







**REDES NEURONALES PROFUNDAS PARA LA EVALUACIÓN DE
SENSIBILIDAD DE VARIABLES DE DISEÑO EN LOS PARÁMETROS DE
DISEÑO ESTRUCTURAL DE PAVIMENTOS FLEXIBLES PARA VÍAS DE
BAJO TRÁNSITO**

**DEEP NEURAL NETWORKS FOR SENSITIVITY ASSESSMENT OF DESIGN
VARIABLES ON THE STRUCTURAL DESIGN PARAMETERS OF FLEXIBLE
PAVEMENTS FOR LOW-TRAFFIC VOLUME ROADS**

 MSc. (c). Brayan A. Velasquez-Bueno*,  Ing. María J. Páez Arenas*,
 PhD. Alex E. Alvarez*,  PhD. Vladimir E. Merchan*,
 PhD. Carlos A. Fajardo**,  PhD. Gustavo Chio Cho*

* **Universidad Industrial de Santander**, Facultad de Ingenierías Fisicomecánicas, Escuela de
Ingeniería Civil.

Carrera 27 calle 9, Bucaramanga, Santander, Colombia.
(60 +7) 6344000 ext. 2332.

E-mail: {brayan.velasquez, maria2175566, alex.alvarez, vmerchan, gchioch}@uis.edu.co

** **Universidad Industrial de Santander**, Facultad de Ingenierías Fisicomecánicas, Escuela de
Ingeniería Eléctrica, Electrónica, y de Telecomunicaciones.

Carrera 27 calle 9, Bucaramanga, Santander, Colombia.
(60 +7) 6344000 ext. 2485.

E-mail: cafajar@uis.edu.co

Cómo citar: Velasquez, B., Páez Arenas, M. J., Alvarez Lugo, A. E., Merchan Jaimes, V. E., Fajardo Ariza, C. A., & Chio Cho, G. (2023).
REDES NEURONALES PROFUNDAS PARA LA EVALUACIÓN DE SENSIBILIDAD DE VARIABLES DE DISEÑO EN LOS
PARÁMETROS DE DISEÑO ESTRUCTURAL DE PAVIMENTOS FLEXIBLES PARA VÍAS DE BAJO TRÁNSITO. REVISTA
COLOMBIANA DE TECNOLOGÍAS DE AVANZADA (RCTA), 2(42), 122–130. Recuperado de
<https://ojs.unipamplona.edu.co/index.php/rcta/article/view/2597>

Derechos de autor 2023 Revista Colombiana de Tecnologías de Avanzada (RCTA).
Esta obra está bajo una licencia internacional [Creative Commons Atribución-NoComercial 4.0](https://creativecommons.org/licenses/by-nc/4.0/).



Resumen: El objetivo de este estudio es implementar redes neuronales profundas (RNPs) para evaluar la sensibilidad de parámetros de diseño en pavimentos flexibles de carreteras con bajo volumen de tráfico. Ciento ocho estructuras fueron modeladas utilizando el programa Pitra Pave® (modelo de teoría elástica multicapa (TEM) para análisis estructural de pavimentos) para generar la base de datos requerida para desarrollar las RNPs. Estas redes, a través de pesos de conexión, permitieron la comparación con TEM para evaluar la sensibilidad de las variables de diseño (módulo resiliente y espesor de capa) sobre los parámetros de diseño estructural. Los resultados sugieren el impacto significativo de los espesores de capa. Adicionalmente, las predicciones de los parámetros de diseño estructural obtenidos mediante las RNPs variaron entre 0,03% y 10,87% respecto a TEM. Para futuras investigaciones, se sugiere ampliar la base de datos y desarrollar una red multi-predictiva.

Palabras clave: Red neuronal profunda, análisis de sensibilidad, teoría elástica multicapa, pavimentos flexibles.

Abstract: This study aims to implement deep neural networks (DNNs) to assess the sensitivity level of design parameters in flexible pavements for roads with low traffic volume. One hundred eight structures were modeled using the Pitra Pave® software (i.e., multilayer elastic theory (MET) model for pavement structural analysis) to generate a database to develop the DNN models. The DNN models, through connection weights, allowed the comparison with MET to evaluate the sensitivity of the selected design variables (resilient modulus and layer thickness) on the structural design parameters. The results suggest the significant impact of layer thicknesses. In addition, the predictions of structural design parameters from these initial DNN models showed variations ranging from 0,03% to 10,87% compared to MET. Expanding the database and developing a multi-predictive network is recommended for future research.

