

Estimación de módulos elásticos en pavimentos usando redes neuronales artificiales



2011 Pan-Am CGS
Geotechnical Conference

Gloria I. & Beltrán C.
Instituto de Ingeniería, UNAM, México y Universidad Nacional de Colombia, Bogotá, Colombia
Miguel P. & Romo O.
Instituto de Ingeniería, UNAM, México

ABSTRACT

Layer stiffness and strength estimation are some of the main difficulties in modeling existing flexible pavement behavior. In order to perform down-to-earth analyses of the complex physical phenomenon of actual pavement's behavior (multivariate, non-linear, discontinuous, heterogeneous problem), cognitive methods are addressed in this work; in particular artificial neural networks are used to estimate layer modulus from non destructive deflection testing data processing. As a result, a reliable modeling is obtained in terms of accurate results, with enough flexibility to perform sensitivity analysis under particular considerations; efficiency is demonstrated by low computational cost.

RESUMEN

Una de las principales dificultades en la modelación del comportamiento mecánico de pavimentos flexibles en servicio, es la representación de la resistencia y la rigidez de las capas que lo componen. Con el ánimo de lograr análisis apegados al fenómeno físico complejo representativo del comportamiento real de pavimentos (problema multi-variado, no lineal, discontinuo, heterogéneo), en este trabajo se abordan métodos cognitivos, y en particular las redes neuronales artificiales para estimar módulos de capa a partir de datos de pruebas no destructivas de deflexión. Como resultado, se obtiene una modelación confiable en términos de precisión, con suficiente flexibilidad para realizar análisis de sensibilidad para condiciones particulares, y eficiencia demostrada mediante bajo costo computacional.

1 INTRODUCCIÓN

Una de las condiciones que deben garantizar las obras de infraestructura de carreteras al tránsito vehicular, es la estabilidad de los pavimentos durante su vida útil. Para esos fines, se realizan evaluaciones en determinados momentos bajo las condiciones reales de servicio y, en función del estado del pavimento, se establece la vida remanente, las necesidades de intervención para mantener o rehabilitar una vía, las estrategias, alcance y costos.

Usualmente, se efectúan auscultaciones para medir características representativas de la condición, cuyo procesamiento, interpretación y análisis permita caracterizar el comportamiento a lo largo de un corredor.

En este trabajo en particular se busca la determinación rápida y confiable de parámetros mecánicos del pavimento, útiles para caracterizar la condición estructural y para orientar las decisiones sobre rehabilitación. Para esos fines, se analizan datos registrados sobre carreteras mexicanas en pruebas no destructivas de deflexión, las cuales se basan en la respuesta que exhibe un pavimento ante un impulso de carga aplicada sobre la superficie, para simular el efecto del tránsito vehicular. En el análisis e interpretación de datos se aplican métodos no convencionales basados en la inteligencia artificial y en particular, las redes neuronales artificiales para estimar módulos elásticos de las capas de pavimento.

La aplicación de estas herramientas de modelación, constituye una posibilidad para superar algunas de las deficiencias de los métodos de evaluación tradicionales, sin pretender desconocer ni reemplazar los avances con ellos alcanzados, ni los juicios ingenieriles basados en la práctica y la experiencia.

2 COMPORTAMIENTO DE LOS PAVIMENTOS

Desde el punto de vista mecánico, un pavimento flexible es una estructura multicapa sometida a carga repetida, cuya respuesta y desempeño depende en gran parte de la rigidez y espesor de las capas que lo componen. Estos pavimentos se conciben de manera tal que el concreto asfáltico colocado como rodamiento, aporte: a) suficiente rigidez para asumir la mayor proporción de la carga repetida transmitida directamente por las llantas de los vehículos; b) flexibilidad para que las deformaciones acumuladas por repetición de carga se mantengan en el rango elástico; c) resistencia a las agresiones del medio ambiente y d) una superficie cómoda para el usuario.

Cada impulso de carga se transfiere gradualmente en profundidad, a través de las capas granulares intermedias de base y subbase, cuya función es aportar resistencia al deterioro y estabilidad estructural y volumétrica. Las capas inferiores actúan como cimentación de la estructura de pavimento y,

eventualmente asumen alguna proporción de carga en función de su capacidad de soporte.

En la simulación del sistema estructural de pavimento para establecer parámetros de comportamiento, una de las principales dificultades a afrontar, es la determinación de la resistencia y rigidez, dada la gran cantidad de variables involucradas y que de alguna manera contribuyen a incrementar la complejidad del problema.

3 PRUEBAS NO DESTRUCTIVAS DE DEFLEXIÓN

En los diferentes intentos para evaluar la capacidad estructural de un pavimento existente, se han propuesto diferentes metodologías dentro de las cuales, las pruebas no destructivas de deflexión en la superficie son probablemente las más aplicadas actualmente. Uno de los fundamentos conceptuales del sistema de gestión vial mexicano, es precisamente la aceptación de que "la deficiencia estructural puede correlacionarse con alguna medida hecha desde la superficie del pavimento. La deflexión parece ser el concepto que mejor sirve para estos fines, pues su magnitud mide el defecto estructural, aunque no lo analice ni lo localice" (Rico et al. 1998).

