

Diseño eficiente de estructuras con Inteligencia Artificial. Aplicación al diseño de una nueva unión prefabricada de hormigón armado*

Efficient Design of structures by using Artificial Intelligence. Application to the design of a novel precast concrete connection

Jorge Domingo Navarro Rubio^{*,a}, Paloma Pineda^b

^a Dr. Arquitecto. Ingeniero de Caminos, Canales y Puertos. Arquitecto Técnico. NR Proyectos CEO.

^b Dra. Arquitecta, MSc Física, Profesora Titular de Universidad, Dpto. Estructuras de Edificación e Ingeniería del Terreno, ETS. Arquitectura, Universidad de Sevilla, España.

RESUMEN

El uso de Redes Neuronales Artificiales (ANN) en el cálculo de estructuras de hormigón prefabricado es una herramienta valiosa para optimizar el diseño y análisis de estos elementos. Las ANN permiten predecir comportamientos complejos y mejorar la eficiencia y precisión en el diseño de uniones y elementos estructurales. Esta investigación destaca la importancia del procedimiento para utilizar las ANN en uniones de elementos prefabricados de hormigón armado y su extrapolación a otro tipo de uniones o elementos estructurales. De esta manera, las ANN permiten obtener soluciones innovadoras y eficientes en el campo de las estructuras arquitectónicas y de obra civil.

ABSTRACT

The use of Artificial Neural Networks (ANN) in the analysis of precast concrete structures are a valuable tool for optimizing the design and evaluation of these elements. ANN enable the prediction of complex behaviors, enhancing efficiency and accuracy in the design of connections and structural components. This research highlights the importance of the methodology for applying ANN to the connections of precast reinforced concrete elements and their potential extrapolation to other types of connections or structural components. In this way, ANN provide innovative and efficient solutions in the field of architectural and civil engineering structures.

PALABRAS CLAVE: Inteligencia artificial, hormigón prefabricado, acero, unión, optimización.

KEYWORDS: Artificial Intelligence, precast concrete, steel, connection, optimization.

1. Introducción

En la última década, la inteligencia artificial (IA) ha revolucionado numerosos campos, y el de las estructuras arquitectónicas y de la obra civil no es una excepción. Entre las técnicas más prometedoras dentro de la IA, las Redes

Neuronales Artificiales destacan por su capacidad para aprender y predecir comportamientos complejos basados en datos previos. Esto les permite diferenciar entre información relevante e irrelevante y adaptarse a

situaciones imprevistas. Además, las ANN pueden predecir relaciones complejas entre variables. Estas redes son especialmente útiles para resolver problemas que no tienen procedimientos de resolución bien definidos, permitiendo la generalización a nuevos casos partiendo de experiencias previas [1].

En el contexto del diseño estructural, las ANN han comenzado a ganar popularidad debido a su capacidad de optimización y diseño. En particular, su aplicación en elementos prefabricados de hormigón armado ha mostrado resultados prometedores. Este método de construcción ofrece numerosas ventajas, como la reducción de tiempo de ejecución y costos, así como una mayor calidad y durabilidad de los componentes.

Sin embargo, el diseño y análisis de elementos prefabricados de hormigón armado presentan desafíos específicos que requieren soluciones innovadoras. Aquí es donde las ANN demuestran su valor. Al integrar técnicas numéricas como el Método de Elementos Finitos (FEM) con las capacidades predictivas de las ANN, se puede mejorar la eficiencia y precisión de los análisis estructurales.

El uso de ANN en el campo estructural tiene múltiples aplicaciones. Desde su introducción en la ingeniería civil en 1989, las ANN han sido utilizadas en el monitoreo de estructuras, control de vibraciones, optimización de diseños y predicción de comportamientos estructurales [2]. En el ámbito específico del hormigón armado, las ANN han permitido predecir la resistencia a compresión y también a fatiga del hormigón.

Además, los sistemas neuro-difusos, como el ANFIS, han sido aplicados en el análisis de curvatura y ductilidad en vigas de hormigón. En combinación con resultados experimentales y simulaciones, las ANN han demostrado ser herramientas robustas para modelar materiales, optimizar diseños y analizar comportamientos complejos bajo diversas condiciones de carga [3].

