

IAG43-07-2013
**RETROCALCULO DE MÓDULOS MEDIANTE EL USO DE REDES
NEURALES ARTIFICIALES CONSIDERANDO CARGA MÚLTIPLE Y
CERO FRICCIÓN ENTRE CAPAS DE PAVIMENTOS FLEXIBLES**

Ing. Fabricio Leiva Villacorta, Ph.D., MBA
Investigador. Unidad de Materiales y Pavimentos
Laboratorio Nacional de Materiales y Modelos Estructurales, Universidad de Costa Rica,
Código Postal: 11501-2060, San Pedro de Montes de Oca, San José, Costa Rica
Teléfono: (506) 2511-2529 / Fax: (506) 2511-4440
E-mail: fabricio.leiva@ucr.ac.cr

Ing. David Timm, Ph.D., PE
Brasfield & Gorrie Professor of Civil Engineering, Auburn University,
238 Harbert Engineering Center, Auburn, AL 36849; PH (334) 844-6282;
E-mail: timmdav@auburn.edu

Resumen

Las redes neurales artificiales (ANN en inglés) se han utilizado recientemente para calcular los módulos de capa a partir de resultados de deflectometría de impacto. Hasta la fecha los modelos desarrollados con métodos ANN consideran una carga de 40kN y fricción completa en la interface de capas. Sin embargo, los ensayos de deflectometría de impacto se ejecutan con múltiples niveles de carga representativos de cargas de tránsito y se puede utilizar para medir la sensibilidad a los estados de esfuerzo de las capas granulares y suelos. El objetivo de este estudio fue desarrollar modelos ANN capaces de predecir los módulos de capa de pavimento de una forma rápida y fiable con niveles múltiples de carga y condiciones de cero fricción o deslizamiento completo entre capas. Los resultados de la aplicación de modelos ANN indicaron que es posible obtener errores significativos en el cálculo de módulos de las capa de pavimento debido al modelado indebido de la condición de interface entre capa. Por ejemplo, la tendencia fue el sobreestimar el módulo de la carpeta asfáltica por 30% y también subestimar el módulo de la base granular por 74%. Los modelos ANN se utilizaron para calcular los módulos de las secciones estructurales de la pista de ensayo del NCAT considerando condiciones de interface entre capas de fricción completa y cero fricción. Se determinó que los módulos calculados con la metodología convencional de retrocálculo de módulos produjo el mayor error global, seguida por una disminución significativa en el error al utilizar modelos ANN bajo condiciones de fricción completo. Más aun, la consideración de los modelos ANN con cero fricción obtuvieron los mejores resultados (errores más bajos de todos).

Resumo

As redes neurais artificiais (ANN em Inglês) recentemente são usadas para calcular os módulos das camadas a partir dos resultados do defletômetro de impacto. Até hoje, os modelos desenvolvidos com métodos ANN consideram uma carga de 40kN e uma fricção plena nas interfaces das camadas. No entanto, os testes do defletômetro de impacto são executados com

múltiples níveis de carga representativos das cargas do tráfego, e podem ser utilizados para avaliar a sensibilidade aos estados de esforço das capas granulares e solos. O objetivo deste trabalho foi desenvolver modelos ANN capazes de prever os módulos das camadas do pavimento de uma maneira rápida e confiável com níveis múltiplos de carga e condições de fricção zero ou deslizamento completo entre as camadas. Os resultados da aplicação dos modelos ANN indicaram que é possível obter erros significativos no cálculo dos módulos das camadas do pavimento devido a uma modelação incorreta da condição de interface entre as camadas. Por exemplo, a tendência foi sobrestimar o módulo da superfície de rolamento em 30% e também subestimar o módulo da base granular em 74%. Os modelos ANN foram utilizados para calcular os módulos das secções estruturais da pista de ensaio do NCAT considerando uma fricção plena e uma fricção zero nas interfaces das camadas. Determinou-se que os módulos calculados com o método convencional de retroanálise de pavimentos produziu um maior erro global, seguido por uma redução significativa no erro usando modelos ANN em condições de fricção plena. Além disso, a consideração dos modelos ANN com fricção zero obteve os melhores resultados (erros mais baixos para tudo).

