







Aplicación de un algoritmo estadístico para la clasificación de la susceptibilidad de pisos ante vibraciones mediante redes neuronales

Application of a statistical algorithm for classifying the susceptibility of floors to vibrations using neural networks

L. F. Lara Gamez ^a, O. Caballero-Garatachea ^b, J. M. Cruz-Olguín ^a, V. López-Morales ^a, M. A. Ojeda-Misses ^a,
Y. N. Resendiz-Aguilar ^{a, *}

^aÁrea Académica de Computación y Electrónica, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

^bÁrea Académica de Ingeniería y Arquitectura, Universidad Autónoma del Estado de Hidalgo, 42184, Pachuca, Hidalgo, México.

Resumen

La tendencia actual de la arquitectura se basa en el uso de materiales ligeros y sistemas estructurales, lo cual ha generado un incremento en la vulnerabilidad de los sistemas de piso ante vibraciones inducidas por la actividad humana. Por ende, es primordial llevar a cabo la evaluación del comportamiento de las vigas y las losas en sistemas de pisos, lo que suele requerir de modelos complejos y herramientas computacionales. Por lo tanto, en este trabajo se presenta un algoritmo estadístico para la clasificación de sistemas estructurales tipo viga y losa mediante la frecuencia natural usando redes neuronales para clasificar vigas y losas susceptibles a vibraciones excesivas o resonancias. El algoritmo propuesto para el entrenamiento de las redes neuronales se basa en la teoría del muestreo estadístico, posteriormente se normaliza el error entre las frecuencias reales y estimadas mediante el uso del Teorema Central del Límite para aproximar la distribución normal y estimar la probabilidad de error, finalmente, ajustar los pesos sinápticos y los sesgos de la red mediante una función de mapeo. Los datos empleados están basados en ejemplos reales de manera analítica usando parámetros estructurales como la carga distribuida, la longitud, el momento de inercia y el módulo de Young. Finalmente, los resultados obtenidos demuestran que el algoritmo propuesto es capaz de clasificar los sistemas de piso con base en la susceptibilidad vibratoria, obteniendo una herramienta computacional eficiente, robusta y de bajo costo capaz de contribuir en el análisis, el diseño en el confort y la seguridad estructural de pisos.

Palabras Clave: Vibraciones, resonancia, red neuronal, estadística, frecuencia natural.

Abstract

In recent years, architecture has increasingly shifted toward lighter materials and more slender structural systems. While this approach offers important advantages in terms of efficiency and sustainability, it has also made floor systems more sensitive to vibrations caused by everyday human activity. Consequently, assessing the dynamic response of beams and slabs has become a necessary step in the design process, even though it often relies on sophisticated analytical models and computational tools. This paper proposes a statistical algorithm for classifying beam and slab structural systems based on their natural frequency, using neural networks to identify elements susceptible to excessive vibrations or resonance. The proposed training methodology is grounded in statistical sampling theory. The error between the actual and predicted natural frequencies is normalized using the Central Limit Theorem, allowing the error distribution to be approximated as normal and enabling the probabilistic estimation of classification uncertainty. The synaptic weights and biases are then updated through a deterministic mapping function rather than conventional gradient-based optimization. The dataset is derived from analytically evaluated real-world structural cases, considering key parameters such as distributed load, span length, moment of inertia, and Young's modulus. The results show that the proposed approach effectively classifies floor systems according to their vibration susceptibility. The method provides an efficient, robust, and computationally low-cost tool that can support structural analysis and design, contributing to improved serviceability, comfort, and structural safety in lightweight floor systems.

Keywords: Vibrations, resonance, neural network, statistical, natural frequency.

*Autor para la correspondencia: re454227@uaeh.edu.mx

Correo electrónico: la380223@uaeh.edu.mx (Luis Fernando Lara Gamez), omar_caballero@uaeh.edu.mx (Omar Caballero-Garatachea), cr233109@uaeh.edu.mx (José Manuel Cruz Olguín), virgilio@uaeh.edu.mx (Virgilio López-Morales), manuel_ojeda@uaeh.edu.mx (Manuel Alejandro Ojeda-Misses), re454227@uaeh.edu.mx (Yamil Nathanael Resendiz Aguilar).

