ARTÍCULO TÉCNICO

5º CONGRESO MEXICANO DE INGENIERÍA DE TÚNELES Y OBRAS SUBTERRÁNEAS

Uso de la Inteligencia Artificial para la estimación de parámetros de operación de una TBM por medio de Redes Neuronales Artificiales

Salvador Israel LAGOS ORTIZ
Posgrado de Ingeniería UNAM
CDMX, México.

Adrián LOMBARDO ABURTO
Construcciones Lombardo
CDMX, México.

Leonardo ALCÁNTARA NOLASCO
Instituto de Ingeniería UNAM
CDMX, México.

Resumen

La aplicación de inteligencia artificial (IA) mediante el uso de redes neuronales artificiales (RNA) en la construcción mecanizada de túneles, tiene como objetivo reaccionar eficazmente a los cambios imprevistos durante el proceso de ejecución de una obra subterránea. El uso de esta tecnología permitirá optimizar las actividades de las tuneladoras TBM ya que en la implementación del modelo neuronal se utilizan los parámetros de operación monitoreados durante la excavación. Si bien los avances tecnológicos han mejorado sustancialmente la operación automatizada de estas máquinas, el uso de la IA abrirá nuevos enfoques en el reconocimiento de patrones de los datos de entrada con relación a los de salida, mismos que están asociados con el rendimiento y la toma de decisiones para la manipulación de la tuneladora en la ejecución de la excavación subterránea.

Abstract

The application of artificial intelligence (AI) using artificial neural networks (ANN) in the mechanized construction of tunnels aims to react effectively to unforeseen changes during the execution process of underground work. This technology will optimize tunnel boring machine (TBM) activities because the neural model implemented uses operating parameters obtained during the excavation process. Although technological advances have substantially improved the automated operation of these machines, artificial intelligence will open new approaches to pattern recognition of input and output data recorded during excavation and manipulated by the operator. Such information is associated with the performance and decision-making for driving the tunnel-boring machine in executing the underground task.

1. Introducción

Las redes neuronales artificiales pretenden imitar la forma en que los seres vivos aprenden, por lo que estos sistemas "aprenden" mediante un entrenamiento las relaciones existentes entre los patrones de datos que les son presentados para estimar una respuesta. El procedimiento se realiza de forma iterativa para optimizar la salida, de tal manera que el error pueda ser reducido a uno aceptado *a priori*.

La complejidad de una excavación está sujeta a condiciones muy cambiantes y durante su desarrollo se genera un volumen elevado de información, que hace prácticamente imposible su análisis, por lo que para manipularlos, se propone la implementación de un modelo basado en las RNA.

El uso de técnicas de inteligencia artificial, particularmente de las RNA, en la operación de las máquinas tuneladoras podrá producir soluciones óptimas que mejoren los procesos de excavación y construcción de túneles mecanizados ya que se tendrán mejores rendimientos y serán un apoyo invaluable en la toma de decisiones para una adecuada manipulación de las TBM en el frente de la excavación. Se esperaría que en un futuro, el uso de la IA y el avance tecnológico de los equipos permita una operación prácticamente autónoma de las tuneladoras.

Las tuneladoras TBM producen flujos continuos de datos generados por sensores colocados en toda la estructura de la máquina y en la superficie del terreno, de tal forma que la información recopilada es utilizada como capa de entrada de una RNA para la estimación de los datos de salida.

La arquitectura del modelo neuronal propuesto se basa en un perceptrón multicapa, constituido por una capa de entrada, una capa oculta y una capa de salida, en una red tipo *Feed Forward* pre-alimentada. El flujo de los datos se trasmite únicamente hacia adelante y sin conexiones laterales entre los nodos. Con relación a la capa de entrada, se determinó que los parámetros que tienen una mayor influencia son: la velocidad de avance (Va), la velocidad angular de la rueda de corte (Vc), la fuerza de empuje (Fe) y el torque (Tr). La capa de salida está integrada por dos nodos, la presión de frente (Pf) y la penetración (Pe).

Para la integración de la base de datos, se utilizó información derivada del Proyecto Túnel Emisor Oriente (TEO), con la máquina tuneladora Hidalgo en macizos rocosos principalmente. La selección se realizó en solicitud de causa y efecto del proceso de excavación, para identificar las interacciones entre los datos de entrada y así llegar a la ponderación adecuada de los parámetros involucrados en la salida. Se integraron dos conjuntos, uno de entrenamiento y otro de prueba.

2. Control de procesos de excavación y operación de una TBM

El control de procesos es la técnica que sirve para la evaluación de los parámetros de excavación de una TBM; este analiza e identifica la interacción entre los distintos procesos que constituyen la excavación con tuneladora y la interacción entre el suelo y el escudo. Este sistema optimiza la seguridad y la calidad de la obra, el rendimiento en el proceso de excavación y los costos del proyecto.

El objetivo principal es asegurar la estabilidad del suelo, minimizar los asentamientos diferenciales y los efectos inducidos a las estructuras existentes, así como el aseguramiento del proceso de excavación con la comparación de valores reales registrados por la tuneladora y los de proyecto, por medio de la gestión de datos y la experiencia de los ingenieros.

El control de procesos es sumamente importante, ya que el escudo es altamente dependiente de las características del suelo. En algunos métodos de excavación, el material excavado es el que actúa como medio de sostenimiento del frente y para mantener ese equilibrio de fuerzas se ajustan los parámetros de excavación, con la intención de conseguir los rendimientos y el avance considerado. La correcta realización del control de procesos genera resultados adecuados en la seguridad y la calidad de la obra, pero también ayuda a tener buenos rendimientos de avance y disminución de los costos.