En la práctica, el uso de ANN para optimización estructural se ha extendido mediante algoritmos metaheurísticos, logrando evaluaciones económicas y diseños más eficientes. Estudios recientes han aplicado ANN para predecir la resistencia al cortante en uniones viga-pilar [4] o los refuerzos a cortante de estructuras de hormigón con materiales compuestos [5], basándose en amplios conjuntos de datos experimentales. Este enfoque no solo reduce significativamente los tiempos de cálculo, sino que también mejora la precisión en escenarios complejos. También han sido explorados mediante ANN los refuerzos a cortante en estructuras de hormigón.

A pesar de los avances sustanciales en la aplicación de ANN en el ámbito estructural, aún existen desafíos y áreas poco exploradas. La aplicación directa de ANN al diseño de elementos prefabricados de hormigón sigue siendo un campo en desarrollo. Aunque las ANN se han utilizado ampliamente en la industria de la construcción 4.0, su potencial en uniones de elementos prefabricados aún no ha sido plenamente explotado.

En este artículo se propone un procedimiento para el uso de ANN para la predicción de tensiones y deformaciones en elementos estructurales aislados y se aplica a un caso de estudio específico, en el diseño de una unión viga-pilar de elementos prefabricados de hormigón. Este procedimiento incluye la selección y normalización de datos de entrada, el diseño y entrenamiento de las redes neuronales, y la validación de los resultados obtenidos.

2. Método y aplicación al diseño de una unión viga-pilar.

2.1 Definición de la unión

La unión utilizada para la aplicación de la metodología propuesta en esta investigación está compuesta por los siguientes elementos (Fig. 1):




Figura 1. 3D de la unión. Discretización FEM. Geometría.

- Vigas y pilar como elementos prefabricados de hormigón armado de sección transversal 40 x 40 cm. La resistencia del hormigón se utiliza como parámetro de dimensionado y varía desde 25 hasta 40 MPa, con incrementos de 5 MPa.
- Chapa de acero S355 de resistencia y espesor también utilizado como parámetro desde los 15 a los 40 mm con incrementos de 5 mm.
- Tornillos de diámetro (12, 16, 20, 22 y 24 mm) y resistencias variables, 4.6, 5.6, 6.8, 8.8 y 10.9, donde el primer valor indica la resistencia a rotura y el segundo el porcentaje donde se sitúa el límite elástico
- Tendón de acero postesado (PT) ubicado en el centro geométrico de las vigas en toda su longitud, cuya carga de postesado varía desde los 0 kN hasta los 200 kN con incrementos de 50 kN.

Estos elementos están diseñados para funcionar como una unión seca con un comportamiento similar a una ejecutada in situ, es decir, capaces de resistir momentos flectores, además de cortantes y, eventualmente, axiles. El

PT proporciona resistencia a cortante en la interfaz viga-pilar y permite cierta restitución de la unión cuando cesa la carga horizontal actuante, disminuyendo así la deformación en la misma. Los tornillos que cruzan las placas y el pilar están diseñados para disipar energía mediante su plastificación. La ubicación del PT, en el centroide de la viga, permite reducir la plastificación de los tornillos cuando rota la viga al someterse a cargas horizontales.

El postesado y los tornillos ha sido modelado como un cilindro sólido con un diámetro equivalente al del área de la sección del elemento. En ambos casos son pasantes y, por tanto, sin contacto con el hormigón.

El armado pasivo, longitudinal y transversal, se ha calculado según el Eurocódigo 2 [6], para las máximas solicitaciones previstas hasta la rotura del hormigón.

2.2 Modelo estructural de la unión

En investigaciones previas [7,8] se han realizado diversos modelos numéricos para simular el comportamiento de la unión

propuesta bajo diferentes hipótesis de carga y variaciones en las dimensiones de sus componentes, tales como el diámetro de los tornillos o el espesor de las placas, así como en la resistencia de elementos como el hormigón en vigas y el acero. Esta variación en resistencias o dimensiones permite realizar un estudio paramétrico del comportamiento y optimizar su diseño. En este apartado se describen los distintos modelos y sus condiciones de contorno.

Los modelos de elementos finitos de la unión se elaboran representando con precisión la configuración geométrica, dimensiones y condiciones de contorno, además de considerar los detalles de armado de acuerdo a los materiales y geometría previamente indicados.