Keywords: Deep neural network, sensitivity analysis, multilayer elastic theory, flexible pavements

1. INTRODUCCIÓN

Las carreteras de tráfico bajo (LVTR) en Colombia están incluidas en la clasificación nacional como carreteras terciarias. Estas carreteras conectan centros poblados y zonas rurales (INVIAS, 2008). A partir de 2017, diferentes entidades estimaron 142.000 km de LVTR en el país. Para el mismo período, se informó que solo el 6% estaba en buenas condiciones, mientras que el 94% restante de LVTR en todo el país exhibió predominantemente condiciones regulares, pobres y malas (Ariza & Romero, 2017). Estas cifras son consecuencia, entre otros factores, de la falta de implementación de nuevas tecnologías, particularmente en las fases de construcción y mantenimiento (Caro & Caicedo, 2017). Sin embargo, el diseño estructural del pavimento es un pilar fundamental en el desarrollo de nuevas carreteras, y los avances recientes en esta área pueden beneficiar significativamente la planificación y construcción de estas carreteras.

Las teorías para el diseño estructural de pavimentos flexibles actualmente incluyen varios enfoques, desde métodos empíricos a mecanicistas (o racionales) considerando el comportamiento no lineal elastoplástico visco de los materiales (Pereira & Pais, 2017). Además, los métodos mecanicistas basados en la teoría de múltiples capas elásticas (MET) cuantifican la respuesta estructural del pavimento en términos de deformaciones y tensiones sobre el principio de que cada material exhibe un comportamiento elástico lineal.

Además, los métodos mecanicistas tradicionales para el diseño de pavimentos flexibles se basan en el control de dos parámetros de respuesta: la tensión de tracción horizontal en la parte inferior del hormigón asfáltico y la tensión de compresión

vertical en la superficie de la subrasante (Coria Gutiérrez et al., 2018), que se asocian, respectivamente, con el agrietamiento de la fatiga de abajo hacia arriba en el hormigón asfáltico y el surco de la subrasante (es decir, deformación plástica). La respuesta estructural de los pavimentos flexibles también puede evaluarse sobre la base de otro criterio de diseño ampliamente estudiado: la desviación de la superficie (Massenlli & Paiva, 2019).

Los programas computacionales han apoyado los enfoques de diseño mecanicista desde la década de 1960. Estos programas incluyen Bisar®, Kenpave®, Elsym5®, Pitra Pave®, y EVERSTRESS, entre otros. Además, a lo largo de los años, el software ha sido desarrollado para modelar estructuras de pavimento utilizando el método de elementos finitos, que permite la solución de ecuaciones constitutivas para evaluar tensiones y tensiones (Rondón Quintana & Reyes Lizcano, 2007).

Por otro lado, con la evolución de los sistemas computacionales, la inteligencia artificial se ha convertido en uno de los principales impulsores de la transformación de los enfoques de investigación en diversos campos del conocimiento. En el ámbito de la ingeniería civil, se ha informado de mejoras significativas en la precisión, la eficiencia y la rentabilidad en diferentes etapas de los proyectos. Específicamente, en ingeniería de pavimentos, se han considerado varios enfoques, que van desde el aprendizaje automático hasta el aprendizaje profundo (Gopalakrishnan, 2018); este último incluye redes neuronales que ofrecen herramientas de predicción robustas y agilizan varios procesos (Yang et al., 2021).

Este estudio busca evaluar el nivel de sensibilidad de las variables de diseño en los parámetros de diseño estructural de pavimentos flexibles para LVTR basado en una red neuronal profunda (DNN) para cada parámetro de diseño estructural. Los modelos de DNN predictor se construyeron utilizando datos generados sintéticamente a partir del Pitra Pave® software (Loría-Salazar et al., 2017), que modela estructuras de pavimento flexibles basadas en la teoría elástica multicapa (MET). Las variables evaluadas en este estudio corresponden a los parámetros primarios de diseño estructural evaluados en los métodos de diseño mecanicista (Corté & Goux, 1996)). Se trata de una tensión de tracción horizontal en la parte inferior de la capa de hormigón asfáltico (ϵ_r), tensión de compresión vertical en la superficie de la subrasante (ϵ_z), y deformación de la superficie (Δ_z). Sin embargo, además de evaluar los parámetros de diseño estructural, el modelo MET permitió calcular la desviación (deformación vertical), la deformación vertical y la deformación horizontal a diferentes profundidades. Estos datos permitieron un refinamiento adicional para el desarrollo de los modelos DNN.