Las pruebas de deflexión con equipos de carga pesada tipo FWD (Falling Weight Deflectometer) y HWD (Heavy Weight Deflectometer), resultan apropiados para evaluar la respuesta mecánica del pavimento, pues imponen cargas dinámicas cuya magnitud y tiempo de aplicación permiten simular satisfactoriamente el efecto del tránsito. Estas pruebas consisten en la aplicación de un impulso de carga, con rango entre 2 y 15 toneladas, a través de una placa circular que se coloca sobre el pavimento; la respuesta se registra en varios sensores localizados radialmente a diferentes distancias del punto de aplicación de la carga, definiéndose una cuenca de deflexiones según se ilustra en la figura 1.

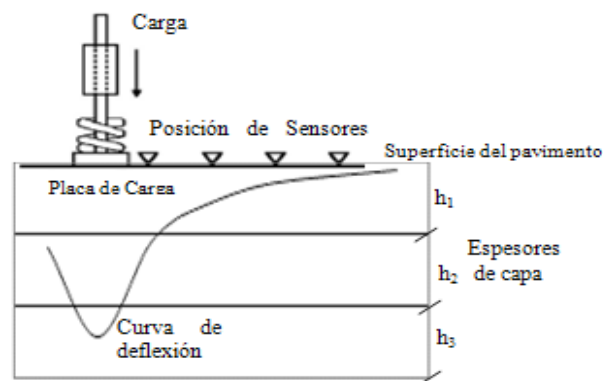


Figura 1. Prueba de deflexión por impacto

Históricamente han surgido muchas propuestas de métodos simplificados, para calcular parámetros e indicadores a partir de las cuencas de deflexión, tales como el radio de curvatura o factores de forma.

Más recientemente, el área de la cuenca de deflexiones se ha considerado como indicador de la variación de la capacidad de distribución de la carga en el pavimento. Sin embargo, es factible que para dos estructuras con diferentes características y resistencia, se obtengan áreas similares, aunque las cuencas de deflexión tengan formas diferentes. Para considerar el efecto de la forma de la cuenca, Orozco (2005) propone un índice estructural- I_e , basado en la relación entre deflexión pico registrada bajo el punto de aplicación de la carga y la posición del punto de inflexión de la curva. La evaluación de éste índice para casos reales, dio lugar a proponer rangos de valores para juzgar la condición estructural del pavimento, desde excelente (entre 0 y 0.05) hasta pésima (mayor de 0.4). En la misma investigación, se destaca la utilidad práctica del indicador, pues se observó la relación con las soluciones recomendables para mejorar la condición de un pavimento: casos de recuperación in situ presentaron valores mayores a 0.3 y los tratamientos superficiales valores menores de 0.1; valores intermedios se asociaron a reforzamientos con sobre-carpeta.

4 MÉTODOS DE ANÁLISIS DE DEFLEXIONES

Para efectos de identificar parámetros mecánicos con base en las respuestas conocidas de deflexión, una de las técnicas más utilizadas es la del cálculo inverso o retro-cálculo. Generalmente se utiliza un modelo equivalente de respuesta teórico donde se asumen inicialmente los módulos de cada capa, con los cuales se calculan las deflexiones y, mediante iteraciones sucesivas, se van ajustando los parámetros mecánicos hasta lograr aproximaciones satisfactorias entre las deflexiones calculadas y las medidas.

La precisión de los análisis de retrocálculo es sensible al tipo y cobertura del análisis de respuesta del pavimento, mientras que la eficiencia depende de la técnica de optimización del proceso.

Se han desarrollado técnicas de cálculo inverso con variaciones en el tipo de análisis, el algoritmo de optimización y el modelo de respuesta utilizado. Goktepe et al. (2006a) realizaron una discusión detallada sobre los métodos desarrollados para pavimentos y los comparan en términos de precisión, costo computacional, detalles de cálculo y requerimientos de datos.

En el ámbito internacional identifican tres enfoques analíticos diferentes: estáticos y dinámicos que aportan soluciones cerradas, analíticas o deterministas, y adaptativos con soluciones aproximadas.

4.1 Aproximaciones Estáticas

En la práctica común se aplican análisis estáticos con modelos, basadas en las teorías de Boussinesq y Burmister sobre elasticidad en medios estratificados. Con ellas se obtienen resultados satisfactorios en estructuras de pavimento con estratos rígidos ubicados a más de 5.5 m, donde resulta válida la hipótesis

tradicional que considera al suelo de cimentación como una capa de espesor semi-infinito. Los modelos lineales son los más utilizados dada su simplicidad, aunque no reflejan la verdadera naturaleza del problema. Para considerar la no-linealidad se han desarrollado aplicaciones de software con elemento finito aunque se sacrifica de manera importante la eficiencia en los cálculos, en términos de costo computacional.

