

Redes neuronales y Kriging para la optimización de la huella de carbono de puentes losa pretensados

Neural networks and Kriging for the optimization of the carbon footprint of prestressed slab bridges

Lorena Yepes-Bellver^a, Ignacio J. Navarro^b, Julián Alcalá^c y Víctor Yepes^{*,d}

^a Ingeniera de Caminos, Canales y Puertos. Dpto. Mecánica de los Medios Continuos y Teoría de Estructuras, Universitat Politècnica de València. Profesora Asociada. loyebel@alumni.upv.es

^b Dr. Ingeniero de Caminos, Canales y Puertos. ICITECH, Universitat Politècnica de València. Profesor Asociado. Ignamar1@upvnet.upv.es

^c Dr. Ingeniero de Caminos, Canales y Puertos. ICITECH, Universitat Politècnica de València. Profesor Titular de Universidad. jualgon@cst.upv.es

^d Dr. Ingeniero de Caminos, Canales y Puertos. ICITECH, Universitat Politècnica de València. Catedrático de Universidad. vyepesp@cst.upv.es

* Persona de contacto / Corresponding author

RESUMEN

El artículo compara el rendimiento de los modelos Kriging y de redes neuronales para optimizar las emisiones de CO₂ en puentes de losa pretensada. Las redes neuronales presentan un menor error medio, pero ambos modelos destacan por conducir hacia áreas prometedoras en el espacio de soluciones. Las recomendaciones incluyen maximizar la esbeltez y reducir el uso de hormigón y armaduras, compensando con un incremento controlado de estas. Aunque los modelos proporcionan superficies de respuesta precisas, es esencial realizar una optimización heurística para obtener mínimos locales más exactos, lo que contribuye a diseños más sostenibles y eficientes.

ABSTRACT

The paper compares the performance of kriging and neural network models for optimizing CO₂ emissions in prestressed slab bridges. Neural networks have a lower mean error, but both models stand out, leading to promising areas in the solution space. Recommendations include maximizing slenderness and reducing the use of concrete and reinforcement, compensated by a controlled increase in reinforcement. Although the models provide accurate response surfaces, it is essential to perform heuristic optimization to obtain more accurate local minima, contributing to more sustainable and efficient designs.

PALABRAS CLAVE: sostenibilidad, redes neuronales, Kriging, huella de carbono, puentes postesados.

KEYWORDS: sustainability, neural networks, Kriging, carbon footprint, post-tensioned bridges.

1. Introducción

La reducción de las emisiones de gases de efecto invernadero es clave en la situación actual del cambio climático, que afecta a todas las

actividades humanas [1]. La construcción consume el 50 % de los recursos extraídos a nivel mundial en forma de materiales y el 15 % del

agua dulce utilizada, y es responsable del 37 % de las emisiones globales de CO₂ relacionadas con la energía [2]. La producción mundial de hormigón estructural representa más del 5 % de las emisiones de carbono [3]. Esto ha impulsado el interés por optimizar la sostenibilidad ambiental en este sector [4].

La selección adecuada de materiales o la optimización de su diseño pueden reducir las emisiones. Nuestro grupo de investigación ha optimizado las emisiones de CO₂ de puentes. Se mejoró un puente de vigas artesa prefabricadas utilizando un algoritmo híbrido basado en luciérnagas, logrando que una reducción de 1 € permitiera ahorrar hasta 1.75 kg de CO₂ [5]. Por otro lado, una pasarela postesada con sección en cajón redujo sus emisiones aumentando los cantos, el uso de más cables de armadura activa y disminuyendo la resistencia característica del hormigón [6]. Otro estudio implementó una optimización multiobjetivo que tuvo en cuenta el coste, las emisiones y la seguridad en un puente postesado de sección en cajón. En comparación, las emisiones generadas durante la demolición de puentes en cajón fueron mayores que las de las fases de mantenimiento y reparación [8]. Además, se destacó que las emisiones de carbono, aunque importantes, no siempre son suficientes para evaluar el impacto ambiental, por lo que también deben analizarse otros efectos [9]. En el diseño de una pasarela mixta de hormigón y acero, se utilizaron metaheurísticas para equilibrar el coste y las emisiones [10]. Pese a estos avances, la investigación sobre la optimización de la huella de carbono en puentes de losa de hormigón sigue siendo limitada, por lo que se destaca la necesidad de ampliar estudios en este ámbito.