Estos modelos de DNN permitieron evaluar la importancia de las variables de diseño (módulo resiliente y espesor de capa de cada capa estructural), determinadas por los pesos de conexión entre neuronas, adquiridos durante el proceso de aprendizaje. En última instancia, estos pesos de conexión se compararon con una evaluación del nivel de sensibilidad realizada utilizando datos de 108 simulaciones (16200 datos) utilizando el modelo MET (i.e., Pitra Pave® software), permitiendo la determinación de la influencia de las variables de diseño en los parámetros típicos de diseño estructural del pavimento. Los modelos DNN pueden ayudar a determinar parámetros de diseño estructural para múltiples estructuras de pavimento para LVTR en el análisis realizado a nivel de la red vial. Las opciones para estas estructuras están limitadas por los rangos establecidos para las variables de diseño evaluadas

2. METODOLOGÍA

El esquema de trabajo aplicado en esta investigación se describe en la Fig. 1. Surgió principalmente de la selección de 108 estructuras de pavimento flexible, como resultado de una parametrización del módulo resiliente (RM) y el espesor de la capa (LT) para cada una de las capas estructurales que comprende una estructura típica de pavimento flexible. A continuación, se llevó a cabo una etapa de modelado

utilizando el Pitra Pave® software, que proporcionó los datos necesarios para evaluar el nivel de sensibilidad y desarrollar los modelos de DNN. Posteriormente, se realizaron validaciones comparando directamente las salidas obtenidas de los modelos DNN y MET. Posteriormente, se realizó una evaluación de las diferencias observadas en las diversas estructuras de pavimento para cada parámetro de diseño estructural para determinar la importancia de las variables de diseño. Finalmente, los modelos DNN dieron las ponderaciones de conexión por variable de diseño necesarias para comparar el nivel de importancia de cada una de estas variables parametrizadas.

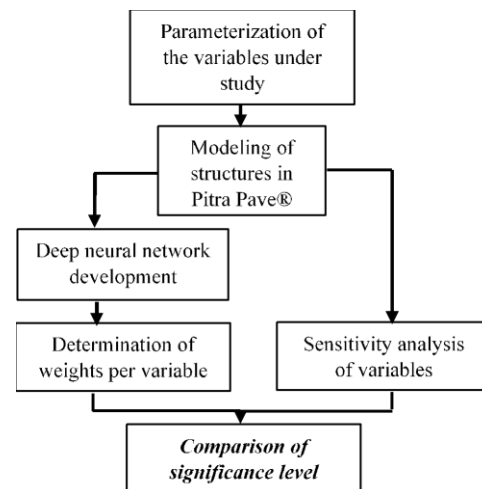


Fig. 1. Metodología aplicada para la realización del estudio.

2.1. Parámetros de diseño

La estructura típica de pavimento flexible adoptada se muestra en la Fig. 2, incluyendo la subcapa (SG) y tres capas estructurales: hormigón asfáltico (AC), base granular (GB) y subbase granular (GSB). Los parámetros de diseño que diferenciaban cada estructura de pavimento eran el espesor de AC (LT_{AC}), el espesor de GB (LT_{GB}), el espesor de GSB (LT_{GSB}), el módulo resiliente (stiffness) de AC (RM_{AC}), el módulo resiliente de GB (RM_{GB}), y el módulo resiliente de GSB (RM_{GSB}). Al variar los espesores, fue posible establecer cuatro configuraciones geométricas (C1, C2, C3, C4; Tabla 1), mientras que para los módulos se adoptaron los valores indicados en la tabla 1. Estos valores generaron diferentes combinaciones, definiendo las 108 estructuras simuladas. Además de esto, el coeficiente de Poisson (ν) y módulo elástico de la subrasante (RM_{SG}), carga (P), presión de contacto entre el neumático y el pavimento (σ), radio del área

de carga (r), y la distancia entre neumáticos (y) se mantuvo constante. La tabla 2 presenta los valores adoptados para estos parámetros.




Fig. 2. Modelo estructural de referencia.

Tabla 1. Rango de variación en módulo elástico y espesor de capa.

Layer r	Resilient modulus [MPa]	Layer thickness [m]			
		C1	C2	C3	C4
AC	3500 - 2500 - 1500	0,1 0	0,0 7	0,0 5	0,03
GB	250 - 200 - 150	0,2 5	0,2 0	0,1 5	0,10
SGB	200 - 150 - 100	0,2 5	0,2 0	0,1 5	0,10
SG	80	-	-	-	-

Nota: El Pitra Pave® software asume el espesor de la capa de la sub-capa (LT_{SG}) infinito.

Tabla 2. Constantes adoptadas en los modelos estructurales de pavimento.