Para el análisis numérico se ha utilizado el software Ansys. Para representar el comportamiento del hormigón se empleó el elemento Solid65. Este elemento es adecuado para reproducir la deformación plástica, fisuración en tres direcciones ortogonales y aplastamiento. Para modelar el armado dentro de los elementos de hormigón se utilizó el elemento Link180, considerando la geometría y sección de cada una de las barras. El elemento SOLID185 se utilizó para el resto de los elementos de acero, como placas, cordón de postesado o tornillos, incluidas las tuercas.

El contacto en la interfaz entre hormigón y acero se representó empleando los elementos TARGE170 y CONTA173. Ambos son capaces de simular la existencia de presión entre los elementos cuando hay contacto y el vacío cuando no existe, incluyendo fricción y cohesión entre los componentes.

La malla consta de 37,631 elementos en el modelo de unión prefabricada (fig. 1).

Se considera un comportamiento en rango no lineal tanto para el material como para la geometría en el desarrollo de los distintos modelos de cálculo.

Se realizaron 32 simulaciones numéricas eligiendo aleatoriamente la resistencia de los

materiales, la geometría y la carga de postesado de la unión.

Se consideran dos tipos de acciones aplicadas a la unión. En primer lugar, se analiza una carga vertical ubicada en la cara superior de las vigas. Para este análisis, se establecen diferentes escalones de carga creciente desde 0 MPa hasta 0.20 MPa, con un incremento en las cargas de 0.02 MPa. Este rango de cargas pretende cubrir los casos más comunes en edificación. Es importante tener en cuenta que, considerando el peso propio de los forjados, así como las cargas muertas y sobrecargas, para luces aproximadas de 5 m, la carga vertical uniforme sobre la cara superior de las vigas se estima en torno a 0.10 MPa.

En segundo lugar, para la evaluación del comportamiento de la conexión frente a cargas horizontales, se ha aplicado un desplazamiento impuesto en la cara superior del pilar. Dicho desplazamiento varía desde 0 mm hasta alcanzar un máximo de 75 mm, equivalente a un 2.5% de desplome horizontal.

Las cargas aplicadas en cada caso se han iterado paso a paso utilizando el método de Newton-Raphson.

3. Proceso

Para esta investigación se han desarrollado y validado cuatro ANN distintas, una para cada elemento de la unión (vigas, placas, tendón postesado y tornillos), utilizando datos obtenidos mediante análisis de elementos finitos.

La implementación de las ANN se realiza mediante la definición de una arquitectura de red adecuada. En esta investigación, se ha optado por un perceptrón multicapa con un algoritmo de retropropagación. La red incluye una capa de entrada con seis neuronas, dos capas ocultas y una capa de salida que representa la predicción de la tensión máxima en cualquier nodo o elemento del sistema estructural.

La validación de las ANN es un proceso crítico para garantizar la calidad de los

resultados. Los resultados obtenidos muestran que los errores medios y máximos de las predicciones realizadas por las ANN son aceptables y se mantienen dentro de los rangos de seguridad establecidos por los códigos de diseño estructural.

La Figura 2 muestra el diagrama de flujo de las ANN generadas. Este diagrama ilustra el proceso completo, desde la selección y normalización de los datos de entrada hasta la validación de los resultados obtenidos.




Figura 2. Diagrama de flujo de las ANN.

3.1 Selección de datos de entrada

Es esencial en el diseño de las ANN la adecuada selección de los datos para el proceso de aprendizaje y validación. La muestra seleccionada debe ser representativa de todas las variables posibles. La mayoría de los parámetros como el espesor de placa, el diámetro del tornillo y la resistencia del hormigón son discretos y

normalizados en el sector industrial. Por ejemplo, los diámetros de los tornillos disponibles suelen ser 12, 16, 20 mm, etc., sin utilizarse valores intermedios como 14.3 mm. El único parámetro continuo podría ser la carga de postesado, pero siguiendo la práctica habitual en construcción, también se seleccionan valores discretos comunes para este parámetro.