La optimización heurística de estructuras es computacionalmente costosa, por lo que se emplean metamodelos como el Kriging. Este método sustituye al modelo de simulación, ofreciendo una interpolación óptima mediante regresión basada en valores observados [11]. El Kriging tiene ejemplos interesantes de

aplicación, aunque su uso en diseño de estructuras reales aún es limitado. Martínez-Frutos y Martí [12] lo emplearon para optimizar el diseño robusto de estructuras y desacoplar eficazmente la evaluación de la incertidumbre del proceso de optimización. Más recientemente, se ha utilizado en la optimización de la dinámica estructural [13], en el diseño de tipologías de edificios residenciales [14] y en puentes postensados [15, 16].

Las redes neuronales artificiales (RNA) son metamodelos inspirados en el cerebro humano, formados por nodos (neuronas) y conexiones. Por su flexibilidad y facilidad de uso, se aplican en problemas como reconocimiento de patrones y aproximación de funciones. Las RNA aprenden de ejemplos de entrenamiento, aproximan funciones no lineales y han sido utilizadas para predecir el comportamiento estructural y para apoyar la optimización multiobjetivo de puentes [17].

Este trabajo avanza sobre estudios previos al combinar metamodelos con redes neuronales y al centrarse específicamente en puentes de losa pretensada, una tipología poco explorada en la optimización de emisiones de CO₂.

2. Descripción del tablero aligerado

El estudio busca optimizar el diseño de una losa pretensada y aligerada con vanos de 24-34-28 m, típica en pasos superiores sobre autopistas de doble carril. Las conclusiones son aplicables a la construcción de puentes en el nuevo mundo. La losa, rectilínea y de canto constante, mide 8.30 m de ancho con dos carriles de 3.50 m cada uno, pretilos de 0.65 m a cada lado y una base de hormigón (Figuras 1 y 2).




Figura 1. Alzado del puente losa.




Figura 2. Sección transversal del puente losa.

Este paso superior se encuentra en el kilómetro 441 de la autovía A-7, en Cocentaina (Alicante). El puente tiene un canto de 1.35 m, una base inferior de 4.00 m y un voladizo de 1.75 m, con dimensiones: $a = 0.20$ m, $b = 0.10$ m y $d = 0.40$ m. Los aligeramientos son cuatro secciones circulares de 0.60 m de diámetro, resultando en un aligeramiento interior de $0.14 \text{ m}^3/\text{m}^2$ y exterior de $0.51 \text{ m}^3/\text{m}^2$.

La teoría de los estados límite verifica la resistencia estructural mediante coeficientes parciales de seguridad. Cada situación de diseño garantiza que no se superen los estados límites últimos y de servicio. En este estudio se utilizó el programa CSiBridge v.21.0.0 para modelar el tablero, analizando y dimensionando diversas alternativas para determinar las cargas actuantes y resistentes. Estos cálculos se detallan en los trabajos de Yepes-Bellver et al. [15,16].

3. Metodología

La construcción de cada tablero genera emisiones de CO_2 . Son factores clave el tipo de hormigón, la superficie de encofrado, la cuantía de acero y el volumen de aligeramientos. Las emisiones se valoraron según la Tabla 1 [15].

Los materiales incluyen el acero Y-1860-S7, conocido por su alta resistencia y durabilidad en refuerzos estructurales, y el acero B-500-S, que ofrece buena ductilidad y resistencia a la tracción para el refuerzo del hormigón. Los hormigones van desde el HP-30, de resistencia media, hasta el HP-50, de resistencia ultra alta. Además, el aligeramiento reduce el peso, mejorando la eficiencia y la rentabilidad,

mientras que el encofrado de las losas soporta y da forma al hormigón, impactando en la calidad de la superficie y la velocidad de construcción.

Tabla 1. Emisiones de CO_2 .