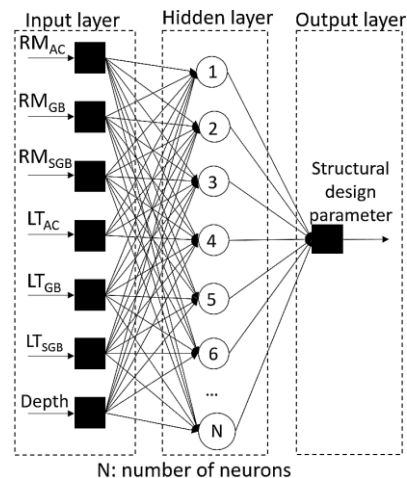
Parameter	Value
ν_{AC}	0,30
$\nu_{GB}, \nu_{SGB},$ and ν_{SG}	0,35
RM_{SG} [MPa]	80,00
r [m]	0,108
y [m]	0,324
P [kN]	20,50
σ [kPa]	562,00

2.2. Modelos de red neuronal profunda (DNN)

Modelando estructuras de pavimento utilizando el Pitra Pave® software, fue posible evaluar los parámetros de diseño estructural en la posición correspondiente al punto medio bajo la impresión del neumático. Este esfuerzo resultó en un conjunto de datos de 16200 entradas, que fue la base para la construcción de un modelo DNN predictor inicial para cada parámetro de diseño estructural de pavimento.

Las arquitecturas de cada DNN propuesto se desarrollaron utilizando un subconjunto de la base de datos obtenida a partir del modelado de estructuras de pavimento con Pitra Pave®. La base de datos sintética se dividió aleatoriamente en tres subconjuntos necesarios para desarrollar cada DNN (tabla 3). La arquitectura de cada modelo DNN fue entrenada utilizando la estimación del momento adaptativo-Adam-optimizador (Kingma & Ba, 2014) con parámetros predeterminados, excepto la tasa de aprendizaje, que fue variada y disminuida por un factor de 0,8 cuando el rendimiento se estabilizó. La técnica de regularización de parada temprana se implementó para evitar el sobreajuste mediante el monitoreo de la pérdida en la prueba de validación, y se utilizó un enfoque estratificado de 5 veces para evaluar el rendimiento del modelo y la capacidad de generalización.

Para el ajuste de hiperparámetros, este estudio exploró varias combinaciones del número de capas ocultas, el número de neuronas y las funciones de activación. Las arquitecturas seleccionadas lograron el máximo rendimiento en el conjunto de pruebas. Las métricas utilizadas para evaluar los modelos de DNN fueron el coeficiente de determinación (R^2) y la raíz significativa error cuadrado (RMSE). Fig. 3 presenta el esquema general de las arquitecturas DNN utilizadas, y la Tabla 4 resume el número de neuronas seleccionadas en las arquitecturas de cada modelo DNN. Todas las capas ocultas en los tres modelos DNN utilizaron las unidades lineales rectificadas —ReLU— función de activación.



Arquitectura de referencia de modelos DNN.

Tabla 3. Proporciones de los subconjuntos de datos utilizados para cada modelo de DNN.

	Training	Test	Validation
Δ_z DNN	70	30	20

ϵ_r DNN	70	30	20
ϵ_z DNN	85	15	10

Tabla 4. Número de neuronas implementadas para cada modelo de DNN.

	Hidden layer 1	Hidden layer 2
Δ_z DNN	180	—
ϵ_r DNN	100	120
ϵ_z DNN	60	180

3. RESULTADOS Y DISCUSIÓN

Los resultados del estudio incluyeron el análisis de precisión y validación empírica de los modelos DNN, variación de los parámetros de diseño estructural debido al cambio en las variables de diseño, el nivel de sensibilidad de las variables de diseño a los parámetros de diseño estructural, y nivel de significación de las variables de diseño determinadas a partir de los modelos DNN.

3.1. Exactitud y validación empírica de los modelos DNN

En la tabla 5 se presentan los valores obtenidos R^2 y RMSE métricas, en comparación con los resultados encontrados en la literatura. Estas métricas demostraron la precisión alcanzada en los datos de la prueba, es decir, no utilizados en la fase de entrenamiento. En general, estos valores apoyan el correcto desempeño de los modelos de DNN propuestos en la estimación y generalización de los parámetros de diseño estructural. Diferencias en comparación con el Pitra Pave® (MET) Posteriormente se examinan los resultados.

Tabla 5. Indicadores de rendimiento de los modelos DNN.

	Model	R^2	RSME
Δ_z DNN	Proposed	0,998± 0,002	0,0029± 0,006
	Karballaezadeh et al., 2020	0,841	0,76
ϵ_r DNN	Proposed	0,996 ± 0,027	1,09E-5 ± 0,016
	(Plati et al., 2016)	0,96 ± 0,003	0,043 ± 0,0001
ϵ_z DNN	Proposed	0,988± 0,006	4,24E-5 ±0,0066
	(Ghanizadeh & Ahadi, 2015)	0,99	

Además, se realizó una comparación directa entre las predicciones del modelo DNN y los resultados del Pitra Pave® software para las tres estructuras de parámetros de diseño evaluados. La Fig. 4 muestra

los resultados de estos criterios, indicando que las predicciones de los modelos DNN siguieron las tendencias del modelo MET. Los resultados de la predicción para Δz (Fig. 4A) de ambos modelos exhibieron diferencias menores de 5%.