El sistema debe ser alimentado con datos suficientes para poder llevar a cabo un análisis exitoso. Las tuneladoras están equipadas con sensores que registran los parámetros de funcionamiento tanto de la maquinaria como de las herramientas que lo componen, desde presiones y desplazamientos, hasta caudales y pesos. Entre más datos se registren, más eficiente será el proceso de control (Figura 1).

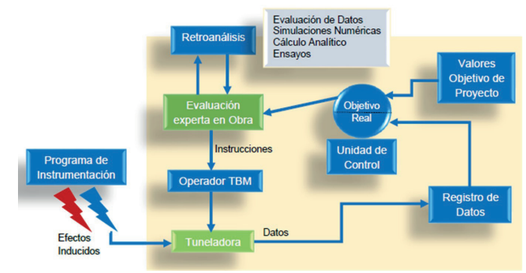

▲ Figura 1. Circuito de control de procesos.

Los parámetros operacionales se registran y almacenan digitalmente. Durante el avance, el circuito de control principalmente verifica los parámetros reales medidos con los valores "objetivo" de referencia. Esta comparación la realiza el ingeniero de frente especializado, tomando en cuenta las condiciones geológicas e hidrogeológicas que está encontrando al momento de excavar.

El objetivo de esta comparación es tomar decisiones fundadas para poder adaptar la operación de la tuneladora a las condiciones actuales del suelo. Este proceso se puede realizar por medio de las redes neuronales artificiales.

Para el mejoramiento del control de procesos, se implementan herramientas informáticas que permiten tener una mejor percepción de la interacción suelo-tuneladora, y manejar en el menor tiempo posible un gran número de datos interrelacionados entre sí.

Deben desarrollarse y emplearse modelos matemáticos y numéricos realistas que simulen el proceso constructivo y las condiciones geológicas de contorno. Los modelos deberán proporcionar los valores objetivo de referencia para la operación, por lo que es importante realizar un retroanálisis para validar o mejorar las hipótesis de cálculo adoptadas, con el objetivo de minimizar el tiempo en la toma de decisiones por parte del operador y de los ingenieros.

3. Redes neuronales

Las RNA buscan resolver problemas complejos sin la necesidad de acudir a técnicas convencionales basadas en hipótesis simplificadoras, cuyo sustento es la simulación del comportamiento del sistema nervioso biológico de los seres humanos. Por medio de un proceso de aprendizaje, se busca establecer las relaciones existentes entre las variables entrada y salida presentadas, que definen el comportamiento ante una acción y su respuesta, para posteriormente generalizar el conocimiento adquirido.

3.1. Redes Neuronales Biológicas

Se estima que el sistema nervioso de los seres humanos está integrado aproximadamente de cien mil millones de células nerviosas llamadas neuronas y prácticamente todo lo que se comprende de la vida cotidiana implica actividad del sistema nervioso, especialmente del cerebro.

La neurona es una célula del sistema nervioso central que posee la capacidad de recibir y decodificar información en forma de señales eléctricas y químicas, transmitiéndolas a otras células a través del proceso de sinapsis, lo que constituye el principio del funcionamiento del cerebro, su estructura principal se observa en la Figura 2.

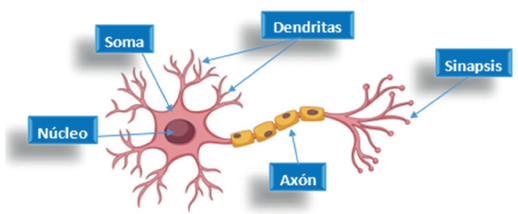

▲ Figura 2. Estructura de una neurona biológica.

3.2. Redes Neuronales Artificiales

La RNA es un algoritmo de cálculo que se basa en una analogía del sistema nervioso con la idea general de emular su capacidad de aprendizaje, de forma tal que aprenda a identificar un patrón de asociación entre los valores de un conjunto de variables predictoras (entradas) y los estados que se consideran dependientes de dichos valores (salidas).

Una RNA consiste en un grupo de unidades de proceso denominadas nodos, que emulan a las neuronas biológicas, los cuales están interconectados por medio de un entramado de relaciones (pesos) análogas al concepto de conexiones sinápticas en el sistema nervioso. A partir de los nodos de entrada, la señal progresa a través de la red hasta proporcionar una respuesta en forma de nivel de activación del nodo de salida. Los elementos que conforman una neurona artificial se observan en la Figura 3.

4. Modelo neuronal para la estimación de parámetros operacionales

Son varios los factores que se deben tomar en cuenta cuando se excava de manera mecánica (TBM). Uno de ellos es el con-

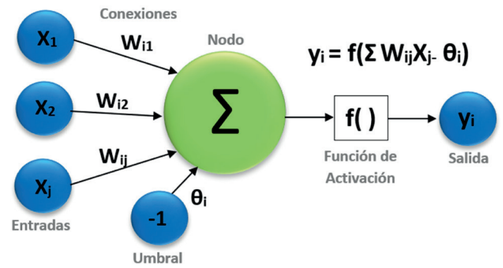

▲ Figura 3. Modelo de una neurona artificial.

trol de los parámetros de operación. Los valores empleados en la predicción de la presión de frente y la penetración aquí utilizados también permiten verificar algunas características geotécnicas de los materiales que se excavan y del proceso constructivo en el frente de excavación.

Los parámetros operacionales proporcionan de forma indirecta información sobre las características del macizo rocoso. El aumento o la disminución de la velocidad de avance se asocia a la calidad de la roca en el frente de excavación; mientras que el empuje dependerá del rozamiento que debe existir entre la tuneladora y el material de corte y, si no se controlan adecuadamente estos valores, la máquina puede quedar atrapada. El aumento instantáneo del torque se asocia a los desprendimientos del terreno. La combinación de estos parámetros proporciona un panorama más amplio de las características geológicas heterogéneas de la roca o de los suelos mixtos.