Material	Ud.	CO_2 (kg)
Hormigón HP-30	m^3	227.01
Hormigón HP-35	m^3	263.96
Hormigón HP-40	m^3	298.57
Hormigón HP-45	m^3	330.25
Hormigón HP-50	m^3	358.97
Acero (B 500S)	kg	3.03
Acero Y1860-S7	kg	5.64
Encofrado	m^2	2.24
Aligeramiento	m^3	604.42

Este trabajo utiliza dos tipos de modelos predictivos: Kriging y redes neuronales. La elección de estas técnicas se basa en su capacidad comprobada para manejar problemas de optimización con superficies de respuesta complejas y no lineales, como las que presenta este caso. Estos modelos se aplican a los 37 datos utilizados previamente para optimizar un puente losa [15] (Tabla 2).

La fase de diversificación usa los primeros 30 datos para optimizar la superficie de respuesta de Kriging, mientras que la fase de intensificación utiliza los 5 datos siguientes. Los tableros 36 y 37 muestran los óptimos locales de ambas fases, respectivamente.

Una vez ajustada la superficie de respuesta, el error de puede medirse con el error cuadrático medio (RMSE), expresado en las mismas unidades que los valores de salida del modelo.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (1)$$

Donde $\hat{y}_i$ son los valores estimados, y_i son los valores observados y n es el número de observaciones.

Tabla 2. Coste económico y emisiones.

Tabl.	Canto (m)	Base (m)	f_{ck} (MPa)	CO ₂ (kg)
1	1.45	4.35	35	439416.04
2	1.55	4.10	35	460392.78
3	1.45	4.75	35	455722.34
4	1.70	3.80	45	484897.39
5	1.20	3.85	40	407988.18
6	1.55	3.60	45	456668.42
7	1.20	4.85	50	472401.00
8	1.15	4.50	50	471362.45
9	1.35	3.95	30	406654.38
10	1.30	4.45	30	436703.35
11	1.35	4.25	45	455373.86
12	1.50	4.55	30	434673.91
13	1.60	4.20	40	503797.39
14	1.25	4.70	40	462914.73
15	1.50	4.05	45	482659.32
16	1.30	4.90	40	477491.15
17	1.65	3.65	35	444713.58
18	1.65	3.45	45	464050.70
19	1.25	3.50	45	420513.71
20	1.40	3.30	40	443839.50
21	1.45	3.90	45	464535.64
22	1.35	3.60	35	416583.96
23	1.50	3.35	45	455442.46
24	1.50	4.50	45	490669.44
25	1.55	3.20	30	403971.90
26	1.25	3.00	50	423111.90
27	1.40	3.45	45	470007.91
28	1.50	3.55	35	418839.00
29	1.70	3.85	40	468897.98
30	1.15	3.70	40	394616.39
31	1.15	3.40	35	411077.14
32	1.25	3.35	35	398614.42
33	1.15	3.65	45	422934.14
34	1.15	3.35	40	395465.24
35	1.15	3.25	40	397153.86
36	1.15	3.55	40	391370.00
37	1.10	3.40	35	386514.57

3.1 Metamodelo Kriging

La metodología consiste en una optimización en dos fases de la superficie de respuesta generada por Kriging [15]. El muestreo de hipercubo latino (LHS) selecciona números aleatorios distribuidos uniformemente para analizar cada alternativa.

Kriging estima el valor de un atributo en un punto n a partir de un conjunto de n valores de z (Figura 3). Este enfoque predice las emisiones de CO₂ utilizando «MATLAB Kriging Toolbox» (DACE) para construir el metamodelo [18]. Las predicciones son deterministas y producen respuestas coherentes para las mismas entradas. Los modelos pueden construirse con regresiones polinómicas de orden 0, 1 y 2, denominados Kriging 1, Kriging 2 y Kriging 3.




Figura 3. Superficie de respuesta (Tabla 2).

El muestreo LHS selecciona números aleatorios distribuidos uniformemente, con menor varianza que la media muestral en comparación con una muestra aleatoria simple [19]. Consiste en seleccionar una muestra al azar de cada intervalo de cada variable y ejecutar el modelo tantas veces como intervalos haya en la distribución de probabilidad. LHS mejora la comprensión del espacio de diseño, minimiza errores sistemáticos, mantiene una muestra uniforme y es idóneo para pruebas computacionales. Es flexible y eficaz, adecuado para diversas aplicaciones, generando resultados rápidamente.