El número de variables contempla todas aquellas definidas e indicadas previamente:

- Espesor de placa: 15, 20, 25, 30, 35 y 40 mm.
- Diámetro del tornillo: 12, 16, 20, 22 y 24 mm.
- Carga de postesado: 0, 50, 100, 150 y 200 kN.
- Resistencia del hormigón: 25, 30, 35 y 40 MPa.
- Resistencia del tornillo: 4.6, 5.6, 6.8, 8.8 y 10.9.

Se procede fijando una variable de cada grupo para analizar su combinación, por ejemplo, 20 mm para espesor de placa, 20 mm para diámetro de tornillo, 100 kN para carga de postesado, 25 MPa de resistencia del hormigón y 8.8 para la resistencia del tornillo. Una vez analizada esa combinación, se modifica una de las variables manteniendo el resto fijas, variando, por ejemplo, la resistencia del hormigón en todo su rango. Este proceso se repite con todas las variables.

Para cada valor distinto de una variable se construye un modelo de elementos finitos y se guardan paso a paso los resultados proporcionados. De esta forma, se registra la historia tensional de cada nodo del sistema desde el inicio de la carga hasta que el modelo deja de converger. Este procedimiento proporciona datos de entrada fiables, sumando aproximadamente dos millones de datos por cálculo. Este volumen permite que las ANN aprendan cómo influye la modificación de un parámetro en las tensiones de los distintos elementos bajo carga, pudiendo además predecir relaciones al cambiar otros parámetros conforme avanza el proceso de aprendizaje.

Para cada modelo FEM se aplica una carga creciente sobre la cara superior de la viga. Los valores de deformación vertical y tensión en los nodos se registran en cada step y substep. Todos los pasos, incluidos los intermedios, desde el estado inicial hasta el final, se han analizado y guardado como entrada para el proceso de aprendizaje. Los datos registrados tienen información implícita relevante ya que las relaciones entre tensiones y deformaciones en nodos adyacentes se consideran en el análisis FEM.

En los modelos utilizados como input, los parámetros se registran en cada substep del modelo numérico FEM. La estructura de datos seguida es uniforme para todos los archivos generados, permitiendo una adecuada lectura y operación del algoritmo de las ANN. Las columnas de los archivos de datos incluyen el paso y el número de nodo para fácil identificación en el modelo numérico, así como las tensiones de material: (i) σ_x y σ_y son las tensiones del hormigón en las direcciones X e Y; (ii) V_{xy} y V_{xz} son las tensiones tangenciales del hormigón a lo largo de los planos XY y XZ; y (iii) σ_{vm} es la tensión de Von Mises en los elementos de acero.

3.2 Elección e implementación de ANN

Hay factores relevantes que influyen en la selección de la mejor red neuronal para resolver un problema específico depende de diversos factores críticos. Estos factores, como pueden ser el tipo de problema que se plantea resolver, el tipo y cantidad de datos de entrada o la capacidad computacional y el tiempo de entrenamiento disponible, aseguran que el modelo de red neuronal escogido se ajuste adecuadamente a las características del problema que se busca resolver.

Una vez considerados, se pueden probar diferentes tipos de redes neuronales para encontrar la que ofrezca los mejores resultados. El entrenamiento y optimización de una red neuronal es un proceso iterativo, y puede ser

necesario probar diversas configuraciones antes de encontrar la mejor solución.

En el diseño de la ANN, un factor clave es obtener una red que sea lo más simple posible y que no incluya datos irrelevantes. En este trabajo, dado que el objetivo principal es predecir cuándo colapsará o plastificará alguno de los elementos de la unión, el interés principal será localizar el nodo más cargado y compararlo con su valor límite. De esta manera, la red aprende cómo la carga aplicada incrementa la tensión en los elementos del modelo FEM. Una ANN para cada elemento de la unión permite predecir el valor tensional máximo bajo una carga determinada. Además, esta red aprende cómo varían las tensiones al cambiar parámetros como la resistencia del hormigón o de los tornillos. Este procedimiento no depende del número de nodos del modelo numérico, pues se analiza el valor máximo de la variable en cada *step* o *substep*.

La etapa inicial del diseño de la ANN consiste en definir la arquitectura de red. Las redes más comunes incluyen una capa de entrada, una oculta y una de salida, suficientes para resolver la mayoría de los problemas.