Los parámetros independientes que controla el operador de la tuneladora son la velocidad de rotación y la fuerza de empuje. El primero depende de la geología del terreno, ya que representa el número completo de vueltas de la rueda de corte por minuto y está relacionado con la velocidad de penetración del escudo. La fuerza de empuje permite conseguir una cierta penetración; cualquier cambio de magnitud de ésta sobre la cabeza de corte se refleja en variaciones en la velocidad de penetración.

La presión de frente y la penetración permiten estimar las características geológicas, geotécnicas y mecánicas del macizo rocoso por lo que, dada su importancia, uno de los objetivos de esta investigación es desarrollar un modelo neuronal con capacidad predictiva para estimar la presión de frente y la penetración mediante los principales parámetros operacionales registrados en el control de proceso de una máquina tuneladora TBM de tipo EPB.

La arquitectura del modelo propuesto se basa en un Perceptrón Multicapa, mismo que está constituido por una capa de entrada, una capa oculta y una capa de salida, que es una red *Feed Forward* prealimentada o alimentada hacia adelante. Con relación a la capa de entrada, se determinó que los parámetros que tienen una mayor influencia son: la velocidad de avance (Va), la velocidad angular de la rueda de corte (Vc), la fuerza de empuje (Fe) y el torque (Tr). La capa de salida está determinada por dos nodos, los cuales están comprendidos por la presión de frente (Pf) y la penetración (Pe).

En la Tabla 1 se identifican los parámetros clave que se monitorean y calibran en la excavación mecanizada con TBM de tipo EPB, determinando los valores mínimos y máximos registrados en el control de procesos en terrenos mixtos.

Entradas				Salidas	
Velocidad de avance (mm/min)	Velocidad angular rueda de corte	Fuerza de empuje (KN)	Torque (KNm)	Presión de frente (KPa)	Penetración (mm/rev)
Valores mínimos					
7	1.17	15803	707	16.42	3.35
Valores máximos					
21	3.88	44646	3023	68.07	12.44

▲ Tabla 1. Valores mínimos y máximos de los parámetros operacionales a evaluar, registrados en la excavación de macizos rocosos: la velocidad de avance (Va), la velocidad angular de la rueda de corte (Vc), la fuerza de empuje (Fe) y el torque (Tr), la presión de frente (Pf) y la penetración (Pe).

Con lo anterior, la arquitectura del modelo neuronal queda representada de la siguiente manera (Figura 4). En la capa de entrada 4 parámetros, en la capa oculta 50 neuronas (nodos) y en la capa de salida 2 parámetros.

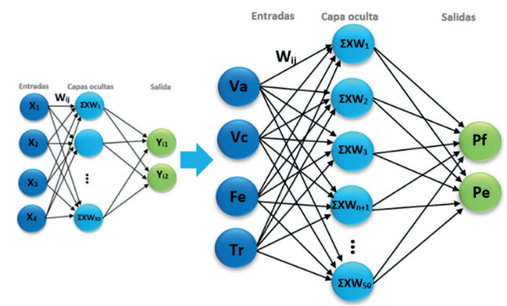

▲ Figura 4. Arquitectura general del modelo artificial.

4.1. Base de datos de los parámetros operacionales

Considerando que las máquinas tuneladoras registran una gran variedad de parámetros, dependiendo del tipo de TBM o las tecnologías a utilizar, para este proceso se utiliza la base de datos de una máquina tuneladora tipo EPB que ha excavado en macizos rocosos y se seleccionan los parámetros más importantes para este tipo de terrenos. Es importante destacar que los sensores instalados en el escudo registran cada avance milimétrico de la máquina, por lo que se elabora un análisis para determinar cuáles son los valores más representativos y completos para generar una base de datos que sea adecuada para el entrenamiento del modelo, entendiendo por esto una adecuada representación del fenómeno que se está modelando. El banco de datos obtenido es de 180 registros para cada parámetro operacional de entrada y salida, de los cuales se formaron dos subconjuntos, el primero para la etapa de entrenamiento y el segundo para la etapa de prueba (90 registros para cada uno).

El criterio para la integración del subconjunto de entrenamiento se basó en tener una representatividad adecuada del amplio intervalo de la magnitud de la presión de frente, ya que, al tener un suelo mixto, este valor (como dato de salida) tiene un rango de variación muy importante en su valor absoluto. Es por ello que se obtuvieron los valores máximos y mínimos de este y de los demás parámetros y se reparten en los dos subconjuntos de la base de datos.

4.2. Herramienta de cómputo *ThinksPro*

El entrenamiento del modelo neuronal se realizó con el software *ThinksPro* (Figura 5), desarrollado por la consultora *Logical Designs Consulting, Neural Networks for Windows*, 2002. Cuenta con una interfaz intuitiva e interactiva en donde se pueden modificar los parámetros de la arquitectura del modelo, antes y durante el procesamiento. Los resultados se pueden ir visualizando mientras van ejecutándose las iteraciones del programa mediante los gráficos de error. Los datos de entrada y salida se importan por medio de tablas de Excel con extensión (csv).

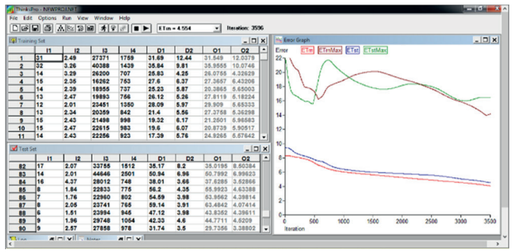

▲ Figura 5. Software *ThinksPro*.

Se establecen los parámetros generales de la arquitectura de la red neuronal artificial. Para este trabajo, se utilizó el perceptrón multicapa de tipo *Feed Forward*, con un error medio cuadrático. Además, se configuró la capa de entrada con 4 nodos, con un procesamiento de máximos y mínimos. El proceso se inicia mediante una semilla que permite inicializar un generador de números aleatorios, cuyos valores se utilizan para los pesos iniciales de cada nodo. El programa inicia con un valor aleatorio, pero se puede manipular arbitrariamente. Finalmente, se fija un error de tolerancia que se considera aceptable de acuerdo con los datos suministrados.