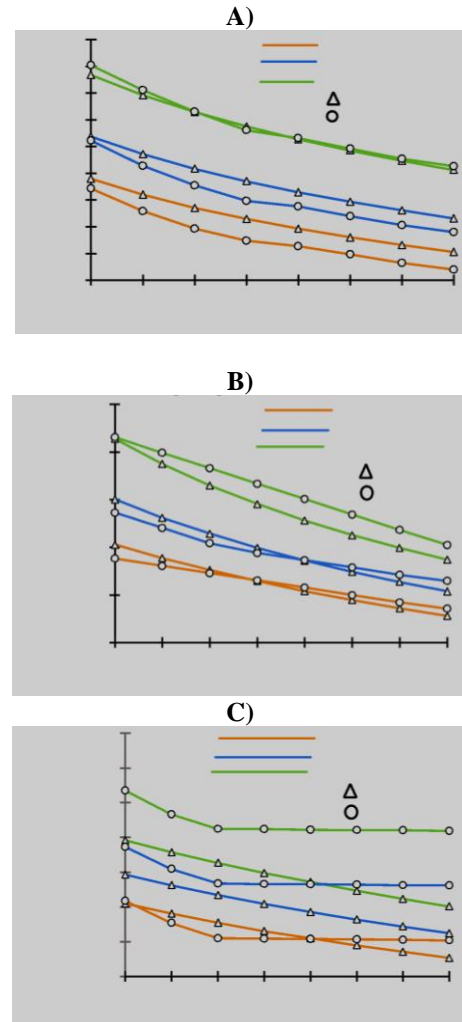


Fig. 4 . Influencia del módulo elástico de hormigón asfáltico y base granular en los parámetros de diseño estructural: A) deformación superficial, B) deformación horizontal en la parte inferior del hormigón asfáltico y C) deformación vertical en la parte superior de la subrasante.

Los resultados correspondientes para la estimación de ϵ_r (Fig. 4B) mostraron diferencias máximas que oscilaban entre 0,04 y 5,07%, un resultado prometedor para este modelo inicial de DNN, lo que sugiere el potencial de un mayor refinamiento para minimizar las discrepancias reportadas. Fig. 4C presenta los valores predichos de DNN para ϵ_z , mostrando una diferencia porcentual que oscila entre 0,66% y 5,50%. Estas discrepancias indicaron

que el modelo DNN también proporcionó una predicción inicial prometedora para este parámetro de diseño.

3.2. Variación de los parámetros de diseño estructural debido al cambio en las variables de diseño

La evaluación del nivel de sensibilidad para cada parámetro de diseño estructural requirió definir un modelo estructural de pavimento de referencia, a partir del cual se calcularon las diferencias generadas por la variación de RM y LT . El modelo estructural de pavimento de referencia seleccionado se muestra en la Fig. 2, y se caracteriza por $RM_{AC}=3250$ MPa, $RM_{GB}=250$ MPa, $RM_{SGB}=200$ MPa, and $RM_{SG}=80$ MPa, junto con espesores de capa definidos para geometría C1 ($LT_{CA}=0,10$ m; $LT_{GB}=0,25$ m; $LT_{SGB}=0,25$ m).

Así pues, se llevó a cabo una evaluación inicial del nivel de sensibilidad, teniendo en cuenta la RM_{GB} (que oscilan entre 150 MPa a 250 MPa) y RM_{AC} (que oscilan entre 1500 MPa a 3250 MPa). Los resultados de ε_r y ε_z se determinaron en el punto central de la impresión de carga circular y se registran en la tabla 6.

Tabla 6. Resultados de los parámetros de diseño estructural asociados con la RM_{GB} y RM_{CA} .

RM_{AC} [MPa]	RM_{GB} [MPa]	ε_r	ε_z
3250*	250*	2,28E-04	1,85E-04
	200	2,54E-04	1,92E-04
	150	2,87E-04	2,00E-04
2500	250*	2,54E-04	1,91E-04
	200	2,86E-04	1,99E-04
	150	3,28E-04	2,07E-04
1500	250*	3,03E-04	2,01E-04
	200	3,50E-04	2,09E-04
	150	4,14E-04	2,19E-04

* Valores modelo de referencia.

Fig. 5 muestra los valores de Δz a función de RM_{AC} . La figura presenta tres posibles resultados mecánicos, cada uno definido por una variación en RM_{GB} para diferentes estructuras de pavimento. Generalmente, y como se espera a nivel teórico, se observa una tendencia inversamente proporcional entre la rigidez de la capa y la desviación de la superficie.