INTRODUCCIÓN

Uno de los ensayos no-destructivos de campo utilizados para calcular el módulo de capa de pavimentos es el ensayo de deflectometría de impacto. Este ensayo se realiza con el Falling Weight Deflectometer (FWD) el cual deja caer una carga representativa de camión sobre una superficie circular. Conociendo la cantidad de capas, los espesores de las mismas y mediante el proceso de iterativo de retrocálculo es posible obtener los módulos de capa.

El proceso de retrocálculo tienen ciertas limitantes que se interponen a la obtención de valores de módulo razonables para una sección dada. Por ejemplo, se obtiene un valor de módulo diferente cada vez que el proceso se pone en funcionamiento y esta desviación de valores depende mucho de los valores de entrada. Para combatir esta y otras limitaciones, algunos investigadores (*Meier et al., 1995, 1997, Ferregut et al. 1999, Ceylan et al, 2005, Gopalakrishnan y Thompson, 2007*) han decidido buscar metodologías alternas como es el caso de redes neurales artificiales (ANN en inglés).

Las redes neuronales Artificiales son redes interconectadas masivamente en paralelo que contienen elementos simples y con una organización jerárquica. Son modelos de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los animales. El aprendizaje en este tipo de modelos es adquirido a través de entrenamiento que se produce de forma iterativa hasta obtener un modelo óptimo. El uso de esta metodología para el cálculo de módulos de capa en pavimentos no solo ha superado las limitantes propias del retrocálculo, pero también han demostrado ser mas precisas y generan resultados de por lo menos 42 veces más rápido que el retrocálculo. El único inconveniente que se ha encontrado a la fecha es que los investigadores se han enfocado en la aplicación de una única carga (40 kN) y al igual de le metodología de retrocálculo convencional sólo considera la condición de completa adherencia o fricción entre las capas del pavimento.

Por otro lado, el uso de diferentes niveles de carga ensayados con el equipo FWD puede ser usado para simular diferentes cargas vehiculares y para medir el comportamiento no-lineal de capas granulares y suelos (*Von Quintus and Killingsworth, 1998*). Adicionalmente, la impropia modelación de la interacción entre capas puede afectar significativamente los resultados de

módulos de capa, especialmente para capas con materiales granulares (*Romanoschi and Metcalf 2003*). Con el fin de incorporar mas opciones en términos de niveles de carga y no limitarse a la modelación de una única interface entre capas se desarrolló un estudio basado en modelos ANN que consideren estas funciones y la verificación de estos modelos se realizó con resultados de campo obtenidos de la pista de ensayos de pavimentos a escala natural del Centro Nacional de Tecnología del Asfalto (NCAT en inglés).

OBJETIVO

El objetivo de este estudio fue el desarrollar modelos ANN capaces de calcular módulos de capa de pavimentos de una forma rápida y precisa que incorpore múltiple niveles de carga y que considere cero fricción entre capas.

RESULTADOS Y DISCUSIÓN

Errores potenciales debido a inadecuada modelación

Para el desarrollo de los modelos ANN y análisis general se creó una base de datos para una estructura de pavimento flexible, donde el mecanismo de cálculo de respuesta fue el análisis multicapa elástica. La Tabla 1 muestra las características y rango de propiedades considerado para la generación de las bases de datos para este estudio.

Tabla 1: Rango de propiedades y características de capa

Capa	Módulo, ksi	Espesor, in	Módulo de Poisson
Mezcla asfáltica (C1)	50 - 3000	5.0 - 8.0	0.35
Base Granular (C2)	1 - 100	4.5 - 7.5	0.40
Subrasante (C3)	1 - 100	Infinito	0.45

Para esta parte del estudio se creó una base de datos artificial de 10 mil vectores con variables de entrada: módulo de cada capa de una estructura de 3 capas, espesores de capa y una carga de 9 kip (40 kN); variables de salida: deflexiones; y lo más importante: considerando "cero fricción" entre capas. Seguidamente se procedió a retrocalcular el módulo de capa para hacer la comparación uno a uno con los módulos de entrada utilizando el procedimiento convencional que considera fricción completa entre capas. Se utilizó el programa EVERCALC 5.0 para realizar el retrocálculo de módulos donde el parámetro estadístico: promedio de la raíz cuadrada del error (RMSE en inglés) juega un papel esencial en la valoración de la calidad de los valores estimados de módulo. Por ejemplo, se considera que las calidad de los datos es muy buena para valores de RMSE menores a 1%, buena de 1% a 3%, aceptable de 3% a 6%, mala mayor a 6% (*Everseries User's Guide, 2005*).