4.2 Aproximaciones Dinámicas

Estos análisis permiten considerar las características visco-elásticas del concreto asfáltico, la naturaleza dinámica inherente al problema y, eventualmente, la profundidad de la capa rígida. Los obstáculos que suelen presentar, están relacionados con la complejidad y demoras computacionales y con la ardua tarea para obtener todos los datos de entrada para el análisis (frecuencia angular, visco-elasticidad en la capa asfáltica, relación interna de amortiguamiento en las capas granulares y en la subrasante). La mayoría de los modelos dinámicos asumen un comportamiento lineal de los materiales, simplificando así el problema para disminuir la complejidad de los cálculos y por tanto, los tiempos de análisis.

En conclusión, se puede decir sobre los métodos de análisis estáticos y dinámicos que, aunque se cuenta con planteamientos teóricos o teórico-experimentales apoyados en la elasticidad y visco-elasticidad, los niveles de confiabilidad son aún discutibles dada la cantidad de simplificaciones que se realizan, asumiendo hipótesis que muchas veces no reflejan la verdadera naturaleza del problema.

Como producto, se obtienen parámetros de comportamiento y caracterización, que no representan las condiciones reales de los pavimentos, pero que se asumen aceptables en virtud del estado actual del conocimiento y de las posibilidades tecnológicas.

4.3 Aproximaciones Adaptativas

Bajo el panorama descrito, se considera que el enfoque adaptativo aportado por el cómputo aproximado puede jugar un rol importante en la modelación apropiada de sistemas estructurales de pavimento.

Estos métodos de análisis utilizan herramientas computacionales de la inteligencia artificial, desarrolladas en el campo de las matemáticas aplicadas y en particular las redes neuronales artificiales, RNA, útiles en la búsqueda de relaciones complejas no lineales en problemas complejos de regresión multi-variada.

Los sistemas de RNA toman como referente las redes neuronales biológicas y en especial, la complejidad de la estructura y la eficiencia del cerebro humano para procesar información y tomar decisiones, donde la inteligencia es producto de la alta conectividad existente entre la gran cantidad de neuronas del cerebro.

De manera análoga, las RNA se conforman mediante unidades o neuronas interconectadas las cuales reciben, procesan y transmiten señales o información a las otras con las cuales tienen conexión.

Estructuralmente, los modelos neuronales son sistemas de múltiples capas en paralelo, con una capa de entrada y una de salida; en el intermedio existen capas ocultas que le aportan dimensionalidad al problema. Las configuraciones o arquitecturas más complejas se asocian con problemas no lineales, mientras que las estructuras simples pueden modelar apropiadamente problemas lineales.

Cada capa está constituida por neuronas que se interconectan con las de otras capas de la red tal como se ilustra en la Figura 2, e incluso con las de la misma capa; estas uniones entre neuronas tienen asociado un valor conocido como peso, que refleja el grado de conectividad o relación entre variables.




Figura 2. Configuración básica de un modelo neuronal

La modelación con RNA se efectúa en dos etapas: la de aprendizaje o entrenamiento y la de prueba. En la primera, el proceso de aprendizaje puede realizarse de modo supervisado, reforzado o no supervisado, según se describen en la Tabla 1, dependiendo del problema a solucionar.

Tabla 1. Tipos de aprendizaje en modelos neuronales

Aprendizaje	Descripción
Supervisado	Se conocen las entradas y las salidas deseadas y se busca establecer relaciones entre ellas. Útil en problemas de regresión multi-variada.
Reforzado	No se conocen a ciencia cierta las salidas, pero se tienen indicios sobre ellas. Útil en problemas de regresión multi-variada.
No supervisado	No se conocen las salidas. La red recibe las entradas y encuentra patrones significativos. Útil para agrupamiento o clasificación.

Para la búsqueda de parámetros mecánicos en pavimentos, resultan aplicables los aprendizajes de tipo supervisado y reforzado. En estos casos, se presentan las variables de entrada y salida a la red, cada una de las cuales queda asociada a una neurona; la red asigna valores iniciales a los pesos y los va ajustando mediante iteraciones sucesivas. Al final de cada iteración, la red

proporciona unas salidas calculadas y las compara con las salidas conocidas hasta satisfacer un criterio de aceptación preestablecido, que en general es una función de error; se dice que para entonces la red ha aprendido naturalmente las relaciones.

En la etapa de prueba, se busca la generalización, es decir que el modelo suministre salidas razonables para condiciones diferentes para las cuales se entrenó.