Fig. 5. Desviación de superficie en función de RM_{AC} y diferentes valores de RM_{GB} .

La tabla 7 presenta las diferencias porcentuales para cada criterio de diseño evaluado después de modificar los valores de RM_{GB} y RM_{AC} . Del mismo modo, la tabla 8 incluye las diferencias encontradas al variar los valores de RM_{SGB} y RM_{AC} . La cuantificación de estas diferencias se basó en la comparación con la estructura de pavimento de referencia. Las diferencias comunicadas en los cuadros 7 y 8 reflejan la proporcionalidad inversa en los parámetros de diseño estructural con las variaciones aplicadas a RM_{BG} y RM_{SGB} .

Tabla 7. Variación de los parámetros de diseño estructural tras el cambio de RM_{GB} y RM_{AC} .

RM_{AC} [MPa]	RM_{GB} [MPa]	Δz [%]	ε_r [%]	ε_z [%]
3250*	250*	0,00	0,00	0,00
	200	5,94	11,40	3,78
	150	14,49	25,88	8,11
2500	250*	0,00	0,00	0,00
	200	6,39	12,60	4,19
	150	15,30	29,13	8,38
1500	250*	0,00	0,00	0,00
	200	6,51	15,51	3,98
	150	16,39	36,63	8,96

* Valores modelo de referencia.

Tabla 8. Variación de los parámetros de diseño estructural tras el cambio de RM_{SGB} y RM_{AC} .

RM_{AC} [MPa]	RM_{SG} [MPa]	Δz [%]	ε_r [%]	ε_z [%]
3250*	200*	0,00	0,00	0,00
	150	4,30	1,75	15,68
	100	11,05	4,39	42,16
200*	200*	0,00	0,00	0,00

2500	150	4,27	1,57	15,1 8
	100	11,02	3,94	42,4 1
<hr/>				
1500	200*	0,00	0,00	0,00
	150	4,20	1,00	15,9 0
	100	10,80	2,60	43,3 0

* Valores modelo de referencia.

La tabla 9 presenta las diferencias porcentuales en los parámetros de diseño -calculadas a partir de la comparación con las respuestas de la estructura de pavimento de referencia- generadas al modificar la LT_{total} y RM_{AC} . Estos valores reflejan una alta influencia de la variación en los espesores de capa correspondientes a las configuraciones geométricas presentadas en la tabla 1. Se observa una tendencia inversamente proporcional para los parámetros de diseño estructural Δz y ϵ_r .

Tabla 9. Variación de los parámetros de diseño estructural con cambios en LT_{total} y RM_{AC} .

RM_{AC} [MPa]	LT_{total} [m]	Δz [%]	ϵ_r [%]	ϵ_z [%]
3250*	0,60*	0,00	0,00	0,00
	0,47	20,98	22,3 7	50,81
	0,35	45,52	32,8 9	132,9 7
	0,23	83,68	7,46	320,5 4
2500	0,60*	0,00	0,00	0,00
	0,47	20,07	18,9 0	49,21
	0,35	43,50	23,6 2	130,3 7
	0,23	79,27	12,2 0	314,1 4
1500	0,60*	0,00	0,00	0,00
	0,47	18,14	10,8 9	47,76
	0,35	39,14	3,96	126,8 7
	0,23	70,23	44,5 5	305,9 7

* Valores modelo de referencia.

Sin embargo, no hubo una tendencia constante en ϵ_r para las configuraciones geométricas evaluadas. Los valores de este parámetro de diseño calculados para $LT_{total}=0,60$ m, $LT_{total}=0,47$ m, y $LT_{total}=0,35$ m mostró una tendencia decreciente con el aumento RM_{AC} y LT_{total} . Sin embargo, se puso de manifiesto una tendencia al alza para la $LT_{total}=0,23$ m. Esta respuesta fue porque cuando el espesor de la AC capa estaba en el orden de 3 cm y su módulo resistente disminuyó, las tensiones tienden a

aumentar debido a la falta de capacidad de distribución de carga.

3.3. Nivel de sensibilidad de las variables de diseño a los parámetros de diseño estructural

Al evaluar el nivel de sensibilidad de las variables de diseño en los parámetros de diseño estructural analizados en las estructuras de pavimento flexible, se podría evaluar su nivel de sensibilidad, clasificados y organizados de mayor a menor influencia en relación con las diferencias porcentuales calculadas. Se organizaron las variaciones máximas obtenidas para cada parámetro de diseño estructural, mostrando el nivel de impacto relativo a cada variable de diseño estudiada. La tabla 10 presenta las variaciones máximas de las variables de diseño analizadas en términos de los parámetros de diseño estructural (Δz , ϵ_r , y ϵ_z).