Con valores de RMSE desde 0.5% hasta 27% se comprobó que el módulo de la capa asfáltica fue sobre-estimado en promedio por un 30% mientras que el módulo de la base granular fue sub-estimado en un 74%; finalmente el módulo de la subrasante fue el menos afectado con una desviación promedio de 3%. A partir de una prueba t-pareada de dos colas con $\alpha = 5\%$, hay evidencia estadística para concluir que el modelar la estructura de pavimento con fricción completa, en lugar de cero fricción entre capas, produce diferencias significativas en los módulos de la capa asfáltica y aun mas en la capa de base granular como se muestra en la Tabla 2. Por otro lado, no hay suficiente evidencia para decir que el módulo de la subrasante retrocalculado o

estimado sea diferente al módulo original, por lo tanto pueden ser iguales y puede no ser afectado por el tipo de modelación de la interface base/subrasante. Para este caso, los resultados ponen en evidencia el potencial error en que se puede incurrir al erróneamente modelar la interface de capas como si tuvieran adherencia o fricción completa cuando lo opuesto es lo que rige y se confirma que los materiales de base serían los mas afectados.

Tabla 2: Prueba t-pareada

Parámetro	Promedio	Desv. Est.	t-value	p-value
E1 original	498.3	113.5	28.46	<<0.05
E1 Estimado	647.1	190.2		
Diferencia	148.6	222.3		
E2 Original	27.7	13.1	-64.85	<<0.05
E2 Estimado	7.1	3.61		
Diferencia	-20.5	13.4		
E3 Original	16.2	7.82	1.63	0.104
E3 Estimado	16.6	7.62		
Diferencia	0.42	10.9		

Desarrollo y aplicación de los modelos ANN

Una red neuronal típica se puede caracterizar por la función de base o de combinación y la función de activación o transformación. Para este estudio la función de activación se muestra en la Ecuación 1, mientras que las Ecuaciones 2, 3 y 4 funcionan como función base. La Figura 1 muestra el proceso de entrenamiento y cálculo de valores respuesta (vector salida) de la red neuronal que es del tipo aprendizaje hacia adelante con retro-propagación del error.

$$f(T) = \frac{2}{1+e^{-2T}} - 1 \quad (1)$$

$$H_k^1 = B_k^1 + \sum_{i=1}^m W_{ik}^1 P_i \quad (2)$$

$$H_j^2 = f(B_j^2 + \sum_{k=1}^n H_k^1 W_{kj}^2) \quad (3)$$

$$Output = Ln(E_1, E_2, E_3) = f(B_0 + \sum_{j=1}^n H_j^2 W_j^3) \quad (4)$$

Donde;

P_i = variables de entrada

T = variable transferida,

H_k^1 = valores transferidos de los nodos en la primera capa oculta,

H_j^2 = valores transferidos de los nodos en la segunda capa oculta

W_{ik}^1 = pesos de interconexión de la primera capa oculta,

W_{kj}^2 = pesos de interconexión de la segunda capa oculta,

W_k^3 = pesos de interconexión de la capa de salida,

B_k^1 = factores de sesgo de la primera capa,

B_j^2 = factores de sesgo de la segunda capa,

B_0 = factores de sesgo de la última capa,

m = número de nodos en la primera capa oculta

n = número de nodos de la segunda capa oculta

$Ln(E_1, E_2, E_3)$ = Logaritmo natural del módulo de cada capa.