Se realizaron varias pruebas con una y dos capas ocultas, cada una con un número variado de nodos (neuronas) y en todas las pruebas se utilizó el algoritmo de retro-propagación como regla de aprendizaje. La función de entrada utilizada en las capas ocultas fue el producto punto, ya que es la suma ponderada del producto de valores con un sesgo. Dado un vector de entrada de valores (n), perteneciente a los valores de los números reales (R) $x_1, x_2, x_3, \ldots, x_n$ y un conjunto de valores ponderados ($n+1$), se tienen dos conjuntos de vectores x y w.

En el vector (x), en su primer componente se localiza la constante de entrada llamada constante de sesgo y la primera componente del vector (w) es llamada peso del sesgo.

La suma ponderada se obtiene mediante la sumatoria de los productos de entrada con su peso correspondiente, donde $w = (W_0, W_1, W_2,..., W_n)$ y $x = (1, X_1, X_2,...,X_n)$. Por ejemplo, ver ecuación 1:

$$f(x,w)= (W0+X_1W_1+X_2W_2+\ldots+X_nW_n) \quad (1)$$

La función de transferencia o de activación para las capas ocultas es la función sigmoide. La configuración de salida de la red se compone por la regla de aprendizaje o algoritmo de retro-propagación, la función de entrada será producto punto y la función de transferencia es definida como lineal.

Los conjuntos de entrenamiento y prueba son importados al programa mediante archivos Excel, donde se enlistan los parámetros de entrada y de salida para la evaluación de la red neuronal artificial.

Una vez establecida la configuración de la arquitectura de la RNA, se ejecuta el programa para que el conjunto de entrenamiento de forma iterativa realice el proceso de la red, ajustando los pesos (w) para encontrar el mínimo error. El conjunto de datos de prueba evalúa el rendimiento de la red durante y después el proceso del entrenamiento, comparando simultáneamente los datos de entrada de ambos subconjuntos y los resultados de salida que la propia red arroja.

En la Figura 6 se visualizan las gráficas de los errores máximos y mínimos de los conjuntos de datos de aprendizaje y de prueba. Cabe señalar que los errores máximos registrados no son datos representativos del error esperado en el proceso, pues estos son valores de referencia del rango donde se encuentra el error, para que el mismo programa de cómputo realice el ajuste del modelo. El error máximo permite identificar si la estructura de la red y/o la función de transferencia son las adecuadas. Los datos de interés son los errores mínimos obtenidos en las etapas de aprendizaje y prueba de la red.

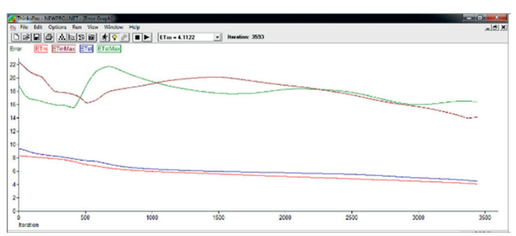

▲ Figura 6. Variación del error durante el entrenamiento.

4.3. Entrenamiento del modelo neuronal artificial

El criterio utilizado para el tipo de entrenamiento y el número de nodos y capas ocultas consideró los resultados de distintos autores en proyectos de ingeniería. No existe una metodología precisa para establecer el número óptimo de nodos en las capas ocultas del modelo neuronal, la experiencia es fundamental para estructurar una arquitectura adecuada. Se sugiere construir una red robusta con varias capas y neuronas, para después irla simplificando, siempre y cuando se mantenga la convergencia del algoritmo de entrenamiento, es decir que el error disminuya hasta encontrar el error aceptable sugerido.

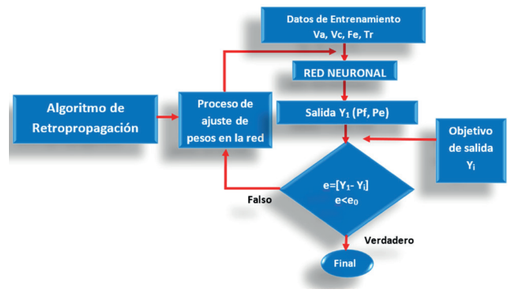

▲ Figura 7. Flujo de entrenamiento de la Red.

En la Figura 7 se ilustra el diagrama de flujo que describe el proceso de entrenamiento a partir de los datos de entrada (Va, Vc, Fe, Tr), asociados a su correspondiente peso (w). Estos parámetros alimentan la red neuronal artificial en el proceso de aprendizaje para obtener una salida (Y1), la cual se compara con el patrón objetivo (Yi), utilizando un criterio de error $e= [Y1- Yi]$; donde $e<e_0$ (propuesto).

El resultado del error (e) se compara con un error aceptable (e_0), y si es menor se finaliza el proceso considerando que la red está entrenada. Por el contrario, si el error (e) es mayor que (e_0), se procede a realizar un ajuste en los pesos (w) por medio del algoritmo de retro-propagación, donde el error se distribuye hacia atrás (se retro-propaga), desde la capa de salida hasta la capa de entrada. Cada nodo es ajustado en su peso (w) correspondiente, considerando su contribución relativa al error de salida en la capa correspondiente. Este proceso se realiza de forma iterativa hasta que se cumple la condición en donde el error (e) es menor que el error (e_0) para dar por concluido el entrenamiento.