1. Introducción

La resonancia ocurre cuando la frecuencia de excitación y la frecuencia generada por el caminar de una persona coinciden con la frecuencia natural de la estructura, provocando una amplificación significativa de las vibraciones. Según el Instituto Americano de la Construcción del Acero (AISC, 2016), las personas son sensibles a las vibraciones de los pisos en un rango de 4 a 8 Hz, debido a la resonancia que desarrollan los sistemas de piso por el caminar humano. Las vibraciones en este intervalo suelen percibirse como molestas o incómodas, por lo que se recomienda que los pisos destinados a ocupaciones comunes tengan frecuencias naturales superiores a 8 Hz para mejorar la comodidad de los ocupantes.

La evaluación de vibraciones se realiza mediante el cálculo de la frecuencia natural del sistema y la aceleración inducida por cargas dinámicas. Para controlar vibraciones no deseadas, se pueden implementar estrategias como aumentar la rigidez, adicionar masa o incorporar dispositivos de amortiguamiento (AISC, 2016). Sin embargo, el estudio de las vibraciones en pisos requiere modelos analíticos o numéricos complejos, generalmente costosos en términos computacionales, lo que limita su aplicación en las etapas de diseño preliminar. Por ello, resulta necesario desarrollar herramientas que simplifiquen la estimación de la respuesta vibratoria sin comprometer la precisión, facilitando la toma de decisiones por parte del ingeniero estructural.

En este contexto, el presente trabajo propone el desarrollo de una red neuronal artificial capaz de clasificar vigas y losas según su frecuencia natural, determinando si se encuentran en condiciones de resonancia frente a frecuencias típicas generadas por el paso humano. Este enfoque combina el análisis estructural tradicional con técnicas de inteligencia artificial, permitiendo detectar automáticamente condiciones críticas de vibración y contribuyendo a un diseño más seguro y eficiente de las estructuras.

Es importante mencionar, que las redes neuronales (Luttrell, 2009) emplean algoritmos de aprendizaje mediante el cual las redes son capaces de ajustar los pesos sinápticos y los sesgos para aprender, controlar, clasificar, entre otros. Entre los algoritmos (Goodfellow *et al.*, 2016) más empleados está el algoritmo de retropropagación (Malinowski y Zurada, 2012), (Ismail y Zainuddin, 2023) también llamado *backpropagation* combinando algoritmo de optimización como el gradiente descendente y variaciones como el algoritmo Adam, los algoritmos estocásticos, el algoritmo RMSProp y otros (Ojeda *et al.*, 2019), (Madan, 2023); que permiten la minimización de una función de costo. Por otro lado, existen otros enfoques basados algoritmos hebbianos, algoritmos competitivos, algoritmo estadísticos y probabilísticos como el bayesiano, así como técnicas adaptativas, técnicas basadas en la normalización del error (Bishop, 2006), (Hayat *et al.*, 2016), (Singht y Banerjee, 2019) (Du *et al.*, 2022) y derivadas del error como el algoritmo de Levenberg-Marquardt (Baruch *et al.*, 2017).

Una vez presentados los algoritmos de aprendizaje más empleados en la literatura. El algoritmo estadístico presentado en este trabajo, usado para el aprendizaje de la red neuronal que permite la clasificación, se entrena mediante un proceso de muestreo estadístico que normaliza el error entre las frecuencias reales y estimadas. Se asume según el Teorema Central del Límite, que la distribución de dicho error tiende a

una distribución normal (Cruz *et al.*, 2025). Esto permite ajustar los pesos sinápticos mediante una función de mapeo, sin necesidad de utilizar el gradiente descendente. Los datos para entrenamiento y validación están basados en ejemplos reales analíticamente, a partir de variables estructurales como longitud, carga distribuida, módulo de Young y momento de inercia. Los resultados validan que el algoritmo clasifica con precisión el nivel de susceptibilidad de los sistemas de piso en función de su frecuencia natural obteniendo una herramienta eficiente y de bajo costo computacional para el análisis estructural orientado al confort y la seguridad del usuario.