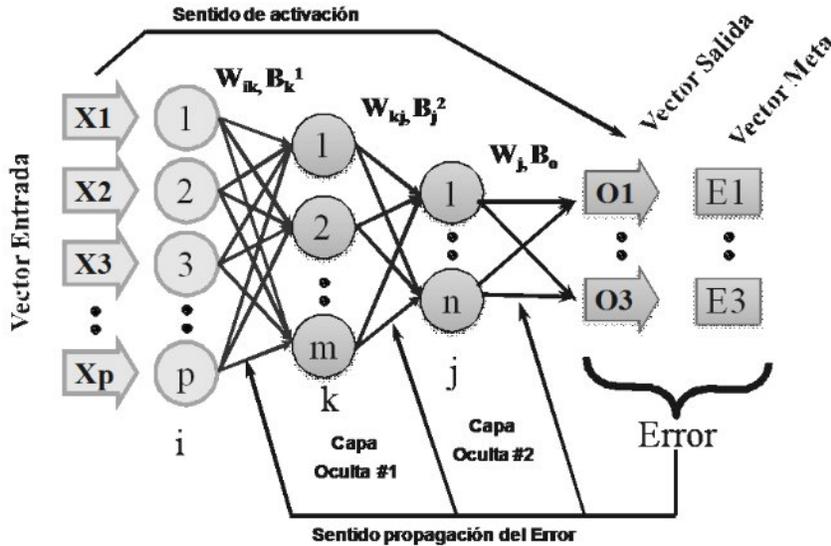


Figura 1: Proceso de funcionamiento del modelo

Para esta parte del estudio se creó una base de datos artificial de 100 mil vectores con variables de entrada: módulo de cada capa de una estructura de 3 capas, espesores de capa y cuatro niveles de carga (6, 9, 12 y 16 kip); con variables de salida: deflexiones (para 9 sensores del FWD). Al final se desarrollaron 2 modelos que consideran "cero fricción" (ANN Full Slip) entre capas y "fricción completa" (ANN Full Bond) entre capas.

La Figura 2 muestra el promedio y la variabilidad de cargas reales aplicadas en 5 tramos de prueba colocados en la pista a escala natural del NCAT. Los 5 tramos comparten la misma estructura y propiedades de material de soporte por lo que solamente las propiedades de las capas asfálticas para cada uno de los tramos se incluyeron en la Tabla 3. Estos tramos fueron colocados en tres capas son diferentes espesores con algunos de los casos con modificante de asfalto o con pavimento reciclado (RAP) en inglés.

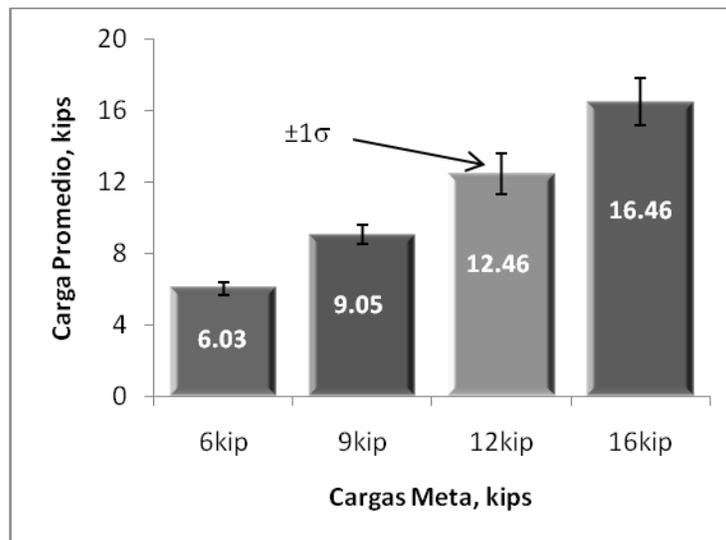


Figura 2: Promedio de cargas reales aplicadas

Tabla 3: Propiedades en sitio de los tramos estudiados

Capa	<i>1-Superior</i>				
Tramo	S9	S10	S11	N10	N11
%Modificador	2.8	2.8	2.8	0.0	0.0
Grado PG ^a	76-22	76-22	76-22	82-10	80-16
RAP ^b , %	0.0	0.0	0.0	50	50
Asfalto, %	6.1	6.1	6.4	6.0	6.1
Aire, %	6.9	7.5	6.4	7.4	8.0
Espesor, in	1.2	1.3	1.5	1.4	1.2
Capa	<i>2-Intermedia</i>				
Tramo	S9	S10	S11	N10	N11
%Modificador	2.8	2.8	2.8	0.0	0.0
Grado PG ^a	76-22	76-22	76-22	94-10	88-10
RAP ^b , %	0.0	0.0	0.0	50	50
Asfalto, %	4.4	4.7	4.6	4.4	4.7
Aire, %	7.2	7.0	7.2	7.1	6.8
Espesor, in	2.8	2.7	2.8	2.7	3.0
Capa	<i>3-Inferior</i>				
Tramo	S9	S10	S11	N10	N11
%Modificador	0.0	0.0	0.0	0.0	0.0
Grado PG ^a	67-22	67-22	67-22	94-10	88-10
RAP ^b , %	0.0	0.0	0.0	50	50
Asfalto, %	4.7	4.7	5.0	4.7	4.6
Aire, %	7.4	7.9	6.2	5.0	5.8
Espesor, in	3.0	3.0	2.6	3.0	2.9