Los principales elementos que se deben definir en la modelación neuronal son: la arquitectura o configuración de la red, las reglas o algoritmos de aprendizaje, las funciones de error, de entrada y de salida. Aunque estos elementos dependen del problema a abordar y de la base de datos, se requiere un arduo trabajo para su definición, regularmente mediante ensayo y error. El resultado final de la modelación, depende principalmente de arquitectura de la red, la manera en que las neuronas están interconectadas y de qué tan fuertes sean esas conexiones, es decir el valor de los pesos.

En el ámbito internacional, existen experiencias exitosas que demuestran el amplio potencial de las redes neuronales para considerarlas como herramientas de análisis complementarios no convencionales para la solución de problemas de infraestructura vial.

En particular, para estimar propiedades mecánicas de pavimentos existen antecedentes desde Meier y Rix (1995) hasta Terzi et al. (2003), usando datos sintéticos para modelar cuencas de deflexión. Ya los estudios más recientes de Reddy et al. (2004), Goktepe et al. (2006b), Rakesh et al. (2006), Saltan et al. (2006 y 2007), Sharma y Das (2008), están enfocados hacia la búsqueda de modelos eficientes usando algoritmos de optimización y modelos híbridos para la evaluación de la condición estructural de vías en servicio.

Con base en la revisión de antecedentes, se identifican dos posiciones diferentes ante las modelaciones con RNA: por un lado, aunque se reconoce la eficiencia, se recomienda su aplicación de manera cuidadosa, pues se dice que estas aproximaciones no se apoyan en un análisis mecánico ni en un modelo estructural del problema, y por lo mismo, puede presentar limitaciones en el tamaño, rango, confiabilidad y distribución de los datos para caracterizar comportamiento determinado.

En contraposición, quienes han logrado experiencias exitosas indican que estas aproximaciones, además de realizar análisis en tiempo real, permiten involucrar la incertidumbre e imprecisión que conlleva el análisis de problemas cuya complejidad dificulta la construcción de modelos para analizar su comportamiento. De hecho, se han considerado como métodos que aproximan todas las leyes mecánicas a las cuales el problema obedece, involucrando muchas de las variables del problema para determinar parámetros de comportamiento, sin recurrir a las simplificaciones de los modelos tradicionales.

5 CASO APLICADO

Con el ánimo de explorar la aplicabilidad de los modelos neuronales como métodos de análisis para pavimentos

en el medio mexicano, en este trabajo se considera un caso de estudio con información suficientemente representativa para modelar y determinar parámetros mecánicos de comportamiento del pavimento y en particular, módulos de elasticidad.

Se seleccionó un corredor conformado por una calzada con dos carriles y una longitud de 28 Km, con cambios en la estructura del pavimento a lo largo de su cadenamiento; la vía atraviesa zonas planas con alturas que van desde los 6 m.s.n.m. a 34 m.s.n.m., temperatura media de 23° y precipitación media anual de 58 mm.

La metodología seguida para la determinación de parámetros mecánicos del pavimento, contempla cuatro etapas: análisis preliminares, conformación de la base de datos, diseño del modelo neuronal y validación, las cuales se describen a continuación.

5.1 Análisis preliminares

Con base en la información disponible, se efectuó una caracterización inicial del corredor en función de la condición y desempeño del pavimento, según se ilustra en la Figura 3.

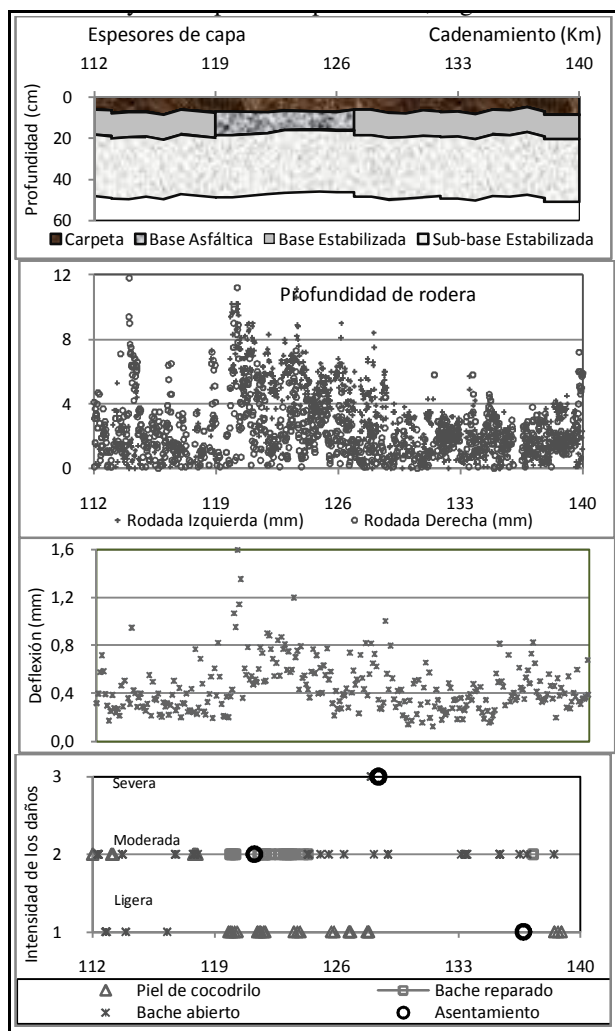


Figura 3. Principales características del corredor vial

En principio, se identifican tres sectores desde el punto de vista estructural: el sector I comprendido entre el k112 y el k119; el sector II entre el k119 y el k127 y el sector III entre el k127 y el K140.