3.2 Redes neuronales artificiales

Una red neuronal artificial (RNA) consta de capas de entrada, oculta y de salida que detectan relaciones complejas entre variables. La capa de entrada recibe los datos, la oculta los procesa y el modelo se entrena ajustando los pesos de manera iterativa, propagando los errores hacia atrás para mejorar la precisión. LeCun et al. [20] revisan los fundamentos, avances y aplicaciones de las RNA, mientras que Zhang et al. [21] analizan sus aplicaciones y detallan su eficacia.

Una red multicapa de propagación hacia delante consta de una capa oculta de neuronas sigmoideas y una capa de salida de neuronas lineales. Las neuronas de la capa oculta se conectan a las capas de entrada y salida (Figura 4), con su número proporcional a los parámetros de entrada y salida.




Figura 4. Ejemplo de red neuronal con capa oculta.

Las entradas (x_i) se multiplican por los pesos ($w_{i,j}$) y se combinan linealmente con un término independiente (b_j). Cada neurona oculta sigue esta ecuación $\sum x_i \cdot w_{i,j} + b_j$. Posteriormente, cada neurona de la capa oculta genera una salida empleando una función tangente sigmoide a la combinación lineal. La capa de salida emplea una función lineal. Es el conocido como perceptrón multicapa (MLP), muy utilizado al aproximar cualquier función, incluso con una sola capa oculta [20]. Su eficacia se debe al algoritmo de retropropagación [22-24].

En una red de propagación hacia delante (*feed-forward*), las conexiones circulan de la capa de entrada a la de salida, y el aprendizaje se

supervisa con datos con respuestas conocidas. Los datos se dividen en tres grupos para evaluar el sobreajuste: entrenamiento para ajustar los parámetros de la red, validación para detectar el sobreaprendizaje y prueba para evaluar el rendimiento. La técnica de «parada temprana» (*early stopping*) evita el sobreajuste dividiendo los datos en entrenamiento y validación. Durante la optimización, se comparan los errores de ambos conjuntos. Si el error de entrenamiento disminuye y el de validación aumenta, el proceso se interrumpe para evitar el sobreaprendizaje.

La red neuronal utilizó 30 datos (24 de entrenamiento, 3 de validación y 3 de prueba) elegidos al azar. Emplea una capa oculta de cinco neuronas. El rendimiento se evalúa mediante simulación, utilizando datos de entrenamiento o nuevos para realizar predicciones y analizar los resultados.

El primer paso es la validación cruzada, que compara la salida del entrenamiento con los resultados de la simulación de la red neuronal. Este proceso es clave para evaluar la precisión y detectar la sobreadaptación, cuando el modelo se especializa demasiado en los datos de entrenamiento. La validación cruzada puede aplicarse a los datos de entrenamiento, validación o prueba, o a todos, para evaluar el sobreajuste.

La Figura 5 muestra el comportamiento de la red para el caso estudiado, con validación cruzada de datos de entrenamiento, validación, prueba y totales. Es importante señalar que, al ejecutar la red, los datos de validación se eligen aleatoriamente, lo que cambia los ajustes. Al analizar los gráficos de la Figura 5, se observa que entrenar la red neuronal con un conjunto de datos aleatorio permite lograr una alta correlación, que disminuye cuando se aplica la red a nuevos datos de prueba. Este efecto también se aprecia al aplicar la red al conjunto completo de datos, donde el coeficiente R es alto, pero menor que durante la fase de entrenamiento.




Figura 5. Validación cruzada de datos de entrenamiento, validación, prueba y datos totales.

4. Resultados y discusión

Los datos observados se representan en una superficie de respuesta para analizar su brusquedad, utilizando Minitab v17. Las Figuras 3 y 5 muestran los 37 datos observados (Tabla 2), con las emisiones como variable de respuesta.




Figura 5. Superficie de respuesta de los 37 tableros.

La Figura 6 muestra el gráfico de contorno correspondiente, revelando múltiples óptimos locales. Los modelos de regresión lineal no son adecuados, y los modelos no lineales suavizan excesivamente la respuesta debido a la abrupta naturaleza de la superficie, lo que resalta la necesidad de modelos avanzados de predicción y optimización para identificar la

solución óptima. No obstante, se ha ajustado también un modelo lineal, con un $R^2_{aj} = 82,04 \%$, cuya ecuación de regresión es la siguiente:

$$CO_2(kg) = 25109 + 115589 \cdot Canto(m) + 34531 \cdot Base(m) + 3055 f_{ck}(MPa) \quad (2)$$




Figura 6. Superficie de contorno de los 37 tableros.