^aGrado de desempeño Superpave^bPavimento Reciclado

Fuente: West et al, 2012.

Los resultados de un año de pruebas de deflectometría de impacto sobre estos tramos fueron utilizados para estimar los valores de módulo de capa para cada tramo. Primero se realizó la estimación de módulos de capa con la metodología tradicional de retrocálculo la cual considera "fricción completa" entre capas y con el uso del programa EVERCALC 5.0. Los resultados de estos valores fueron comparados con los valores estimados del modelo ANN Full Bond que también considera "fricción completa". La Figura 3 muestra la comparación entre resultados de módulo de la capa asfáltica para estos 2 primeros modelos. Por medio del análisis de la pendiente de la curva observada se determinó que los valores retrocalculados fueron en promedio 6% inferiores que los estimados con la metodología ANN. En este caso el valor tan alto de R^2 indicó una alta concordancia en la tendencia observada para los valores de módulo estimados por ambas metodologías.

En promedio, los módulos de la capa asfáltica y la subrasante presentaron resultados similares para todos los casos y para las tres metodologías empleadas como se observa en la Tabla 4. Por ejemplo, en esta tabla se observa como el tramo experimental N10 presentó en promedio el módulo de capa asfáltica y modulo de material de subrasante mas alto para las 3 metodologías empleadas. Esto se esperaba debido a la alta cantidad de material de pavimento reciclado utilizado en esta sección que resulta en una mezcla asfáltica mas rígida.

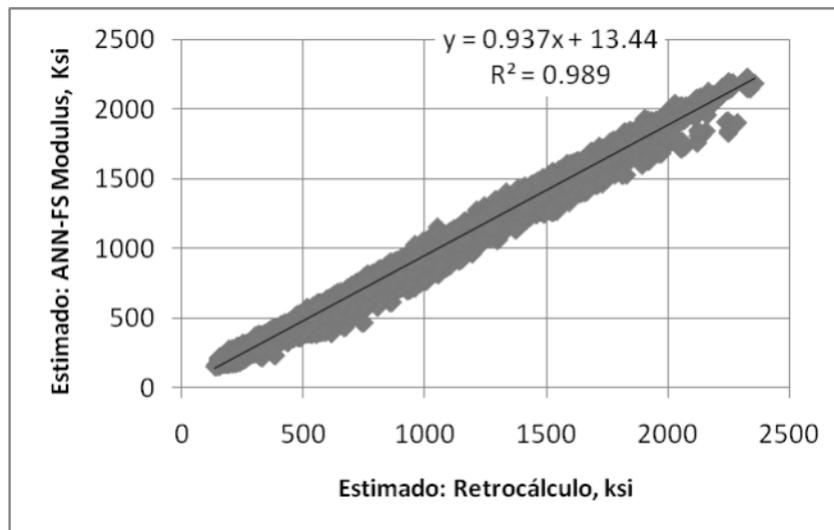


Figura 3: Módulos de capa asfáltica estimados

En cuanto a las estimación del módulo de la base, se observa que al usar la metodología convencional de retrocálculo y la metodología ANN Full Bond los resultados son similares y en general el módulo de la base estimado fue menor al módulo de la subrasante. Este fenómeno se podría explicar por la falta de incorporación del comportamiento no-linear del material de subrasante, por la inapropiada modelación de la interface de capas o por una combinación de ambas.