Los sectores I y III poseen la misma estructura de pavimento conformada por una capa asfáltica de 7 cm de espesor, una capa de base estabilizada con cemento de 12 cm y una capa de subbase rigidizada con cemento de 30 cm de espesor. En el sector II, la capa de base estabilizada es reemplazada por una base asfáltica de 10 cm de espesor. En los tres sectores, las capas inferiores tienen un espesor de 3 m.

El sector II exhibe los valores más altos de profundidad de rodera, sin llegar a considerarse como críticas; también presenta alta proporción de daños estructurales caracterizados como piel de cocodrilo con intensidad ligera, y baches reparados y baches abiertos con intensidad moderada. Adicionalmente, registra las mayores deflexiones pico, lo cual puede estar asociado con el efecto combinado entre mayor espesor de capa

asfáltica, menor espesor de capas granulares y los niveles de daño observados.

Por su parte, en los sectores I y III, las mayores deflexiones se encuentran asociadas con sectores donde predominan daños tipo baches abiertos con intensidad moderada y severa, y asentamientos severos y ligeros.

Se aprecian niveles altos de deflexiones y profundidad de roderas alrededor de la zona donde hay cambio de estructura en el corredor, e incluso presencia de baches y piel de cocodrilo.

5.2 Conformación de la Base de Datos

Dentro de la información disponible, existen variables asociadas con la estructura del pavimento, pruebas de auscultación no destructiva y resultados de análisis realizados previamente por métodos tradicionales (Orozco 2005), los cuales constituyen un marco de referencia para poder discutir y de alguna manera validar el modelo propuesto.

La base de datos para la estimación de módulos quedó conformada por las variables de entrada asociadas con la geometría de la estructura del pavimento, pruebas de deflexión y materiales de las capas, con un total de 278 registros y 18 variables. Esta base se dividió posteriormente en dos grupos: 200 datos para la etapa de entrenamiento o aprendizaje y 78 datos para la de prueba.

En la Tabla 2 se presentan las variables consideradas en la modelación neuronal para poder evaluar el comportamiento mecánico del corredor seleccionado.

Tabla 2. Variables utilizadas para análisis

Clasificación	Variable
Geometría	Espesor de capas (3), medidos cada km. Profundidad de cada capa (3).
Pruebas-deflexión	Carga aplicada (1 nivel). Deflexión registrada en sensores (7)
Material	Tipo de material – Relación de Poisson(4).

5.3 Diseño del Modelo Neuronal

En esta etapa, se realizaron múltiples pruebas por ensayo y error para diseñar la mejor configuración de red neuronal capaz de predecir los valores de módulos a partir de registros de deflexión, puesto que no se encontraron antecedentes sobre la sensibilidad que tiene la estructuración de la red neuronal en la evaluación de deflexiones en pavimentos, o análisis comparativos de resultados teniendo en cuenta diferentes combinaciones entre los elementos propios de este tipo de herramienta.

La red neuronal quedó conformada por una capa de entrada con 18 neuronas de entrada, y una capa de salida con 4 neuronas que representan los valores de módulos elásticos (esperados). Se aplicaron los tipos de aprendizaje supervisado y reforzado, probando varias posibilidades en cuanto al número de capas ocultas y cantidad de neuronas en esas capas.

Buscando eficiencia en términos de tiempo de cómputo y precisión, dentro del análisis de sensibilidad se evaluó la estructura completa del pavimento y análisis separados para cada capa y cada sector estructural. Adicionalmente, se evaluó el efecto de deterioros estructurales severos, mediante una depuración manual de la base de datos, eliminando registros con niveles altos de roderas, baches y deflexión. Esto teniendo en cuenta que los análisis tradicionales revelan que las pruebas de deflexión tienen limitaciones para evaluar estructuralmente el pavimento cuando existen discontinuidades (agrietamientos) o evidencia de deformaciones permanentes asociadas con insuficiencias de espesores, calidad de los materiales o problemas constructivos.

El análisis de sensibilidad refleja que no es necesario realizar análisis separados por sectores, ni eliminar registros de zonas con daños estructurales para mejorar el desempeño de la red neuronal.

Finalmente, en la Tabla 3 se presentan las características de la red neuronal que tuvo mejor desempeño para la determinación de módulos elásticos.