La Tabla 3 muestra los valores observados, los tres modelos de Kriging utilizados, una regresión lineal y la media de 16 ejecuciones de redes neuronales para los óptimos locales en la diversificación (#36) e intensificación (#37). Los modelos Kriging son deterministas, mientras que las redes neuronales no, ya que sus datos de aprendizaje y validación se eligen aleatoriamente. La red neuronal se ejecutó 16 veces para estabilizar la desviación típica de los valores medios, dividiéndola por 4.

Para analizar el error relativo se han comparado la predicción de las 30 losas empleadas en la fase de diversificación con todos los modelos (Tabla 1). El menor error relativo respecto al óptimo de la fase de intensificación lo proporciona el modelo lineal. Sin embargo, el panorama cambia cuando observamos en la Tabla 4 las medias del error cuadrático medio (MSE) y su raíz (RMSE) para la predicción de las losas #31 a #37. Se observa que aquí, los menores errores los ofrece la red neuronal, seguido de cerca del modelo Kriging 1.

Tabla 3. Valor observado y predicción de los óptimos locales en diversificación (#36) e intensificación (#37), con sus errores relativos.

	Óptimos locales		Error relativo (%)	
	#36	#37	#36	#37
Observado	391370.00	386514.57	0.00	0.00
Kriging 1	394807.56	398496.09	0.88	3.10
Kriging 2	389611.63	373195.10	-0.45	-3.45
Kriging 3	387247.17	349637.95	-1.05	-9.54
Regresión lineal	402802.49	376570.76	2.92	-2.57
RNA	400618.57	399218.74	2.36	3.29

Tabla 4. MSE y RMSE de los modelos predictivos.

Modelo predictivo	MSE	RMSE
Kriging 1	85289721	9235
Kriging 2	368206605	19189
Kriging 3	762449127	27612
Regresión lineal	160076717	12652
Media RNA	70085787	8372

Se evalúa la capacidad de la red neuronal para identificar valores óptimos mediante el análisis de los promedios de 16 ejecuciones con los 37 valores observados. La Figura 7 muestra la predicción del canto mínimo del tablero con una base de 3.40 m y hormigón HP35. El canto óptimo obtenido con Kriging, 1.10 m, coincide con los resultados de la red neuronal, que indican un aumento de las emisiones de CO₂ a partir de esta medida. Esto confirma la coherencia entre ambos enfoques para la optimización.




Figura 7. Predicción del CO₂ en función del canto del tablero (base de 3.40 m y HP35).

Cuando el canto del tablero es de 1.10 m y el hormigón es HP35, la red neuronal indica cómo evolucionan las emisiones con la dimensión del ancho del tablero. Como se puede ver, entre 3.00 m y 3.40 m de base, las emisiones son mínimas, subiendo a partir de ahí lentamente y luego, ya a partir de 4.00 m, de forma más pronunciada. Esto es coherente con el valor mínimo de la base encontrado al optimizar la superficie de respuesta de Kriging, que era de 3.40 m.




Figura 8. Predicción del CO₂ en función de la base del tablero (canto de 1.10 m y HP35).

Si ahora se mantiene el canto en 1.10 m y la base en 3.40 m, la red neuronal indica cómo evolucionan las emisiones de CO₂ con la resistencia característica del hormigón (Figura 9). De 30 a 40 MPa, las emisiones permanecen en sus valores más bajos, aumentando claramente a partir de ese momento. Esto concuerda con el valor de 35 MPa obtenido en la optimización de la superficie de respuesta generada por el metamodelo Kriging.




Figura 9. Predicción del CO₂ en función del hormigón (base de 3.40 m y canto de 1.10 m).