Tabla 10. Variaciones máximas de las variables de diseño para cada parámetro de diseño estructural.

Variable	Δz [%]	ϵ_r [%]	ϵ_z [%]
LT_{total}	83,68	44,55	320,54
RM_{GB}	16,39	36,72	9,05
RM_{AC}	13,06	32,70	8,45
RM_{SGB}	11,05	4,39	43,28

Sandoval-Higuera (2006) presentó una escala de variaciones porcentuales para clasificar los resultados obtenidos y enumerados anteriormente. Esta escala de sensibilidad se muestra en la tabla 11. En la tabla 12 se presenta el grado de sensibilidad de las variables de diseño evaluadas. Según estos resultados, la evaluación de sensibilidad para los tres parámetros de diseño estructural sugiere que la variable más influyente fue LT_{total} .

Tabla 11. Escala de definición del nivel de sensibilidad.

Sensitivity level	Variation [%]
Low	<15
Medium	15-30
High	>30

Tabla 12. Nivel de sensibilidad de las variables de diseño en los parámetros de diseño estructural.

Variable	Δz	ϵ_r	ϵ_z
LT_{total}	High	High	High
RM_{AC}	Low	High	Low
RM_{GB}	Medium	High	Low
RM_{SGB}	Low	Low	High

3.4. Nivel de significación de las variables de diseño determinadas a partir de los modelos DNN

El nivel de significación de las variables de diseño calculadas utilizando los modelos DNN se evaluó en términos de los pesos de conexión. Estos pesos fueron parámetros que la DNN ajustó en el proceso de entrenamiento, determinando la contribución de cada neurona asociada a cada variable de entrada. La determinación y cálculo de estos pesos siguió el enfoque propuesto por Ghanizadeh et al., 2020. El análisis para cada parámetro de diseño estructural implicó determinar los pesos de conexión para cada capa oculta y asociar la suma de estos pesos con cada variable de entrada (variable de diseño).

La tabla 13 presenta los pesos de conexión entre neuronas para las diferentes variables de diseño relativas a los parámetros de diseño estructural evaluados. Vale la pena señalar que para el entrenamiento de los modelos DNN, cada uno de los espesores de capa inicialmente caracterizados en cada capa estructural se trató de forma independiente. Este enfoque permitió medir la influencia a través de los pesos de conexión para cada espesor de capa, mientras que para el análisis realizado por el modelo MET, el espesor total de la capa (LT_{total}) conceptualizado en cada configuración geométrica definida inicialmente se consideró.

Tabla 13. Pesos de conexión de las variables de diseño determinadas a partir de los modelos DNN.

<i>Variable</i>	<i>Δz_{DNN}</i>	<i>ϵ_r_{DNN}</i>	<i>ϵ_z_{DNN}</i>
LT_{AC}	13,78	8,24	6,09
LT_{GB}	8,29	9,07	6,39
LT_{SGB}	9,24	8,47	7,72
RM_{AC}	11,53	6,44	7,27
RM_{GB}	12,78	7,85	6,07
RM_{SGB}	12,70	8,54	4,56

Los resultados de ambos modelos (DNN y MET) mostraron algunas variaciones en el nivel de sensibilidad de las variables de diseño para cada parámetro de diseño estructural. Sin embargo, en ambos casos, se encontró que los espesores de capa fueron las variables más significativas.

4. CONCLUSIONES

El desarrollo de este estudio permitió la creación de modelos DNN, en evolución, para predecir los parámetros típicos de diseño estructural de pavimentos flexibles diseñados para LVTR. Estos modelos de DNN permitieron evaluar el nivel de sensibilidad de los parámetros de diseño estructural

con respecto a los cambios en las variables de diseño (es decir, rigidez y espesores de capa).

Los modelos de Aprendizaje Profundo desarrollados lograron métricas satisfactorias de R^2 y RSME, sugiriendo su capacidad de predicción y generalización con respecto a los parámetros de diseño estructural (es decir, la desviación de la superficie, la tensión de tracción horizontal en la parte inferior de la CA, y la tensión vertical debido a la compresión en la superficie de la SG).

Las estimaciones numéricas calculadas por los modelos MET y DNN permitieron determinar el nivel de sensibilidad de cada variable de diseño en los pavimentos flexibles evaluados para LVTR. El resultado fue consistente, comparando los resultados del modelo MET y los pesos de conexión de los modelos DNN; es decir, los espesores de capa ejercen la mayor influencia en cada parámetro de diseño estructural evaluado para las estructuras de pavimento caracterizadas. Sin embargo, los modelos DNN fueron capaces de determinar un desglose más detallado de este nivel de sensibilidad en términos de espesor para cada capa estructural.