2. Estado del arte

Las redes neuronales artificiales han sido ampliamente utilizadas como herramientas capaces de modelar, predecir, clasificar, identificar y controlar sistemas complejos, especialmente aquellos que resultan difíciles de describir y analizar mediante métodos tradicionales. Su principal fortaleza radica en la capacidad de aprender a partir de datos de entrenamiento mediante algoritmos específicos, lo que les permite adaptarse y generalizar ante nuevas situaciones.

Estas redes están inspiradas en el funcionamiento del cerebro humano, el cual está conformado por miles de neuronas interconectadas a través de sinapsis que actúan de manera coordinada para realizar tareas como la percepción, la memoria y el control del movimiento (Sánchez Camperos y Alanís García, 2006). A partir de esta analogía biológica, las redes neuronales artificiales han sido formuladas mediante modelos matemáticos que permiten aproximar el comportamiento de sistemas reales y resolver problemas de alta complejidad.

Su implementación ha dado lugar a modelos inteligentes y adaptativos que ofrecen resultados eficientes y con altos niveles de precisión, evaluados mediante métricas cuantitativas. Además, en muchos casos reducen significativamente el tiempo de cómputo y constituyen una alternativa viable y robusta para el modelado de sistemas dinámicos y no lineales.

En comparación con los métodos tradicionales de análisis, las redes neuronales artificiales presentan ventajas importantes. Entre ellas destacan su capacidad de aprendizaje no supervisado, su funcionamiento automatizado y, especialmente, el uso de funciones de activación no lineales. Estas funciones permiten capturar relaciones complejas entre las variables de entrada y salida, lo cual resulta fundamental en sistemas donde la dinámica no es lineal.

Esta característica es particularmente relevante en el estudio de sistemas estructurales, como vigas y losas, cuyas respuestas dependen de múltiples parámetros físicos y geométricos. En estos casos, el desempeño del modelo neuronal está influenciado tanto por la arquitectura de la red como por el algoritmo de aprendizaje empleado, lo que permite ajustar el modelo para obtener representaciones precisas del comportamiento estructural bajo diferentes condiciones.

Estudios presentados han explorado el uso de las redes neuronales aplicadas en el estudio de las vigas y las losas estructurales (Mansour *et al.*, 2004). En Couto, (2022) se presenta un estudio sobre momentos críticos de pandeo en vigas uniformes y ahusadas, entrenó una red neuronal con más de 60,000 muestras obtenidas mediante elementos finitos, revelando que las redes podían igualar o superar la precisión

de las fórmulas existentes, además, permiten realizar una evaluación rápida en etapas tempranas de diseño. De forma similar, en Zhang y Xue, (2024) se hace uso de redes neuronales para el diseño mecánico de vigas, donde numerosas simulaciones basadas en elementos finitos se usaron para predecir parámetros como rigidez inicial, absorción de energía y comportamiento de rigidez negativa. Estos modelos basados en datos resultaron valiosos para explorar amplios espacios paramétricos y optimizar diseños con capacidad de absorción de energía. No obstante, tales métodos dependían en gran medida de los datos de elementos finitos y eran deterministas, careciendo por tanto de información sobre la incertidumbre o la confianza de las predicciones.

Por otro lado, en Trinh *et al.*, (2024) presentaron redes neuronales informadas por la física (PINN, por sus siglas en inglés) aplicadas a vigas delgadas de material con gradiente funcional, aprovechando formulaciones basadas en energía para asegurar predicciones físicamente coherentes de desplazamiento y torsión, al tiempo que se reduce la dependencia de grandes conjuntos de datos. De igual forma, en Schommartz *et al.*, (2025) presentaron modelos neuronales aumentados con física para vigas hiperelásticas geoméricamente exactas incorporando restricciones mecánicas, simetría y consistencia termodinámica directamente en la arquitectura neuronal, generando modelos que respetan las leyes físicas fundamentales desde su construcción. Estos estudios marcan una transición hacia paradigmas de aprendizaje híbrido que combinan principios basados en datos y en la física. Sin embargo, los enfoques PINN y los modelos aumentados con física suelen requerir implementaciones complejas y una sintonización computacional extensa, y aún rara vez cuantifican explícitamente la incertidumbre en las predicciones.