5. Recomendaciones prácticas

La Dirección General de Carreteras (DGC) [25] sugiere una relación de esbeltez entre 1/22 y 1/30, mientras que la SETRA [26] recomienda una relación de 1/28 para tableros de losa de tres vanos con voladizos anchos. Los resultados de la red neuronal, que coinciden con las conclusiones de Yepes-Bellver et al. [15], proporcionan recomendaciones prácticas para reducir las emisiones en un puente de losa pretensada de tres vanos con una luz principal de 34 m. Estas recomendaciones incluyen una esbeltez superiores 1/28, una cuantía de hormigón inferior a $0.60 \text{ m}^3/\text{m}^2$ para el tablero, una cuantía de armadura pasiva de $120 \text{ kg}/\text{m}^3$ de hormigón, con una armadura activa por debajo de $17 \text{ kg}/\text{m}^2$ de tablero. La resistencia característica a la compresión del hormigón debe estar comprendida entre 35 y 40 MPa, el aligeramiento interior no debe superar los $0.20 \text{ m}^3/\text{m}^2$ de tablero y el aligeramiento exterior debe estar comprendido entre 0.40 y $0.50 \text{ m}^3/\text{m}^2$ de tablero.

Así, la red neuronal puede identificar el óptimo local, que se aproxima al valor obtenido tras optimizar la superficie de respuesta del metamodelo Kriging. Sin embargo, para que los modelos de Kriging o las redes neuronales predigan las emisiones de CO_2 con mayor precisión, debe realizarse un proceso de optimización heurística. Por lo tanto, aunque los modelos subrogados pueden proporcionar una superficie de respuesta, es fundamental optimizarla para encontrar un mínimo local. Sin embargo, estos modelos permiten obtener resultados de proyecto probados y ayudan a acotar los rangos óptimos de diseño para las variables críticas. El planteamiento propuesto constituye una importante ayuda para los ingenieros de estructuras que no recurren rutinariamente a algoritmos heurísticos de optimización, lo que les hace perder oportunidades de reducir los costes económicos y medioambientales.

6. Conclusiones

El artículo compara el rendimiento de la técnica de Kriging y de una red neuronal perceptrón multicapa para minimizar las emisiones de CO_2 en puentes de losa aligerada pretensada. Para ello, se evaluaron las emisiones para la construcción de 37 soluciones de un paso elevado de carretera real utilizando modelos de Kriging y de redes neuronales. El análisis reveló que la superficie de respuesta que evalúa el consumo de energía es compleja y abrupta, y presenta numerosos óptimos locales, lo que pone de manifiesto la complejidad del problema. Tanto los modelos de Kriging como las redes neuronales tienden a predecir valores cercanos a los observados. Sin embargo, la red neuronal presenta errores cuadráticos medios (RMSE) más bajos. A diferencia de los modelos Kriging deterministas, las redes neuronales requieren múltiples ejecuciones para estabilizar sus respuestas y determinar los valores medios. Además, la verificación de esta estructura indica que la red neuronal identifica la ubicación del óptimo local, que se asemeja al valor obtenido al optimizar la superficie de respuesta obtenida mediante Kriging. No obstante, ninguno de los dos metamodelos logra predicciones exactas de la función objetivo, sino que orientan hacia zonas prometedoras dentro del espacio de soluciones. Por lo tanto, aunque los modelos definen una superficie de respuesta con bastante aproximación, sigue siendo necesario optimizar esta superficie para encontrar un mínimo local con una mayor precisión.

Para reducir las emisiones, las recomendaciones de diseño pasan por utilizar esbeltez lo más alta posible, mayores 1/28, lo que supone una mayor cantidad de armadura pasiva. Este aumento de la armadura pasiva se compensa con la reducción de la cuantía de hormigón y de la armadura activa. Para reducir el volumen de hormigón, se recomienda aumentar los aligeramientos en la medida de lo posible.

Agradecimientos

Ayuda PID2023-150003OB-I00 financiada por MICIU/AEI/10.13039/501100011033 y por “FEDER/UE”.