Tabla 3. Elementos de la red neuronal para determinar módulos

Elemento	Tipo/Cantidad	
Arquitectura	Jordan recurrente	
Regla de aprendizaje	Retropropagación mejorada	Jacob
Función de error	Error medio absoluto	
Función de entrada	Producto punto	
Función de transferencia	Sigmoide	
No. de capas ocultas	Una	
Numero de nodos ocultos	Cuatro	

Con esta configuración, se obtiene un error de 1.74% entre los módulos calculados con la red neuronal y los calculados con teoría elástica, lo cual refleja resultados satisfactorios en cuanto a precisión. La convergencia se logró en la iteración No. 1700, en menos de dos minutos, demostrando la eficiencia computacional del modelo. El aprendizaje reforzado arrojó las mejores respuestas en cuanto a los módulos calculados, donde los valores empleados para entrenar la red, se consideran como "indicios" de los valores esperados.

En la Figura 4 se ilustran los módulos de capa obtenidos en la etapa de entrenamiento de la RNA, a lo largo de la vía. Para efectos de comparación, se incluyen los valores calculados mediante teoría elástica.

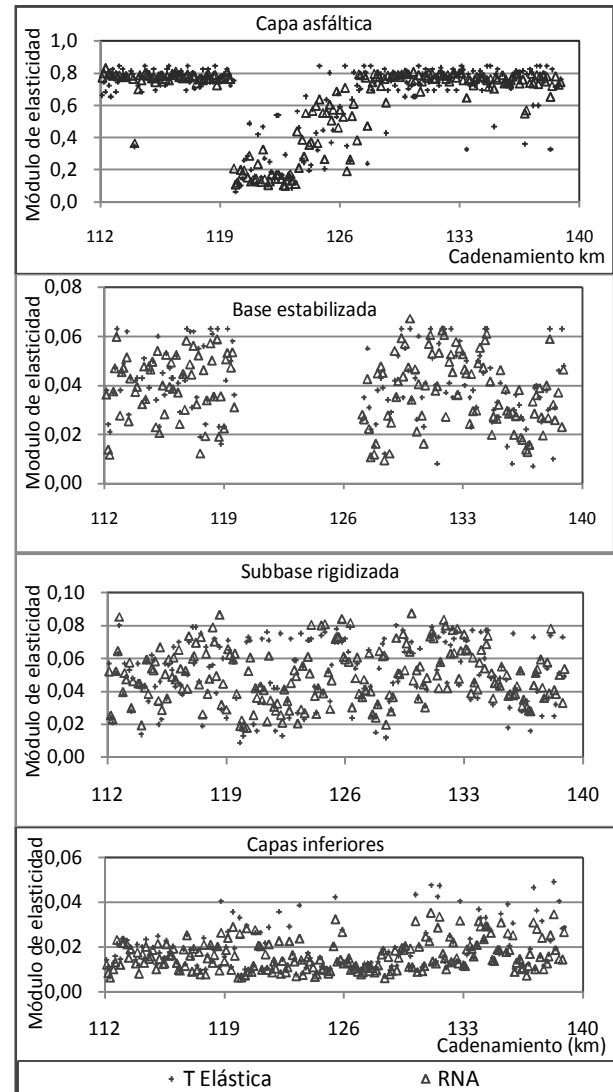


Figura 4. Módulos de capa estimados ($\text{kg/cm}^2 \cdot 10^5$), etapa de entrenamiento

5.4 Validación

La etapa de prueba de la modelación neuronal, constituye una forma de validar los resultados, puesto que en ella se presenta a la red un conjunto de datos diferentes a los utilizados para el entrenamiento. Como se mencionó anteriormente, este conjunto está conformado por 78 registros. En la Figura 5 se presentan los módulos estimados para estas nuevas condiciones, mediante RNA y teoría elástica.

Los resultados demuestran la gran capacidad de la RNA para reproducir la respuesta mecánica de un pavimento ante pruebas de deflexión. Se observa coherencia entre la condición del pavimento y los módulos de capa obtenidos: el sector II exhibe módulos bajos en la capa asfáltica, asociados con las altas

deflexiones registradas y con la intensidad y severidad de daños estructurales; los sectores I y III, exhiben módulos de capa similares en virtud del mismo tipo de estructura.




Figura 5. Módulos de capa ($\text{kg/cm}^2 \cdot 10^5$), etapa de prueba

Cualquier método de análisis resulta sensible a la calidad de la información disponible y las RNA no son ajenas a este hecho, pues las predicciones que se realicen con una red ya entrenada dependen de la confiabilidad de la base de datos usada en la etapa de aprendizaje.

Para validar previamente los datos usados para entrenar la red, se optó por diseñar una red neuronal, bajo la premisa de que “existe un conjunto de módulos de capa, capaz de generar una respuesta de deflexiones muy similar a las deflexiones medidas en campo bajo las

condiciones específicas de cada prueba”. Esto se traduce en una red neuronal donde las entradas están conformadas por variables asociadas con las características de la prueba de deflexión y con propiedades de la estructura; las salidas corresponden a las deflexiones o respuesta conocida del pavimento. Conceptualmente, esto corresponde a un aprendizaje supervisado, pues se conocen las respuestas ante los patrones de entrada.