EJEMPLO	ARQUITECTURA	PROCESAMIENTO	CONJUNTO DE APRENDIZAJE		CONJUNTO DE PRUEBA	
	ARREGLO RNA E-CO1-CO2-5	NÚMERO DE ITERACIONES	FACTOR DE CORRELACIÓN PRESIÓN DE FRENTE (Ra_{fr})	FACTOR DE CORRELACIÓN PENETRACIÓN (Ra_{pe})	FACTOR DE CORRELACIÓN PRESIÓN DE FRENTE (Rp_{fr})	FACTOR DE CORRELACIÓN PENETRACIÓN (Rp_{pe})
A	4-50-2	3596	0.914	0.992	0.881	0.990
B	4-100-2	2684	0.930	0.995	0.428	0.993
C	4-30-2	1000	0.930	0.990	0.071	0.730
D	4-50-60-2	7000	0.990	0.990	0.064	0.245
E	4-50-50-50-2	3000	0.990	0.904	0.046	0.663

▲ Tabla 2. Arquitecturas representativas del proceso de modelado de la red neuronal artificial.

De forma inmediata a la primera etapa de entrenamiento, se realiza una segunda de prueba, mediante iteraciones de los valores de entrada y de salida con sus respectivos pesos (w), pero con un subconjunto diferente al utilizado durante el entrenamiento, es decir los datos de prueba no son expuestos al modelo neuronal durante este proceso inicial.

De hecho, este entrenamiento es considerado como supervisado, ya que considera los resultados de disminución con el número de iteraciones ejecutado. Un elemento importante a considerar es que a pesar de tener una red entrenada y la experiencia del diseñador del modelo, no hay un arreglo único para encontrar el error mínimo global que indique que es el entrenamiento más óptimo para resolver el problema propuesto. Si el error encontrado se mantiene constante o no varía y los resultados obtenidos del conjunto de prueba son cercanos a los reales, se considera que la red está entrenada, siempre y cuando el error de salida (e) sea menor al error aceptable (e_0).

4.4. Resultados de la red neuronal artificial

La Tabla 2 presenta las arquitecturas propuestas con los valores más cercanos a los reales, considerando que los resultados tienen los factores de correlación óptimos ya sea para uno o los dos parámetros de salida, tanto en el entrenamiento como para la etapa de prueba. El número máximo de neuronas (nodos) en las capas ocultas varió de 50 a 200, iniciando con valores pequeños hasta llegar al máximo de nodos establecido, los incrementos correspondientes en las capas fueron de 50 en 50 generalmente. Con base en las variaciones del error y de los factores de correlación, se aumenta o se disminuye el número de capas ocultas para observar su comportamiento.

La arquitectura de la red neuronal artificial se representa con las siguientes nomenclaturas: "E-CO1-CO2-S", donde E representa el número de parámetros en la capa de entrada de la red. En este trabajo se utilizaron 4. "CO1" y "CO2" representan el número de capas ocultas y "S" las dos salidas del modelo.

Los valores contenidos en la Tabla 2 presentan solo 5 del total de las configuraciones y arquitecturas definidas para el modelo neuronal. Se observa que el caso A es el que ofrece los mejores resultados, tanto en etapa de aprendizaje como de prueba, como lo indican los factores de correlación Ra_{fr}, Ra_{pe}, Rp_{fr} y Rp_{pe}.

En las Figuras 7 a 12 se presentan los ejemplos A, B, C, D y E resumidos en la Tabla 2. El objetivo es ilustrar el procedimiento seguido para determinar los mejores valores de correlación, al hacer variar la estructura del modelo y el número de iteraciones. En el eje de las abscisas se representan los valores de la presión de frente y la penetración que registran los sensores de una máquina tuneladora tipo EPB por medio del control de procesos y en el eje las ordenadas las estimaciones del modelo neuronal.

El modelo del ejemplo (B) tiene una capa de entrada con 4 nodos, una capa oculta con 100 nodos y una capa de salida con 2 nodos (4-100-2). Sus valores de correlación fueron: Ra_{fr}=0.930, Ra_{pe}=0.995 para el entrenamiento y Rp_{fr} = 0.428, Rp_{pe}=0.993 para la prueba. Los datos de entrenamiento indican un proceso bastante adecuado, sin embargo, en la etapa de prueba, los valores de salida de la presión de frente tienen un error muy elevado en comparación con los de la penetración, dando valores de correlación bastante bajos. Este es un caso típico en el que la optimización en el entrenamiento no cumple para las dos salidas en la etapa de prueba de la red (ver Figuras 8 y 9).

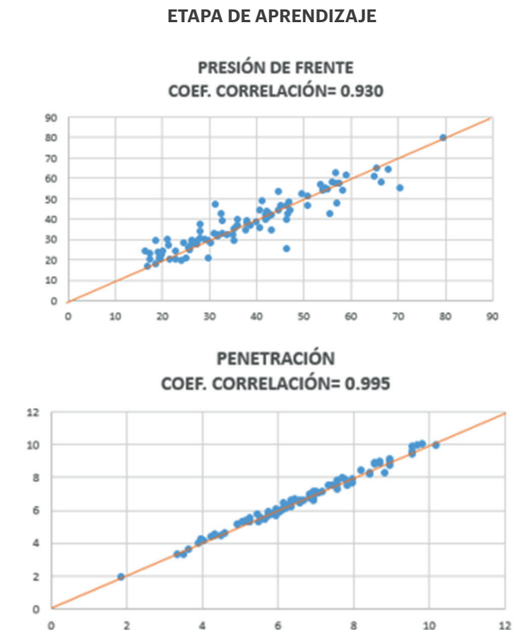

▲ Figura 8. Ejemplo B se presentan valores de correlación en la etapa de aprendizaje.

