Randolph & Murphy (1987), ver ecuación (4) y (5) y API (2007), ver ecuación (6) [17].

$$Q_s = \sum (\alpha \cdot C_u \cdot A_s) \quad (1)$$

$$f = \alpha \cdot C_u \quad (2)$$

$$\alpha = C(\bar{\sigma}'_o / C_u)^{0,45} \quad (3)$$

$$\alpha = 0,5(C_u / \bar{\sigma}'_o)^{-0,5} \rightarrow C_u / \bar{\sigma}'_o \leq 1 \quad (4)$$

$$\alpha = 0,5(C_u / \bar{\sigma}'_o)^{-0,25} \rightarrow C_u / \bar{\sigma}'_o > 1 \quad (5)$$

$$f_{av} = 0,5(C_u \cdot \bar{\sigma}'_o)^{0,5} \text{ o } 0,5(C_u)^{0,75}(\bar{\sigma}'_o)^{0,25} \text{ (se toma el mayor resultado)} \quad (6)$$

Donde  $f$ : es la fricción lateral,  $\alpha$ : es el coeficiente empírico de adhesión,  $C_u$ : es la cohesión no drenada del suelo,  $A_s$ : es el área lateral del pilote,  $\bar{\sigma}'_o$ : es la presión efectiva vertical promedio,  $C \approx 0,4$  a  $0,5$  para pilotes perforados y  $C \geq 0,5$  para pilotes hincados y  $f_{av}$ : es la resistencia friccional unitaria promedio.

Los resultados de la modelación numérica se comparan con los de las formulaciones empíricas, para la longitud de  $L_p = 1,20$  m, todos los diámetros y valores de cohesión. Se evidencian diferencias promedio de 52% con los valores determinados por la fórmula de Sladen, 36% con la fórmula de Randolph & Murphy y 24% con la fórmula del API, siendo la capacidad última obtenida mediante el Método de los Elementos Finitos mayor que la calculada por las formulaciones empíricas, ver Figura 4. Esta discrepancia se explica por las hipótesis simplificadas adoptadas por el método alfa, el cual asume una adherencia uniforme entre el suelo y el pilote y una movilización instantánea de la resistencia por fricción, sin considerar la redistribución de esfuerzos ni el deslizamiento relativo en la interfaz suelo-pilote. En cambio, el modelo numérico permitió representar de manera más realista el comportamiento del sistema, incorporando la redistribución de esfuerzos en el suelo, la concentración de las deformaciones en zonas críticas y la movilización gradual de la resistencia a tracción conforme aumenta la carga aplicada. Por esta razón se generaron ábacos para la determinación de la capacidad de carga última a tracción según las predicciones obtenidas de las Redes Neuronales Artificiales que se entrenaron con los patrones de comportamiento determinados de los modelos numéricos implementados.