En esta investigación, todas las ANN tienen una estructura básica: un perceptrón multicapa. Se implementa un algoritmo simple de *backpropagation*. La capa de entrada tiene seis neuronas que representan las variables de entrada: Steps, diámetro del tornillo, resistencia del hormigón, resistencia del tornillo, carga PT y espesor de la placa (Tabla1). En cuanto a las capas ocultas, generalmente una capa es suficiente. Sin embargo, cuando aumenta el número de neuronas en una sola capa, la eficiencia predictiva no mejora de forma significativa, y para problemas complejos, se podrían requerir dos capas ocultas. Después de una fase de ensayo y error con una capa oculta y mayor número de neuronas, se observó que las redes diseñadas no convergían adecuadamente. Por ello, se optó por incluir una nueva capa

oculta para lograr una mejor convergencia y rendimiento.

Tabla 1. Resumen de las ANN generadas.

	RED NEURONAL			
	Placa	Tornillos	Vigas	PT
Número de nodos de entrada		6		
Número de capas ocultas		2		
Número de neuronas en la capa oculta #1	20	12	25	8
Número de neuronas en la capa oculta #2	12	8	15	4
Número de nodos en la capa de salida		1		
Función de activación en los nodos ocultos	Tangente hiperbólica			
Volumen de datos en aprendizaje		2.126.000		
Volumen de datos en validación		1.200.000		
Tiempo de entrenamiento máximo		16 h		
Número de iteraciones		1.8 millones		

El número de neuronas en la capa oculta es crucial y depende de la complejidad del modelo ANN, influenciado por varios aspectos como el número de entradas y salidas del problema y la continuidad de la variable de entrada. Estudios previos [9] han demostrado que elegir adecuadamente el número de neuronas en la capa oculta es esencial para obtener un rendimiento óptimo en la red. Para minimizar el error de salida y acelerar el proceso de aprendizaje es vital contar con un número mínimo de neuronas en las capas ocultas, asegurando la estabilidad de la red.

Respecto a la arquitectura de la red, la capa de salida consta de una sola neurona que representa la predicción de la tensión máxima en cualquier nodo o elemento del sistema estructural. Esta neurona produce el resultado final de la red.

Cada una de las ANN diseñada debe ser probada y analizada.

Una de las principales ventajas de implementar el uso de Redes Neuronales Artificiales en las etapas iniciales del diseño de

elementos estructurales es la reducción significativa en el tiempo de computación requerido en comparación con los análisis convencionales de Elementos Finitos. De hecho, una vez que la ANN ha completado su proceso de aprendizaje, proporciona estimaciones de manera inmediata para cualquier nueva configuración. En este estudio, el tiempo consumido en el proceso de aprendizaje fue de 16 horas por cada ANN, utilizando un equipo con un procesador Ryzen 9 3900X y 16 GB de RAM, donde se realizaron aproximadamente 1,8 millones de iteraciones. La ANN propuesta predice la matriz de rigidez resuelta en el modelo FEM, proporcionando la tensión máxima esperada en los nodos para cada elemento: placas, tornillos, vigas o tendones. Cabe destacar que la resolución de esa matriz es uno de los pasos más costosos en términos de tiempo en los análisis de FEM. Además, el tiempo de computación aumenta exponencialmente en los análisis no lineales. La predicción de datos es proporcionada por la ANN inmediatamente tras ingresar los datos de entrada para cualquier valor de carga aplicada en la cara superior de la viga. Adicionalmente, la ANN puede predecir el comportamiento no lineal (en términos de material y geometría) de la conexión diseñada. Cada step del modelo FEM tiene una relación directa con la carga aplicada, permitiendo obtener fácilmente la relación entre la carga aplicada y las tensiones en el elemento.

3.3 Validación de las ANN

La validación de una red neuronal es un proceso importante para determinar su eficacia y capacidad de generalización en problemas nuevos. Existen varias técnicas comunes para validar una red neuronal, entre las cuales se incluyen la validación cruzada, la *boldout* o la validación por *bootstrapping*.

Es importante considerar que la validación es un proceso crítico para garantizar la calidad de los resultados obtenidos por una red neuronal. Este procedimiento ayuda a prevenir el

sobreajuste y asegura que la red neuronal pueda generalizar a problemas nuevos de manera efectiva.