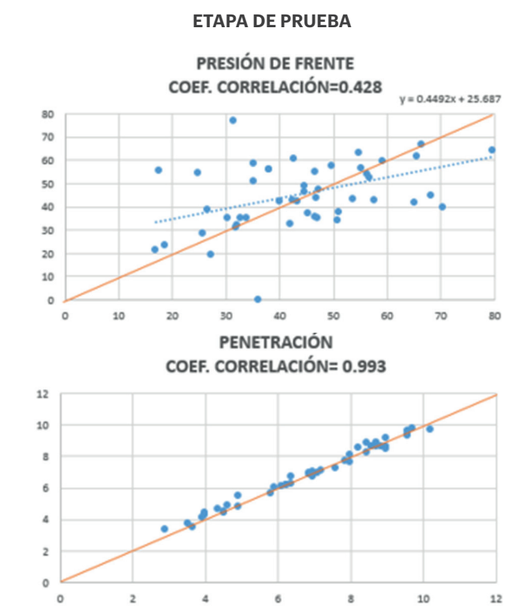

▲ Figura 9. Ejemplo B se presentan valores de correlación bajos en uno de los nodos de salida de la red (presión de frente), etapa de prueba.

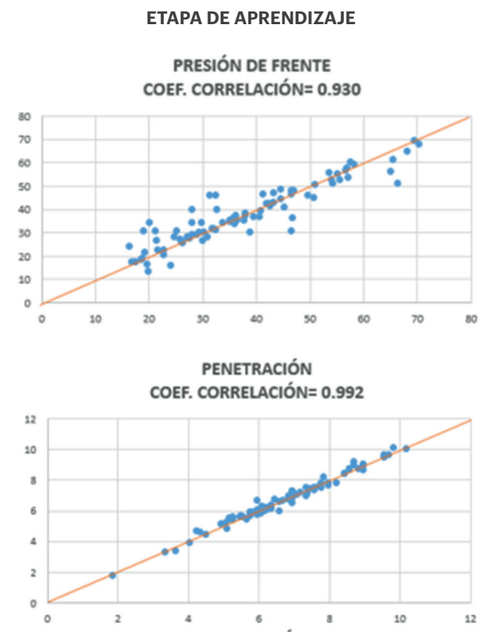

▲ Figura 10. Correlaciones realizadas en la etapa de aprendizaje para la presión de frente y la penetración.

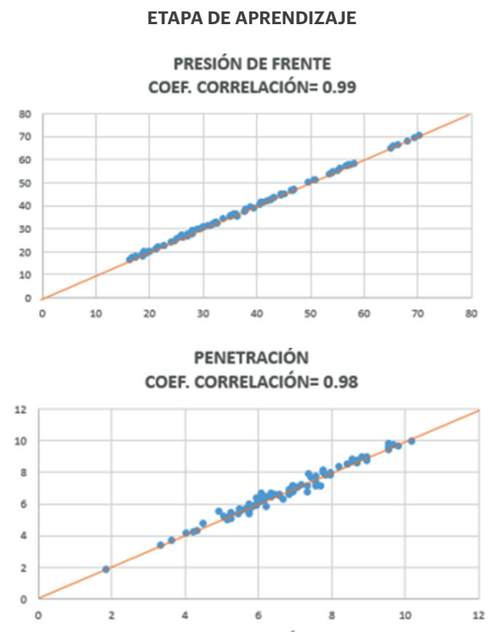

▲ Figura 12. Sobre-entrenamiento en la etapa de aprendizaje.

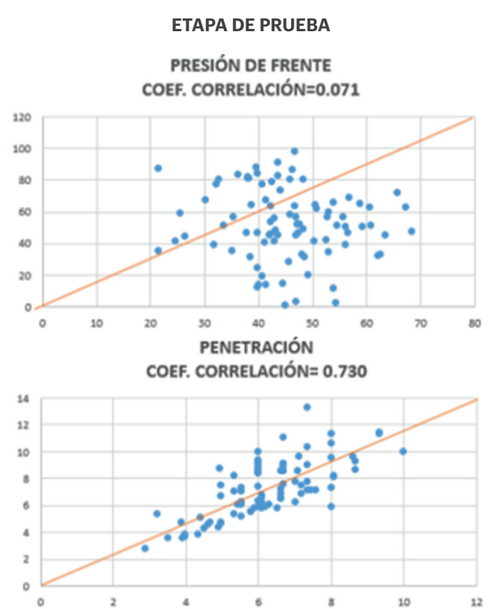

▲ Figura 11. Correlaciones pobres en la etapa de prueba para ambos parámetros de salida (presión de frente y penetración).

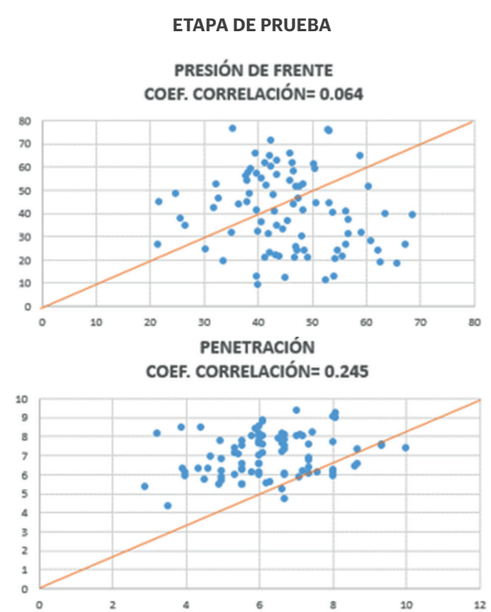

▲ Figura 13. Sobre-entrenamiento y pérdida de capacidad de generalización.

Para el caso del ejemplo C (Figuras 10 y 11) con una configuración 4-30-2 los valores de correlación obtenidos fueron: Ra_{fr}= 0.930, Ra_{pe}=0.992 para el entrenamiento y Rp_{fr}= 0.071, Rp_{pe}=0.730 para la prueba. Las correlaciones son bastante pobres, especialmente para la etapa de prueba en donde el error es muy grande. Lo anterior se asocia al bajo número de iteraciones realizadas (1000).