Posteriormente, en De Carvalho *et al.*, (2024) presentaron una investigación sobre vigas tipo I de acero inoxidable para modelos basados en redes neuronales entrenados con casi diez mil simulaciones de elementos finitos, donde podían capturar eficazmente la estabilidad global y las interacciones de falla. La herramienta computacional resultante ilustró el potencial de los modelos sustitutos basados en redes neuronales para el diseño ingenieril práctico.

Una vez presentados estudios previos donde se hace uso de las redes neuronales como herramientas computacionales para el modelado, la predicción y el estudio estructural de vigas y losas. La mayoría de los métodos y técnicas están basadas en enfoques deterministas, y en muchos casos hacen uso de volúmenes de datos (Avcar *et al.*, 2015), (Kaczmarek y Szymańska, 2016). Por ende, en este artículo se propone un algoritmo estadístico trabajo aplicado a una red neuronal multicapa capaz de clasificar las frecuencias en vigas y losas, con el fin de determinar si se están en resonancia. En otras palabras, determinar cuándo las frecuencias naturales coinciden con las frecuencias inducidas por el paso humano. Este artículo combina el análisis estructural tradicional con enfoques de inteligencia artificial, para identificar automáticamente condiciones de vibración y contribuir en un diseño seguro y eficiente de vigas y losas.

Este artículo parte de la suposición de que los datos de las vigas y las losas están instrumentadas mediante sensores, cámaras y el equipo necesario, que permiten obtener los parámetros de la viga como perfil, pesos, frecuencias, entre otros parámetros en tiempo real. La suposición anterior,

permitirá llevar a cabo el entrenamiento de redes neuronales mediante el algoritmo estadístico presentado. El algoritmo se basa en un proceso de muestreo que normaliza el error entre las frecuencias reales y las estimadas aplicando el Teorema Central del Límite y considera que convergen a una distribución normal, lo que permite ajustar los pesos sinápticos mediante una función de mapeo sin recurrir al método del gradiente descendente. Los datos de entrenamiento se basan en estudios reales y la validación se realiza a partir de variables estructurales representativas como longitud, carga distribuida, módulo de Young y momento de inercia.

Los resultados obtenidos muestran que el algoritmo propuesto es capaz de clasificar de manera automática los sistemas de piso según su nivel de susceptibilidad ante vibraciones excesivas constituyendo una herramienta eficiente, automática y de bajo costo computacional para el análisis y diseño estructural orientado al confort y la seguridad del usuario. Este trabajo se basa en tres temas principales. Primero, la parte teórica sobre las vigas y las losas simplemente apoyadas con carga distribuida; segundo, la parte teórica de las losas simplemente apoyadas; y finalmente, la estimación de las frecuencias naturales, que serán utilizadas por la red neuronal multicapa con el algoritmo de aprendizaje estadístico para clasificar las vigas en resonancia.

3. Estudios preliminares

3.1 Estudios preliminares en vigas

La Figura 1 ilustra el comportamiento típico de una viga, en la parte superior se muestra la viga sin carga y en la inferior, la deformación bajo carga distribuida, siendo máxima en el centro y mínima en los apoyos (González, 2014).




Figura 1. Estado no deformado (superior) y deformado de una viga bajo carga uniforme (inferior).

El procedimiento empleado se basa en la teoría clásica de vigas y en correlaciones experimentales obtenidas para materiales como el concreto reforzado (Murray, *et al.*, 2009), (Allen, 2012), (Allen & Murray, 1993), (Allen, *et al.*, 1987), (Amick, *et al.*, 2005). Para este tipo de análisis, se consideran factores como el módulo de elasticidad del material, el momento de inercia de la sección transversal, la longitud del claro y la carga distribuida equivalente al peso propio del elemento. Para determinar la frecuencia natural de una viga simplemente apoyada se emplea la siguiente expresión:

$$f_n = 0.18 \sqrt{\frac{g}{L}} \quad (1)$$

donde f_n es la frecuencia natural (Hz), g es dada como la aceleración de la gravedad (9.81 m/s^2) y Δ es la deflexión máxima de la viga. La deflexión máxima para una viga simplemente apoyada sometida a una carga distribuida uniforme se obtiene mediante:

$$\Delta = \frac{(5wL^4)}{(384EI)} \quad (2)$$

donde w es la carga distribuida (ton/m), L es dada como la longitud de la viga (m), E es el módulo de elasticidad del material (ton/m²) y I es el momento de inercia de la sección (m⁴). Es importante mencionar que la carga distribuida w se define en términos de los parámetros de inercia para una viga rectangular como:

$$w = 2.4 \frac{\text{ton}}{\text{m}^3}(b)(h) \quad (3)$$

siendo b la base y h la altura de la sección transversal en metros. Por otro lado, el coeficiente 2.4 es una constante que aproxima el peso del concreto reforzado por metro cúbico, considerando una densidad promedio de 2400 kg/m^3 equivalente a 2.4 ton/m^3 . Asimismo, el momento de inercia para una sección rectangular es determinado como:

$$I = \frac{(b)(h)^3}{12} \quad (4)$$

Por otra parte, con base en las normas técnicas complementarias para diseño y construcción de estructuras de concreto (Secretaría de Obras y Servicios de la Ciudad de México, 2023) el módulo de elasticidad del concreto se calcula mediante la expresión:

$$E = 14000\sqrt{fc} \quad (5)$$

donde fc es la resistencia a la compresión del concreto en kg/cm^2 . El factor 14000 proviene de correlaciones experimentales entre el módulo de elasticidad y la resistencia del concreto en unidades del sistema técnico (kg/cm^2).

A partir de las expresiones teóricas presentadas anteriormente, se presenta un ejemplo analítico para una viga. Por lo cual, considere una viga de concreto simplemente apoyada con los siguientes datos: $L = 10 \text{ m}$, $fc = 250 \text{ kg/cm}^2$, $b = 0.30 \text{ m}$, $h = 0.40 \text{ m}$, con estos datos es calculado el módulo de elasticidad como:

$$\begin{aligned} E &= 14000\sqrt{250} \\ &= 221359.4362 \frac{\text{kg}}{\text{cm}^2} = 2213594.362 \frac{\text{ton}}{\text{m}^2} \end{aligned} \quad (6)$$

estimando la carga se tiene

$$w = 2.4(0.30)(0.40) = 0.288 \frac{\text{ton}}{\text{m}^2} \quad (7)$$

Asimismo, estimando el momento de inercia se tiene:

$$I = \frac{(0.30)(0.40)^3}{12} = 0.0016 \text{ m}^4 \quad (8)$$

Calculando la deflexión máxima se tiene:

$$\Delta = \frac{5(0.288)(10)^4}{384(2213594.362)(0.0016)} = 0.010587983 \text{ m} \quad (9)$$

Finalmente, se obtiene la frecuencia natural para la viga presentada:

$$fn = 0.18 \sqrt{\frac{9.81}{0.010587983}} = 5.4789 \text{ Hz} \quad (10)$$

Los resultados obtenidos sirven como base para definir la entrada de la red neuronal multicapa entrenada con un algoritmo de aprendizaje estadístico. Esta red tiene como objetivo clasificar las vigas y las losas según su frecuencia identificando aquellas que se encuentran en condiciones de resonancia o cercas a ella, de esta manera se integra la herramienta de inteligencia artificial para identificar y evaluar el comportamiento vibratorio de elementos estructurales.

3.2 Estudios preliminares en losas

En este estudio se parte de una losa simplemente apoyada de dimensiones $L \times B$, con un módulo de elasticidad E , relación de posición v y una densidad de carga W . Primero, se define la relación

$$\lambda = \frac{L}{B} \quad (11)$$

En conjunto, con un coeficiente que depende de esta relación dado como:

$$\alpha = 1.57(1 + \lambda^2) \quad (12)$$

donde el parámetro α representa la influencia geométrica de la losa sobre su rigidez, cuando mayor es la relación de aspecto mayor será la rigidez en una dirección.