En este caso, al aplicar el modelo ANN Full Slip (ANN-FS) no solo se observa como en la mayoría de los casos el módulo de la base granular aumentó a valores esperados para este tipo de materiales; pero también se observó como esta última metodología presentó los errores de estimación mas bajos como se observa en la Figura 4. En promedio, se obtuvo una reducción en el nivel de error del 66% al estimar los módulos de capa con el modelo ANN-FB en lugar de la metodología convencional. Aún mas, al pasar de la metodología ANN-FB a la ANN-FS se obtuvo una mejora adicional (reducción en el error de estimación) del 70%. Por otro lado, como se muestra en la Figura 4 para este proyecto se estableció un límite de aceptación del 3% en el error (RMSE) para determinar la cantidad de datos en la categoría "buena" o en otras palabras la cantidad de datos confiables. El 84% de los resultados de estimación de módulo de capa cumplen con el límite establecido con la aplicación de la metodología convencional. En el caso de la metodología ANN-FB el 88% cumple y para la metodología ANN-FS se llegó al 92% de cumplimiento y por lo tanto está ultima genera la mayor cantidad de datos confiables y utilizables para los diferentes análisis estructurales y de capacidad de soporte.

Finalmente, y continuando con el análisis de cumplimiento mencionado en el párrafo anterior, se extendió a cada tramo experimental y se incorporó un límite todavía mas conservador para estimaciones de módulo con errores por debajo del 1% dentro de la categoría "muy buena". Los resultados de este análisis se muestran en la Tabla 5 donde se refleja mas aún la ventaja que tienen los modelos ANN sobre el método de retrocálculo. De igual forma se observa como el método convencional resulta en los valores de cumplimiento mas bajos para estos límites establecidos principalmente el de 1%, y se observa como la metodología ANN-FS resulta en los valores mas altos, indicando de una forma que las estructuras estudiadas deben considerar en sus modelos de evaluación una condición de poco o cero fricción entre capas para asegurar su apropiada aplicación.

Tabla 4: Promedio de módulo estimados

Metodología	Tramo	E1, ksi	E2, ksi	E3, ksi
Retrocálculo Convencional	S9	1111	5.5	14.0
	S10	912	3.6	10.9
	S11	968	3.5	15.5
	N10	1134	4.5	19.0
	N11	1006	5.7	12.1
ANN Full Bond	S9	1095	5.7	13.3
	S10	983	3.0	11.1
	S11	1038	2.7	15.6
	N10	1153	5.6	18.8
	N11	1076	5.8	10.75
ANN Full Slip	S9	1040	12.1	13.5
	S10	844	7.4	11.3
	S11	903	6.0	16.3
	N10	1098	16.5	20.4
	N11	1005	23.0	10.7

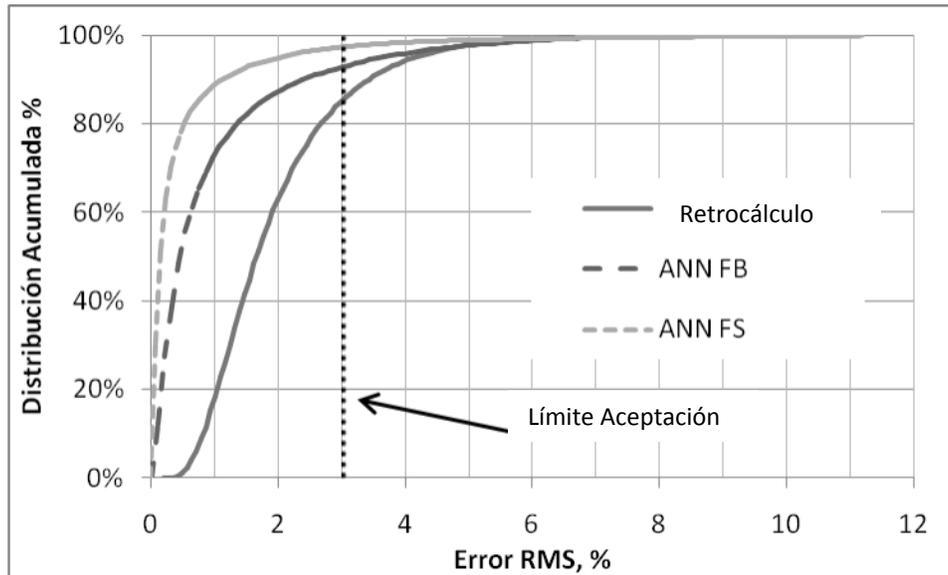


Figura 5: Análisis de errores entre metodologías

Tabla 5: Análisis de resultados a partir del RMSE

RMSE	Tramo	Porcentaje de valores dentro del criterio		
		Retrocálculo	ANN FB	ANN FS
Muy Buena 1%	S9	21.5	76.2	93.2
	S10	22.9	40.9	78.3
	S11	21.9	54.5	79.8
	N10	8.28	53.8	65.1
	N11	8.2	92.9	99.9
Buena 3%	S9	85.8	94.8	99.2
	S10	89.9	81.3	97.2
	S11	74.7	83.2	95
	N10	86.1	86.2	87.6
	N11	92.8	100	100