En las Figuras 12 y 13 se presenta el caso D en el cual el modelo tiene una configuración de: 4-50-60-2 muestra valores de correlación: Ra_{pf}= 0.990, Ra_{pe}=0.980 para el entrenamiento y Rp_{pf}= 0.064, Rp_{pe}=0.245 en la prueba.

Los resultados indican un sobre-entrenamiento del modelo puesto que, al realizar 7000 iteraciones, se logró reducir significativamente el error en los datos de entrenamiento, pero se perdió capacidad de generalización, lo que resultó en las bajas correlaciones de la etapa de prueba.

Considerando que se trata de un entrenamiento supervisado podría haberse detenido el proceso al observar un incremento en el error.

En el caso del ejemplo E, el cual tiene una configuración de 4-50-50-50-2, sus valores de correlación para 3000 iteraciones fueron: Ra_{fr}=0.990, Ra_{pe}=0.940 para el entrenamiento y Rp_{fr}=0.046, Rp_{pe}=0.663 en la prueba. Se realizó otro ensayo con la misma configuración, pero ahora con 5000 iteraciones. Los factores de correlación resultaron muy similares a los indicados (en entrenamiento como en prueba).

Es decir, existe buena correlación en el entrenamiento, pero muy pobre en prueba, lo que es un indicio de que no necesariamente el incremento en el número de iteraciones o de capas ocultas puede mejorar el rendimiento de la red en cuanto a la reducción del error (Figuras 14 y 15).

No obstante, podría darse el caso que, utilizando la misma arquitectura, se obtuviera una mejor correlación con un número mayor de iteraciones, lo que significaría que probablemente el modelo estaría abandonando un error mínimo local y encontrando un error mínimo global.

La configuración del modelo neuronal del ejemplo A es: 4-50-2, con valores de correlación de Ra_{fr}= 0.914, Ra_{pe}=0.992 para el entrenamiento y Rp_{fr}=0.881, Rp_{pe}=0.990 para la prueba. En este proceso se realizaron 3596 iteraciones, y como se observa en las Figuras 16 y 17, los valores durante el entrenamiento presentan una buena aproximación a los datos reales, especialmente para la penetración.

Con respecto a la etapa de prueba, es claro que el modelo tiene una tendencia a sobreestimar los valores de la presión de frente, aunque como se indicó, el coeficiente de correlación para este parámetro es bastante aceptable. Por lo que se considera que el modelo del caso A es el que ofrece los mejores resultados.

De acuerdo con los resultados presentados, el modelo neuronal artificial para estimar la presión de frente y la penetración quedó definido como se indica en la Figura 18: cuatro nodos en la capa de entrada (velocidad de avance Va, velocidad angular de la rueda de corte Vc, fuerza de empuje Fe y torque Tr), una capa oculta con cincuenta nodos y dos nodos en la capa de salida (presión de frente Pf y penetración Pe).

5. Conclusiones

Se implementó un modelo basado en las redes neuronales artificiales para estimar parámetros operacionales de una máquina tuneladora TBM tipo EPB. La estimación de tales parámetros permitirá optimizar los ajustes necesarios durante el proceso de excavación de una obra subterránea.

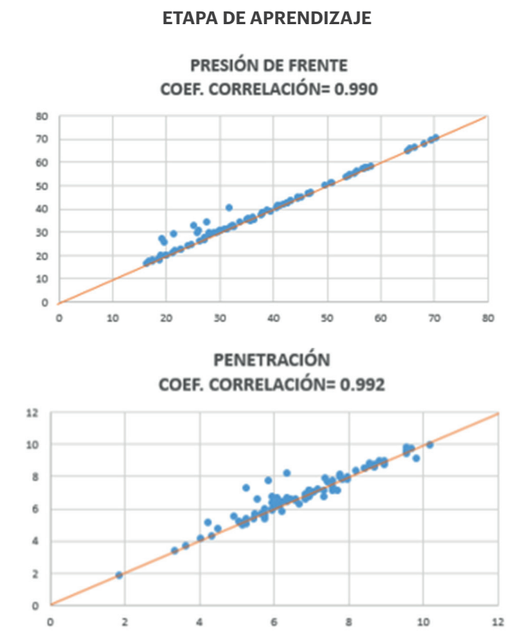

▲ Figura 14. Aumento y disminución de capas ocultas e iteraciones, etapa de aprendizaje.

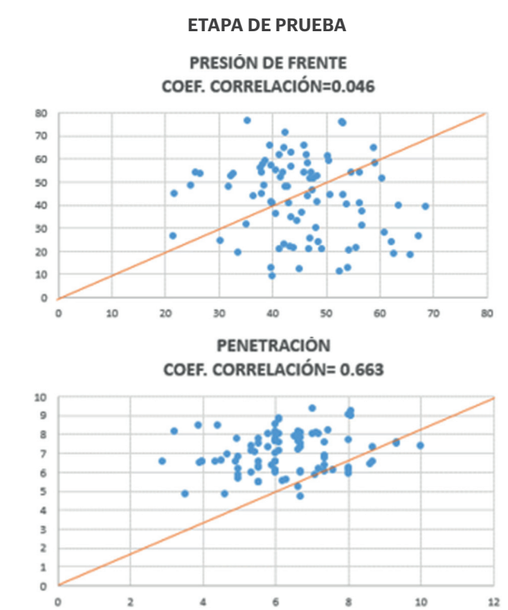

▲ Figura 15. Aumento y disminución de capas ocultas e iteraciones, etapa de prueba.