Para el trabajo futuro, se sugiere explorar un número más significativo de simulaciones para permitir una generalización más sólida de los modelos de DNN y así mejorar las métricas. Además, es esencial evaluar otros puntos de análisis además del punto medio bajo la impresión del neumático (por ejemplo, el punto medio entre las impresiones circulares del neumático), que también puede conducir a valores críticos de los parámetros de diseño estructural. Por último, la validación de la predicción de los modelos DNN para las deformaciones y desviaciones verticales y horizontales en toda la profundidad de las estructuras del pavimento es de interés para mejorar la generalización óptima para cada variable en el desarrollo de un modelo DNN multipredicador.

AGRADECIMIENTOS

Los autores desean agradecer el apoyo financiero brindado por la Vicerrectoría de Investigación y Extensión (Proyecto VIE 3717, "Caracterización de materiales granulares marginales para pavimentos considerando cambios hidromecánicos relacionados con ciclos de humectación y secado") y la Escuela de Ingeniería Civil de la Universidad Industrial de Santander, que hizo posible esta investigación.

REFERENCIAS

- Instituto Nacional de Vías (2008). Manual de diseño geométrico de carreteras.
- Alejandra, M., Ariza, A., Alejandro, P., & Romero, A. (2017). Las vías terciarias en Colombia, una oportunidad para la ingeniería vial y el desarrollo del país. *Universidad Catolica*.
- Caro, S., & Caicedo, B. (2017). TECNOLOGÍAS PARA VÍAS TERCIARIAS: PERSPECTIVAS Y EXPERIENCIAS DESDE LA ACADEMIA. *Revista de Ingeniería*, 45. <https://doi.org/10.16924/revinge.45.3>
- Coria Gutiérrez, C. A., Hernández Domínguez, R. I. ;, & Garnica Anguas, P. (2018). Teorías para calcular esfuerzos, deformaciones y deflexiones en pavimentos flexibles: un enfoque mecanicista. In *IMT Instituto Mexicano del Transporte* (Issue 72).
- Corté, J. F., & Goux, M. T. (1996). Design of pavement structures: The French technical guide. *Transportation Research Record*, 1539. <https://doi.org/10.3141/1539-16>
- Ghanizadeh, A. R., & Ahadi, M. R. (2015). Application of artificial neural networks for analysis of flexible pavements under static loading of standard axle. *International Journal of Transportation Engineering*, 3(1).
- Ghanizadeh, A. R., Heidarabadizadeh, N., & Jalali, F. (2020). Artificial neural network back-calculation of flexible pavements with sensitivity analysis using Garson's and connection weights algorithms. *Innovative Infrastructure Solutions*, 5(2). <https://doi.org/10.1007/s41062-020-00312-z>
- Gopalakrishnan, K. (2018). Deep learning in data-driven pavement image analysis and automated distress detection: A review. In *Data* (Vol. 3, Issue 3).
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *ArXiv Preprint ArXiv:1412.6980*.
- Loría-Salazar, L. G., Aguiar-Moya, J. P., Trejos-Castillo, C., & Rojas-Pérez, F. (2017). *Solución a la teoría de multicapa elástica y software de cálculo de las respuestas del pavimento PITRA PAVE*.
- Massenlli, G. S. R., & Paiva, C. E. L. de. (2019). Influencia de la deflexión superficial en pavimentos flexibles con subrasante de baja resistencia. *Ingeniare. Revista Chilena de Ingeniería*, 27(4).
- Pereira, P., & Pais, J. (2017). Main flexible pavement and mix design methods in Europe and challenges for the development of an European method. In *Journal of Traffic and Transportation Engineering (English Edition)* (Vol. 4, Issue 4). <https://doi.org/10.1016/j.jtte.2017.06.001>
- Plati, C., Georgiou, P., & Papavasiliou, V. (2016). Simulating pavement structural condition using artificial neural networks. *Structure and Infrastructure Engineering*, 12(9). <https://doi.org/10.1080/15732479.2015.1086384>
- Rondón Quintana, H. A., & Reyes Lizcano, F. A. (2007). Metodologías de diseño de pavimentos flexibles: Tendencias, alcances y limitaciones. *Ciencia e Ingeniería Neogranadina*, 17(2). <https://doi.org/10.18359/rcin.1074>
- Sandoval, Higuera;Hernando, C. (2006). Análisis de sensibilidad de las variables de diseño de un pavimento rígido y su incidencia en la deflexión. *Facultad de Ingeniería*, 15(20).
- Yang, X., Guan, J., Ding, L., You, Z., Lee, V. C. S., Mohd Hasan, M. R., & Cheng, X. (2021). Research and applications of artificial neural network in pavement engineering: A state-of-the-art review. In *Journal of Traffic and Transportation Engineering (English Edition)* (Vol. 8, Issue 6).