Mediante pruebas de ensayo y error, se logró la convergencia en la iteración No. 678, con un error de 1.8% en menos de tres minutos. En la Figura 6, se muestra el ajuste entre las deflexiones calculadas con la red neuronal y las medidas en campo, lo cual nos permite concluir acerca de la confiabilidad de los módulos de elasticidad.

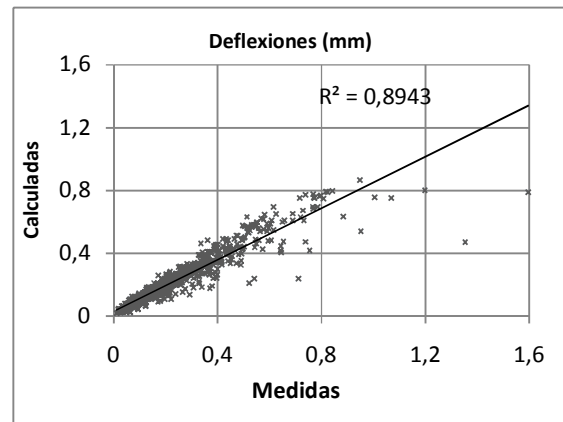


Figura 6. Deflexiones calculadas con RNA y medidas en campo

6 CONCLUSIONES

Mediante la integración de diversas áreas del conocimiento, se plantea una forma confiable no convencional para abordar la modelación y análisis estructural de pavimentos en servicio.

De acuerdo con los antecedentes y los resultados alcanzados en este trabajo, se identifican beneficios importantes al usar herramientas de la inteligencia computacional, y en particular las RNA.

Dada la capacidad de las RNA para efectuar modelación multi-variada no-lineal, se obtienen aproximaciones realistas que integran las variables significativas que influyen en la problemática, sin necesidad de asumir hipótesis simplificadoras.

Por otra parte, se logra eficiencia en términos del costo computacional y buenos niveles de precisión, sin que la modelación se convierta en algo complicado de usar para efectos prácticos.

Específicamente para determinar parámetros mecánicos a partir de la modelación de deflexiones, se aportan elementos importantes para definir la

configuración de la red neuronal más eficiente, como producto de un intenso análisis por ensayo y error.

Los resultados obtenidos en la modelación neuronal para la determinación de módulos de elasticidad, indican que el aprendizaje reforzado muestra ser el más eficiente en precisión y tiempo: se obtuvieron errores menores al 3% y resultados en menos de tres minutos.

El análisis de sensibilidad realizado, refleja que no es necesario considerar por separado los distintos sectores del corredor ni las capas del pavimento para mejorar los resultados; esto indica la gran capacidad de las redes para realizar análisis robustos.

Para el caso de estudio, tampoco se obtuvieron mejoras en el desempeño del modelo al eliminar los registros de deflexiones, baches o roderas severos, en virtud de la baja representatividad de estos datos dentro de la gran base de datos considerada. Para estudiar más profundamente ese efecto, se requeriría analizar corredores con mayor cantidad de este tipo de registros.

Más allá de establecer correlaciones que reflejen buenos ajustes entre los comportamientos observados y los estimados, y de establecer ventajas y limitaciones del método respecto a los análisis tradicionales, resulta de gran interés poder discutir acerca de la forma con que el modelo permite representar la realidad, a la luz de los resultados obtenidos y de la experiencia lograda en esta investigación. Con base en ellos, se reconocen las bondades para el procesamiento e interpretación de información, lo cual se traduce en conocimiento aplicable en la solución de problemas específicos de evaluación de pavimentos.

7 COMENTARIOS FINALES

Este trabajo forma parte de una investigación doctoral que se viene desarrollando en el Instituto de Ingeniería de la UNAM, como un esfuerzo para implementar el cómputo aproximado en la búsqueda de soluciones para problemas de la ingeniería de pavimentos.

Aunque los resultados preliminares resultan satisfactorios para el procesamiento de datos de auscultación no destructiva y para la identificación de parámetros mecánicos en pavimentos flexibles, se espera complementar una metodología basada en un modelo neuro-difuso que contemple otras variables de comportamiento, de manera que resulte útil para procesos de toma de decisión propios de la gestión de infraestructura de carreteras.

AGRADECIMIENTOS

Los autores reconocen y aprecian el apoyo valioso del Dr. Raúl Vicente Orozco, al suministrar la información relacionada con la auscultación no destructiva. Igualmente se agradece el soporte proporcionado por la Dra. Silvia Raquel García, al compartir su conocimiento y experiencia sobre los métodos cognitivos aplicados a problemas geotécnicos. El desarrollo de esta investigación ha sido posible gracias a la comisión

otorgada por la Universidad Nacional de Colombia a una docente para adelantar estudios de Doctorado en Ingeniería en la UNAM.