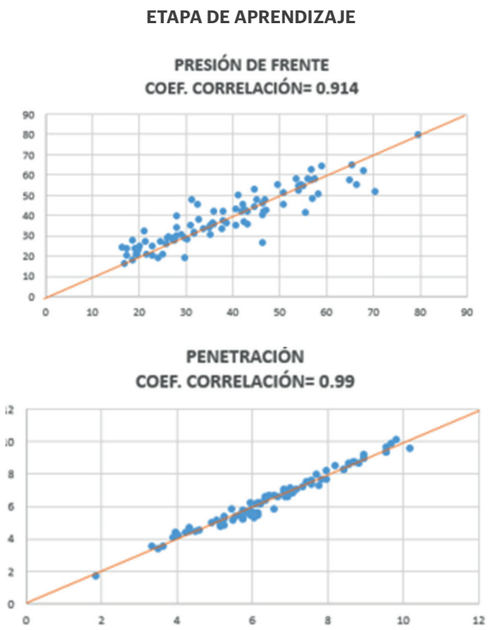

▲ Figura 16. Ejemplo A correlaciones óptimas del modelo neuronal propuesto en la etapa de aprendizaje.

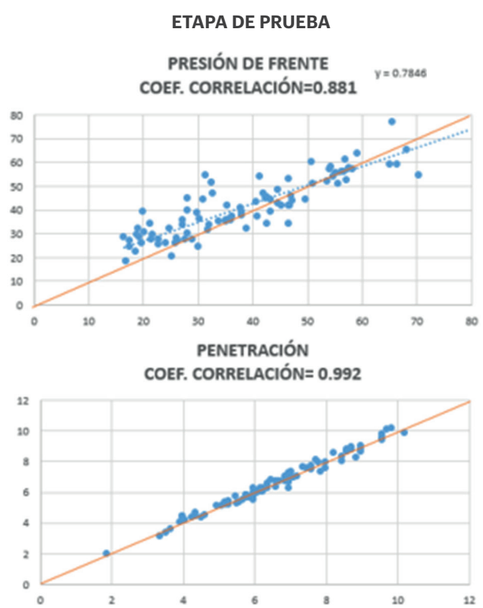

▲ Figura 17. Ejemplo A correlaciones óptimas del modelo neuronal propuesto en la etapa de prueba.

La estructura del modelo se basó en la de un perceptrón multicapa y quedó establecida mediante una capa de entrada con 4 nodos, una capa oculta con 50 nodos y una capa de salida con 2 nodos. Para la capa de entrada, se consideraron los parámetros: velocidad de avance (Va), velocidad angular de la rueda de corte (VC), fuerza de empuje (Fe) y torque Tr). Con relación a los parámetros a estimar, es decir los datos de salida, se establecieron: presión de frente (Pf) y penetración (Pe).

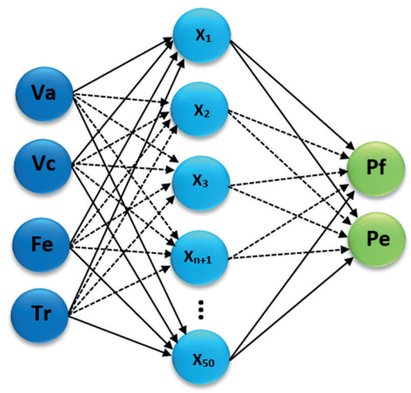

▲ Figura 18. Arquitectura final del modelo neuronal artificial.

Para el entrenamiento del modelo, se utilizó información del proyecto Túnel Emisor Oriente (TEO), con la cual se integraron dos conjuntos, uno de aprendizaje y otro de prueba.

La configuración 4x50x2 permitió optimizar la reducción del error y obtener factores de correlación bastante buenos. En el caso de la presión de frente (Pf), se obtuvo un factor de correlación Rp_{EF}=0.881, se observa una ligera tendencia del modelo a sobreestimar el parámetro. Para la penetración (Pe), la correlación fue de Rp_{PC}=0.99, muy similar a la obtenida para el proceso de aprendizaje.

Durante el entrenamiento, se realizaron varias pruebas con diferentes configuraciones de arquitectura y procesamiento, lo que es un indicio de que no necesariamente el incremento en el número de iteraciones, capas ocultas o nodos (neuronas) puede mejorar el rendimiento de la red. En realidad, es un proceso heurístico que además del conocimiento del fenómeno a modelar, también depende de la experiencia que se tenga en el entrenamiento de las RNA.

La importancia principal de este proyecto es que la utilización de estas herramientas de IA permitirá mejorar los rendimientos, será un elemento de mucha utilidad en la toma inmediata de decisiones juste en el frente de la excavación y finalmente, permitirá una eficiente manipulación de la tuneladora en la ejecución del proceso constructivo.

6. Referencias

Acevedo E, Serna A y Serna E. (1998). "Principles and characteristics of artificial neural networks", Universidad Cooperativa, Medellín Colombia.

Boeree G. (1990). "La Neurona", Departamento de Psicología, Universidad de Shippensburg, E.U.

Alcántara L. (2013). "Análisis de movimientos sísmicos en las ciudades de Oaxaca y Puebla con Redes Neuronales", Tesis doctoral del Programa de maestría y doctorado UNAM, CDMX.

Basoqain X. (2001). "Redes Neuronales Artificiales y sus Aplicaciones", Departamento de Sistemas y Automática, Escuela Superior de Ingeniería de Bilbao, España.

Comulada M. (2005). "Process Controlling and Data Management for Shield Tunnelling, Maidl Tunnelconsultants", Mechanised Shield Tunnelling, (pp.393-399).

Lagos S. (2019). "Estimación de parámetros operacionales de máquinas tuneladoras tipo EPB por medio de Redes Neuronales Artificiales", Tesis de Maestría del programa de maestría y doctorado UNAM; CDMX.

Logical Designs Consulting, Thinks Pro. (2002). "The Professional Neural Network Development Environment", Neural Networks for Windows, http://www.logicaldesigns.com/ThinksPro.htm, La Jolla California E.U.