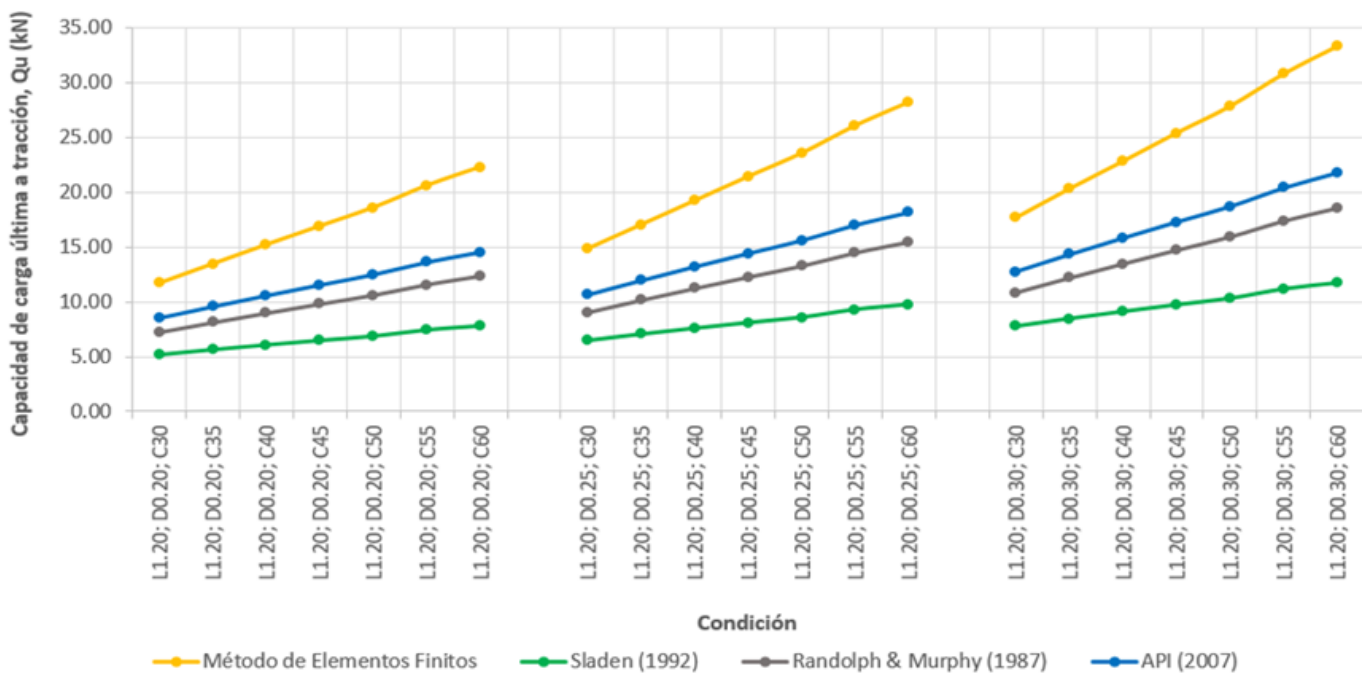


Fig. 4- Comparación de los resultados obtenidos mediante la modelación numérica y el método alfa.

### 3.4. ÁBACOS BASADOS EN DATOS SINTÉTICOS GENERADOS MEDIANTE LA RNA

Como parte del proceso de análisis y aplicación práctica de los resultados obtenidos del estudio con el empleo del aprendizaje automático, se desarrollaron tres ábacos predictivos que permiten representar gráficamente la relación entre la longitud del pilote y la carga última a tracción ( $Q_u$ ), empleando exclusivamente los datos sintéticos generados por el modelo de la Red Neuronal Artificial (RNA). Estos ábacos fueron elaborados con el propósito de ofrecer una herramienta visual clara y accesible que facilite la interpretación de los resultados del modelo y puedan ser empleados para la determinación preliminar de la capacidad de carga última a tracción de pilotes cortos perforados en suelo cohesivo en la práctica profesional. El uso de estos ábacos debe complementarse con la selección adecuada de un factor de seguridad, aspecto que corresponde a los diseñadores, debiendo complementar su elección con el desarrollo de pruebas de carga *in situ*.

Los ábacos se construyeron a partir de la base de datos ampliada mediante la generación sintética de valores, proceso realizado tras el entrenamiento final de la RNA, una vez alcanzado un desempeño óptimo en términos de generalización y precisión. Cada ábaco corresponde a uno de los tres diámetros de pilote analizados (0,20 m, 0,25 m y 0,30 m), lo que facilita su lectura y aplicación práctica al mostrar claramente la evolución de la carga última a tracción con la longitud del pilote para un diámetro constante. Ver Figura 5, Figura 6 y Figura 7.




Fig. 5- Ábaco para estimar capacidad de carga última a tracción en pilotes cortos perforados en suelo cohesivo.

### Ábaco para estimar capacidad de carga última ( $Q_u$ ) a tracción en pilotes cortos perforados en suelo cohesivo




Fig. 6- Ábaco para estimar capacidad de carga última a tracción en pilotes cortos perforados en suelo

### Ábaco para estimar capacidad de carga última ( $Q_u$ ) a tracción en pilotes cortos perforados en suelo cohesivo




Fig. 7- Ábaco para estimar capacidad de carga última a tracción en pilotes cortos perforados en suelo cohesivo.

## 4. CONCLUSIONES

1. La base de datos generada a partir de la modelación numérica permitió analizar de manera consistente la influencia de los parámetros geotécnicos del suelo y geométricos del pilote en la capacidad de carga a tracción, constituyendo un soporte adecuado para el entrenamiento y validación de los modelos predictivos.
2. El análisis comparativo permitió identificar diferencias claras en el desempeño de los modelos de aprendizaje automático, mostrando que su comportamiento predictivo está condicionado por el tipo de algoritmo empleado, su calibración, estructura, calidad y cantidad de los datos utilizados en el estudio, demostrando que las Redes Neuronales Artificiales presentan un desempeño predictivo superior al de los algoritmos lineales y a los basados en árboles para la estimación de la capacidad de carga a tracción en pilotes cortos de hormigón armado perforados en suelo cohesivo. El empleo de los algoritmos lineal y árbol de decisión brindan predicciones igualmente satisfactorias y permiten identificar con mayor claridad la influencia de las variables de entrada sobre la respuesta del sistema suelo-pilote.
3. La integración de la modelación numérica y el análisis mediante aprendizaje automático para cimentaciones profundas a tracción en suelo cohesivo es un enfoque coherente y aplicable, ya que combina el rigor de la simulación con la eficiencia y rapidez predictiva de los algoritmos para optimizar el análisis y el diseño.
4. Los ábacos obtenidos a partir de las predicciones de la Red Neuronal Artificial permiten estimar preliminarmente la carga última de tracción de pilotes cortos en función de la longitud y el diámetro del pilote, dentro de los rangos analizados. La capacidad de carga de diseño debe ser verificada por pruebas de carga en correspondencia con la importancia de la obra y la seguridad definida para el diseño.

## 5. RECOMENDACIONES

La continuidad de la línea de investigación que se presenta en el trabajo, demanda el desarrollo de pruebas de carga reales que permitan validar los resultados preliminares alcanzados en esta investigación.