Referencias

- [1] Alhorr, Y., Eliskandarani, E., & Elsarrag, E. (2014). Approaches to reducing carbon dioxide emissions in the built environment: Low carbon cities. *International Journal of Sustainable Built Environment*, 3(2), 167–178.
- [2] World Green Building Council (WGBC). (2023). *How we are #BuildingTheTransition to support the Sustainable Development Goals*. Retrieved from <https://worldgbc.org/wp-content/uploads/2023/09/Buildings-SDG-graphic-1.pdf>.
- [3] Gursel, A. P., Masanet, E., Horvath, A., & Stadel, A. (2014). Life-cycle inventory analysis of concrete production: A critical review. *Cement and Concrete Composites*, 51, 38–48.
- [4] Maureira, C., Pinto, H., Yepes, V., & García, J. (2021). Towards an AEC-AI industry optimization algorithmic knowledge mapping. *IEEE Access*, 9, 110842–110879.
- [5] Yepes, V., Martí, J. V., & García-Segura, T. (2015). Cost and CO₂ emission optimization of precast-prestressed concrete U-beam road bridges by a hybrid glowworm swarm algorithm. *Automation in Construction*, 49, 123–134.
- [6] García-Segura, T., Yepes, V., Alcalá, J., & Pérez-López, E. (2015). Hybrid harmony search for sustainable design of post-tensioned concrete box-girder pedestrian bridges. *Engineering Structures*, 92, 112–122.
- [7] García-Segura, T., & Yepes, V. (2016). Multiobjective optimization of post-tensioned concrete box-girder road bridges considering cost, CO₂ emissions, and safety. *Engineering Structures*, 125, 325–336.
- [8] Penadés-Plà, V., Martí, J. V., García-Segura, T., & Yepes, V. (2017). Life-cycle assessment: A comparison between two optimal post-tensioned concrete box-girder road bridges. *Sustainability*, 9(11), 1864.
- [9] Penadés-Plà, V., García-Segura, T., Martí, J. V., & Yepes, V. (2018). An optimization-LCA of a prestressed concrete precast bridge. *Sustainability*, 10(3), 685.
- [10] Yepes, V., Dasí-Gil, M., Martínez-Muñoz, D., López-Desfilís, V., & Martí, J. V. (2019). Heuristic techniques for the design of steel-concrete composite pedestrian bridges. *Applied Sciences*, 9(16), 3253.
- [11] Cressie, N. (1990). The origins of Kriging. *Mathematical Geology*, 22, 239–252.
- [12] Martínez-Frutos, J., & Martí, P. (2014). Diseño óptimo robusto utilizando modelos Kriging: Aplicación al diseño óptimo robusto de estructuras articuladas. *Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería*, 30, 97–105.
- [13] YiFei, L., MaoSen, C., Hoa, T. N., Khatir, S., Minh, H. L., SangTo, T., Cuong-Le, T., & Wahab, M. A. (2023). Metamodel-assisted hybrid optimization strategy for model updating using vibration response data. *Advances in Engineering Software*, 185, 103515.
- [14] Sánchez-Zabala, V. F., & Gómez-Acebo, T. (2024). Building energy performance metamodels for district energy management optimisation platforms. *Energy Conversion and Management: X*, 21, 100512.
- [15] Yepes-Bellver, L., Brun-Izquierdo, A., Alcalá, J., & Yepes, V. (2022). CO₂-optimization of post-tensioned concrete slab-bridge decks using surrogate modeling. *Materials*, 15(14), 4776.
- [16] Yepes-Bellver, L., Brun-Izquierdo, A., Alcalá, J., & Yepes, V. (2023). Embodied energy optimization of prestressed concrete road flyovers by a two-phase Kriging surrogate model. *Materials*, 16(20), 6767.

- [17] Hong, W. K., Nguyen, M. C., & Pham, T. D. (2023). Pre-tensioned concrete beams optimized with a unified function of objective (UFO) using ANN-based Hong-Lagrange method. *Journal of Asian Architecture and Building Engineering*, 23, 1573-1595.
- [18] Lophaven, N. S., Nielsen, H. B., & Sondergaard, J. (2002). *MATLAB Kriging Toolbox DACE (Design and Analysis of Computer Experiments) Version 2.0*.
- [19] McKay, M. D., Beckman, R. J., & Conover, W. J. (1979). A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, 21(2), 239-245.
- [20] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- [21] Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35-62.
- [22] Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(4), 359-366.
- [23] Rumelhart, D. E., McClelland, J. L., & PDP Research Group. (1986). *Parallel distributed processing: Explorations in the microstructure of cognition* (Vol. 1: Foundations). Cambridge, UK: MIT Press.
- [24] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- [25] Dirección General de Carreteras. (2000). *Obras de paso de nueva construcción: Conceptos generales*. Ministerio de Fomento, Centro de Publicaciones.
- [26] SETRA. (1989). *Ponts-Dalles. Guide de conception*. Ministère de l'Équipement, du Logement des Transports et de la Mer.