CONCLUSIONES

Con base en los resultados de este estudio, se llegó a las siguientes conclusiones que se enmarcan dentro de los alcances de este proyecto:

- Se verificó que una inadecuada modelación de la interface de capas puede generar diferencias significativas en los módulos estimados. Esto principalmente para bases granulares donde la tendencia observada fue a subestimar los módulos reales hasta un 74%.
- La superioridad de la aplicación de modelos de redes neuronales sobre la metodología convencional de retrocálculo de módulos fue confirmada. Esto se observó por la significativa reducción en los errores medidos con el parámetro RMSE.
- Con respecto a estudios anteriores se obtuvo una mejoría significativa en la aplicación de modelos ANN para estimar módulos de capa con la incorporación de diferentes niveles de carga y con la incorporación de condiciones deslizantes entre capas de pavimento flexibles.
- El uso de modelos ANN que incorporen condiciones deslizantes entre capas de pavimento flexibles puede mejorar la estimación de módulos de capas a valores mas cercanos a los esperados. Esto se vuelve de suma importancia para la estimación de módulos de capas granulares colocados a nivel de base.

REFERENCIAS

- Ceylan, H., Guclu, A., Tutumluer, E., and Thompson, M. R., “*Backcalculation of fulldepth asphalt pavement layer moduli considering nonlinear stress-dependent subgrade behavior*,” The International Journal of Pavement Engineering, 2005, Vol. 6, No. 3, pp. 171-182.
- Everseries User’s Guide. “*Pavement Analysis Computer Software and Case Studies*”, Washington State Department of Transportation, Olympia, Washington. 2005.
- Ferregut C., Abdallah I, Melchor O, and Nazarian S., “*Artificial Neural Network-Based Methodologies for Rational Assessment of Remaining Life of Existing Pavements*”. Center for Highway Materials Research, The University of Texas at El Paso. Texas Department of Transportation, April 1999.
- Gopalakrishnan, K., and Thompson, M.R. “*Characterization of NAPTF subgrade soils for mechanistic-based analysis and design of airport flexible pavements*.” International Journal of Pavement Engineering, 2007, 8(4), pp. 307-321.
- Lenngren C. A., Olsson J., “*Enhanced Backcalculation Techniques for Assessing Highway Structural Properties*”. International Symposium (NDT-CE 2003) Non-Destructive Testing in Civil Engineering, 2003.
- Meier, R., Alexander, D., and Freeman, R. “*Using Artificial Neural Networks as a Forward Approach to Backcalculation*.” Transportation Research Record, Washington, D.C., 1997. 1570, 126-133.
- Meier, R. W., and G. J. Rix. “*Backcalculation of Flexible Pavement Moduli Using Artificial Neural Networks*”. In Transportation Research Record 1448, TRB, National Research Council, Washington, D.C., 1995, pp. 75–82.
- Romanoschi S.A. and Metcalf J.B., “*Errors in Pavement Layer Moduli Backcalculation due to Improper Modeling of the Layer Interface Condition*”. Proceedings of the Transportation Research Board, TRB 2003 Annual Meeting CD-ROM.
- Von Quintus, H. and Killingsworth B. “*Analyses Relating to Pavement Material Characterizations and Their Effects on Pavement Performance*”. Federal Highway Administration. McLean, VA. Publication No. FHWA-RD-97-085. 1998.
- West R., Timm D., Willis R., Powell B., Tran N., Watson D., Brown R., Robbins M., Vargas-Nordebeck A., and Nelson J., “*Phase IV NCAT Pavement Test Track Findings*”. Draft Report, National Center for Asphalt Technology, Auburn University, February 2012.