## REFERENCIAS BIBLIOGRÁFICAS

1. Chen Yit-Jin, Jos Mary Abigail, Topacio Anjerick, and Wang Kai, "Uplift Capacity and Displacement of Pre-Bored PC Piles in Undrained Soils," *International Journal of Engineering and Technology Innovation*, vol. 15, no. 3, pp. 300-313, 07/31 2025. <https://10.46604/ijeti.2024.14597>
2. J Fang, S Lin, and K Liu, "Multi-scale study of load-bearing mechanism of uplift piles based on model tests and numerical simulations," (in eng), *Sci Rep*, vol. 13, no. 1, p. 6410, Apr 19 2023. <https://10.1038/s41598-023-33221-z>
3. Hailong Ma, Yufei Ma, Lin Zhu, and Hangyu Zhang, "Experimental Study on the Difference Mechanism of Shaft Resistance between Uplift Piles and Compressive Piles," *Applied Sciences*, vol. 13, no. 5, p. 3158, 2023. doi: <https://doi.org/https://10.3390/app13053158>
4. R. B. J. Brinkgreve, S. Kumarswamy, W. M. Swolfs, and D. Waterman, B. Systems, Ed. *PLAXIS 2D Reference Manual*. 2020
5. D. M. Potts and L. Zdravkovic, C. Press, Ed. *Finite Element Analysis in Geotechnical Engineering: Theory and Application*, 2nd ed. 2019
6. Sayed Hemeda, "PLAXIS 3D numerical analysis of complex geotechnical problems of colossal built heritage," *Heritage Science*, vol. 12, no. 1, p. 32, 2024/01/30 2024. <https://10.1186/s40494-024-01156-x>:
7. A. T. C. Goh and W. Zhang, "A hybrid intelligence approach to modeling pile capacity in clays," *Soils and Foundations*, 2018. <https://doi.org/10.1016/j.gsf.2020.02.014>:
8. Bashar Tarawneh, Wassel A. L. Bodour, and Khaled Al Ajmi, "Intelligent Computing Based Formulas to Predict the Settlement of Shallow Foundations on Cohesionless Soils," *The Open Civil Engineering Journal*, vol. 13, pp. 1-9, 2019/01/01/ 2019. <https://doi.org/10.2174/1874149501913010001>:
9. Shrikant M. Harle and Rajan L. Wankhade, "Machine learning techniques for predictive modelling in geotechnical engineering: a succinct review," *Discover Civil Engineering*, vol. 2, no. 1, p. 86, 2025/05/01 2025. <https://10.1007/s44290-025-00224-w>
10. Usman Hasan Jalali, Badee Alshameri, Muhammad Hamza Khalid, Waqas Hassan, Lokmane Abdeldjouad, S. Muhammad Jamil et al., "Data-driven approach to enhance deep foundation safety: reliable methods for predicting bored pile capacity," *International Journal of Geo-Engineering*, vol. 16, no. 1, p. 16, 2025/08/12 2025. <https://10.1186/s40703-025-00247-3>
11. Hongchen Liu, Huaizhi Su, Lizhi Sun, and Daniel Dias-da-Costa, "State-of-the-art review on the use of AI-enhanced computational mechanics in geotechnical engineering," *Artificial Intelligence Review*, vol. 57, no. 8, p. 196, 2024/07/05 2024. <https://10.1007/s10462-024-10836-w>
12. Nezam Bozorgzadeh and Yu Feng, "Evaluation structures for machine learning models in geotechnical engineering," *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, vol. 18, no. 1, pp. 52-59, 2024/01/02 2024. <https://10.1080/17499518.2024.2313485>
13. Jalal Shah, Mehtab Alam, Faisal Javed, Muhammad Umar, and Furqan Ahmad, "Comparative performance evaluation of machine learning models for predicting the ultimate bearing capacity of shallow foundations on granular soils," *Scientific Reports*, vol. 15, no. 1, p. 36525, 2025/10/21 2025. <https://10.1038/s41598-025-13926-z>
14. KNIME AG. *KNIME Analytics Platform (Versión 5.4.3)*. Zurich, Switzerland: KNIME AG, 2025 Disponible en: <https://www.knime.com>
15. Swarup Saha, "Developing a Predictive Model to Predict the Exchange Rate of Bangladeshi Taka (BDT) Against us Dollar (USD)," 2023. <https://doi.org/10.58964/JBA44N201>
16. Syed Jamal Arbi, Zia ur Rehman, Waqas Hassan, Usama Khalid, Nauman Ijaz, Zain Maqsood et al., "Optimized machine learning-based enhanced modeling of pile bearing capacity in layered soils using random and grid search techniques," *Earth Science Informatics*, vol. 18, no. 4, p. 332, 2025/03/19 2025. <https://10.1007/s12145-025-01784-2>
17. Braja M. Das and Nagaratnam Sivakugan, *Principles of Foundation Engineering*, 9th ed. 2019