En la validación de cada red neuronal artificial, se ha utilizado la técnica *holdout* con un total de 1.2 millones de datos de entrada. Estas entradas se distribuyen en 40 archivos, 10 para cada una de las ANN, obtenidos variando aleatoriamente los parámetros. Se han realizado diez simulaciones o cálculos numéricos adicionales, comparando paso a paso los resultados de las tensiones máximas en los nodos de los elementos del modelo FEM con las predicciones realizadas por cada ANN. Los parámetros aplicados en la validación se resumen en la Tabla 2. Los modelos se seleccionaron aleatoriamente, por lo que los parámetros correspondientes a cada unión también fueron escogidos de forma aleatoria.

Tabla 2. Parámetros de los archivos de validación.

	D torn.	Fck	Resis. Torn.	Carga PT	Esp. Chapa
(a)	20	25	5.6	100	20
(b)	20	25	8.8	50	20
(c)	20	25	8.8	50	20
(d)	20	25	8.8	100	30
(e)	20	30	8.8	100	20
(f)	22	25	8.8	0	20
(g)	24	40	6.8	100	40
(h)	16	30	4.6	150	30
(i)	24	30	6.8	200	15
(j)	12	35	10.9	50	35

5. Resultados obtenidos por las ANN

Las cuatro redes neuronales artificiales (ANN) desarrolladas permiten diseñar y dimensionar uniones estructurales en etapas preliminares, reduciendo significativamente el tiempo de cálculo. Una vez definidas la arquitectura de cada

red, el *dataset* para el entrenamiento y el proceso de aprendizaje, las ANN se validan utilizando datos específicos. Durante este proceso, se comparan los valores de las curvas de ajuste, obteniendo el error máximo y medio. La Tabla 3 muestra el error medio en los distintos *steps* y *substeps*, así como el porcentaje de diferencia máxima entre las tensiones calculadas mediante elementos finitos y las predichas por las ANN en cada nodo.

Tabla 3. Errores de las ANN generadas comparadas con resultados numéricos (FEM).

ANN	Error Medio	Error Máximo
Placa de anclaje	8.36%	9.16%
Tornillos	6.45%	6.84%
Vigas prefabricadas	7.25%	6.11%
Cordón de PT	5.69%	6.89%

Como se puede observar, se detecta un error máximo del 9,16% en las placas, mientras que el error medio es del 8,36%. Tras analizar el modelo FEM, se verifica la presencia de valores elevados en algunos nodos ubicados en áreas de concentración de tensiones, o en *steps* cercanas al límite de resistencia del material, lo cual provoca dichas desviaciones. Resultados similares se observan en tornillos, vigas y tendones de postesado. Esta diferencia entre los valores medios y máximos se debe a dichos factores.

Para poder comprobar la evolución o convergencia durante el proceso de entrenamiento de las redes así como los resultados obtenidos en la validación o las predicciones que la ANN nos arroja cuando realizamos una consulta, se ha desarrollado una herramienta a modo de visor (fig. 3). Esta herramienta nos permite evaluar la convergencia de la red durante el entrenamiento y tomar decisiones de forma más ágil sobre las posibles modificaciones de la arquitectura de la red.




Figura 3. Visor de predicción de resultados y gráficas de validación.

Cada ANN evalúa elementos estructurales específicos (placas, tornillos, vigas y tendones), comparando las tensiones nodales máximas obtenidas por step con los resultados FEM. En hormigón, se utiliza la tensión principal máxima ($\sigma_x - \sigma_y$), mientras que en acero se aplica el criterio de Von Mises. Las cargas varían entre 0 y el máximo calculado en los análisis FEM, mostrando que, bajo 0,08 MPa, las diferencias son inferiores al 3%. Dado que la tensión máxima esperada en estructuras reales equivale aproximadamente al 50% del límite de resistencia del material (12,5 MPa para hormigón de 25 MPa), las ANN cumplen con los requisitos del Eurocódigo y del Código Estructural, confirmando su eficacia en el diseño.

A medida que se incrementan las cargas aplicadas y el hormigón alcanza su límite de resistencia, se observan desviaciones máximas entre las tensiones pronosticadas y las soluciones FEM.