REFERENCIAS

- Abdallah, I., Yuan, D. y Nazarian, S. 2005. Case studies on application of data integration to nondestructive testing of pavements, *Research Report 0-4393-3*. Center for Transportation Infrastructure Systems, University of Texas at El Paso. Texas Department of Transportation and Federal Highway Administration, USA.
- Amarantha, M., Sudhakar, R. y Pandey, B. 2004. Selection of genetic algorithm parameters for backcalculation of pavement moduli, *International Journal of Pavement Engineering*, Taylor y Francis Ltd., E y FN Spon Ltd., 5 (2): 81-90.
- Biswas, K. y Pellinen, T. 2007. Practical methodology of determining the in situ dynamic complex moduli for engineering analysis, *Journal of Materials in Civil Engineering*, ASCE, 19(6): 508-514.
- Collop, A., Armitage, R. y Thom, N. 2001. Assessing variability of in situ pavement material stiffness moduli. *Journal of Transportation Engineering*, ASCE, EBSCO publishing, 127(1): 74-81.
- García, S. 2009. *Métodos Conexionistas para la Solución de Problemas de Ingeniería GeoSísmica*. Tesis de Doctorado en Ingeniería, UNAM, México D.F.
- Garnica P. y Correa A. 2004. Conceptos mecanicistas en pavimentos. *Publicación técnica No. 258, SCT – IMT*, Querétaro, México.
- Goel, A. y Das, A. 2008. Non-destructive testing of asphalt pavements for structural condition evaluation: a state of the art, *Journal of Non Destructive Testing and Evaluation*, Taylor & Francis Ltd., 23(2): 121-140.
- Goktepe A., Agar E. y Lav H. 2006a. Advances in back-calculating the mechanical properties of flexible pavements, *Advances in Engineering software*, Elsevier Ltd., 37: 421-431.
- Goktepe, A., Agar, E. y Lav, A. 2006b. Role of learning algorithm in neural network-based backcalculation of flexible pavements. *Journal of Computing in Civil Engineering*, ASCE, 20(5): 370-373.
- Gopalakrishnan, K y Ceylan, H. 2008. Stiffness characterization of full-scale airfield test pavements using computational intelligence techniques, *The IES Journal Part A: Civil & Structural Engineering* 1(4): 280-290.
- Haykin, S. 1999. *Neural Networks, a Comprehensive Foundation*. 2nd ed. Prentice Education Inc. India.
- Ledesma, A. 1987. *Identificación de parámetros en geotecnia*, Tesis de doctorado en ingeniería, Universidad Politécnica de Cataluña, Barcelona, España.

- Meier R. y Rix G. 1995. Back-calculation of flexible pavement moduli from dynamic deflection basins using artificial neural networks, *TRB Transportation Research Record 1473*, National Research Council, Washington, D.C: 72-81.
- Orozco, R. 2005. *Evaluación de pavimentos flexibles con métodos no destructivos*, Tesis de Doctorado en Ingeniería, UNAM. México, D.F.
- Rakesh N., Jain A., Reddy M. y Reddy K. 2006. Artificial neural networks - genetic algorithm based model for back-calculation of pavement layer moduli, *International Journal of Pavement Engineering*, Taylor y Francis, 7(3): 221-230.
- Reddy, M., Sudhakar, R. y Pandey, B. 2004. Selection of genetic algorithm parameters for back-calculation of pavement moduli, *International Journal of Pavement Engineering*, Taylor y Francis Ltd., E y FN Spon Ltd. 5(2): 81-90.
- Rico A., Téllez R. y Garnica P. 1998. Pavimentos flexibles. Problemática, metodologías de diseño y tendencias, *Publicación Técnica No 104. SCT – IMT*, Querétaro, México.
- Sharma S. y Das A. 2008. Back-calculation of pavement layer moduli from falling weight deflectometer data, using an artificial neural network, *Canadian Journal of Civil Engineering*, NRC Research Press, 35: 57 – 66.
- Saltan M., Saltan S. y Şahiner A. 2006. Fuzzy logic modeling of deflection behavior against dynamic loading in flexible pavements, *Construction and Building Materials*, Elsevier Ltd., 21(7): 1406-1414.
- Saltan M. y Terzi S. 2007. Modeling deflection basin using neural networks with cross-validation technique in backcalculating flexible pavement layer moduli, *Advances in Engineering software*, Elsevier Ltd., article in press.
- Saltan M. y Sezgin H. 2007. Hybrid neural network and finite element modeling of sub-base layer material properties in flexible pavements, *Material and design*, Elsevier Ltd., 28: 1725-1730.
- Seo, J., Kim, S., Choi, J. y Park, D. 2009. Evaluation of layer properties of flexible pavement using a pseudo-sattic analysis procedure of falling weight deflectometer, *Construction and Building Materials*, Elsevier Ltd., 23: 3206-3213.