En la validación, basada en diez combinaciones de parámetros del análisis FEM (ver Tabla 2), los errores promedio son inferiores al 8,38%, evidenciando la fiabilidad de las predicciones en etapas iniciales de diseño. Las

diferencias entre ANN y FEM son más estables en elementos tensados, como tornillos o tendones, y ligeramente más variables en placas y vigas (0,33%-8,38%). Estas discrepancias suelen concentrarse en los últimos pasos del cálculo, cerca del límite de resistencia del material, corroborando que las ANN son herramientas adecuadas para dimensionar elementos estructurales de forma preliminar.

5. Conclusiones

En este artículo se describe un procedimiento basado en redes neuronales artificiales que puede emplearse en las primeras fases de dimensionamiento o diseño de elementos estructurales. Después de generar y validar las ANN, se obtuvieron las siguientes conclusiones:

El análisis mediante elementos finitos comparado con las redes neuronales artificiales mostró un error máximo del 9,16% en esfuerzos cuando la tensión en el hormigón se acercaba a su límite de rotura. El error medio fue menor al

8,36% en el peor escenario de validación, ocurriendo en la ANN de la placa.

Si la tensión del hormigón es menor que F_{cd} , la diferencia máxima entre las tensiones del modelo de elementos finitos y las de las ANN se mantuvo por debajo del 5%. Con los coeficientes de seguridad que se utilizan siguiendo las normas y estándares de cálculo, esta diferencia es suficientemente segura para diseñar y calcular uniones en estructuras.

Las redes diseñadas pueden realizar análisis numéricos complejos, permitiendo la predicción de resultados para su uso como herramientas de decisión en las etapas iniciales del diseño de elementos estructurales. Además, las redes propuestas reducen el tiempo de cálculo en comparación con los métodos numéricos comunes, como los análisis mediante elementos finitos.

El procedimiento propuesto es flexible y aplicable a diferentes materiales y configuraciones estructurales, incluidos nuevos parámetros, dimensiones, formas y conexiones, mediante el uso de redes neuronales artificiales para predecir tanto los esfuerzos de los elementos como las deformaciones.

En conclusión, las ANN están transformando el cálculo de estructuras y el diseño de elementos prefabricados de hormigón, ofreciendo soluciones innovadoras y eficientes. Su capacidad para manejar problemas complejos, junto con su integración con métodos tradicionales, asegura un impacto duradero en la ingeniería estructural y civil. La investigación futura debe centrarse en explorar nuevas aplicaciones de las ANN y en mejorar su integración con otros métodos de análisis para maximizar su potencial en el diseño estructural.

Referencias

- [1] Murat, H., Zeynep, S. (2004) A neural network approach for early cost estimation of structural systems of buildings, *International Journal of Project Management*. 22: 595-602.
- [2] Amezcuita-Sanchez, J.P., Valtierra-Rodriguez, M.A., Adeli, H. (2016) Neurocomputing in civil infrastructure, *Sharif University of Technology*. 23: 2417-2428.
- [3] Kim T., Kwon, O.S., Song, J. (2019) Response prediction of nonlinear hysteretic systems by deep neural networks, *Neural Networks*, 111: 1-10.
- [4] Haido, J. (2022) Prediction of the shear strength of RC beam-column joints using new ANN formulations. *Structures*, 38: 1191-1209.
- [5] Perera, R., Barchín, M., Arteaga, A., de Diego, A. (2008) Diseño del refuerzo a cortante de estructuras de hormigón a base de materiales compuestos aplicando redes neuronales artificiales. *Hormigón y Acero*, 59 (250): 41-56.
- [6] AENOR (2004) *Eurocódigo 2: Proyecto de estructuras de hormigón*. Madrid.
- [7] Navarro-Rubio, J., Pineda, P., García-Martínez, A. (2019) Sustainability, prefabrication and building optimization under different durability and re-using scenarios: Potential of dry precast structural connections, *Sustainable Cities and Society*. 44: 614-628.
- [8] Navarro-Rubio, J., Pineda, P., Navarro-Rubio, R. (2020) Efficient Structural Design of a Prefab Concrete Connection by Using Artificial Neural Networks, *Sustainability*. 12: 1-18.
- [9] Marai, M., Ahmed, M., Mousa, S. (2009) Neural networks for predicting compressive strength of structural light weight concrete, *Construction and Building Materials* 23: 2214-2219.