En consecuente, es importante considerar el espesor de la losa definido como t , éste se calcula mediante una expresión empírica utilizada comúnmente en diseño estructural de losas de concreto dado como:

$$t = \frac{L}{33} + 25 \text{ mm} \quad (13)$$

donde el término $L/33$ proviene de recomendaciones de diseño que limita la esbeltez del elemento para controlar las deflexiones mientras que los 25 mm adicionales corresponden al espesor mínimo requerido para recubrimiento del esfuerzo y durabilidad. Por otro lado, el peso superficial o la carga de la losa se determina mediante la expresión:

$$W = 2.4(t) + w_2 \quad (14)$$

donde 2.4 representa el peso específico del concreto armado en (ton/m^3) y w_2 es una carga adicional en (ton/m^3). Para la masa equivalente M se obtiene dividiendo la carga w entre la gravedad g :

$$M = \frac{w}{g} \quad (15)$$

En cuanto a la rigidez está dada por el producto del módulo de elasticidad y el cubo del espesor mientras que el denominador incorpora los efectos de la masa:

$$a = \frac{Et^3}{12M(1-\nu^2)}. \quad (16)$$

Posteriormente, la frecuencia ante vibraciones se obtiene mediante la siguiente fórmula para losas:

$$f = \frac{\alpha}{L^2} \sqrt{\frac{Et^3}{12M(1-\nu^2)}}. \quad (17)$$

A continuación, se presenta un ejemplo analítico considerando una losa de 6 m x 6 m. Primero se calculó el parámetro:

$$\alpha = 1.57(1 + 1^2m) = 3.14 \quad (18)$$

y considerando la longitud de la losa $L = 6m$ y el módulo de elasticidad para el concreto $E = 2,213594.362 \frac{\text{ton}}{m}$ se calcula:

$$h = \frac{6}{33} + 25mm = 206.88mm \quad (19)$$

Así la altura es aproximada como $20.68cm \approx 0.21m$. Por lo que, calculando la masa equivalente M y la carga w se tiene:

$$w = 2.4(0.21m) = 0.504 \frac{\text{ton}}{m^2} \quad (20)$$

así

$$M = \frac{0.504 \frac{\text{ton}}{m^2}}{9.81m/s^2} = 0.0513 \frac{\text{tons}^2}{m^2} \quad (21)$$

Finalmente, la frecuencia natural para la losa es dada como:

$$fn = \frac{3.14}{6^2} \sqrt{\frac{(2213594.362 \frac{\text{ton}}{m^2})(0.21m)^3}{12(0.0513 \frac{\text{ton}}{m^2})(1 - 0.2^2)}} \quad (22)$$

$$fn = 16.24501764 \text{ Hz}$$

Una vez presentados los principios teóricos empleados en este artículo, a continuación, se presenta el algoritmo de aprendizaje estadístico para la red neuronal presentada.

4. Metodología

4.1 Algoritmo de aprendizaje estadístico

Por otro lado, el algoritmo de aprendizaje empleado en este trabajo es la propuesta de un algoritmo estadístico, que se emplea en la red considerando que el error $e_j^{(l)}(k)$ está definido como la diferencia entre la entrada $y_j(k)$ y salida $\hat{y}_j^{(l)}(k)$ predicha por la red neuronal, esto es:

$$e_j^{(l)}(k) = y_j(k) - \hat{y}_j^{(l)}(k) \quad (23)$$

El objetivo del entrenamiento de la red neuronal es que, a medida que el modelo se entrena, la salida $\hat{y}_j^{(l)}(k)$ converja al

valor deseado $y_j(k)$. En términos del error $e_j^{(l)}(k)$ tiende a cero cuando el tiempo tiende a infinito.

Este algoritmo está basado en la teoría del muestreo (Ojeda et al., 2024) como un conjunto de un universo, tiene como objetivo ajustar de manera adaptable los parámetros de la red neuronal con el fin de ser entrenados y generalizados. A diferencia de otros algoritmos y métodos usados para el aprendizaje de las redes neuronales, el algoritmo estadístico presentado en este trabajo usa conceptos estadísticos y probabilísticos como el Teorema Central del Límite, la media, la desviación estándar, la distribución normal y la probabilidad para ajustar los pesos sinápticos y los sesgos mediante una función matemática, llamada función de mapeo.

La red neuronal usa datos muestrales obtenidos de la salida del sistema esenciales para el entrenamiento, pero también permiten para calcular el error, validar y evaluar el desempeño del aprendizaje, e incluso obtener la generalización en el aprendizaje. Además, un preprocesamiento adecuado de estos datos mejora la eficiencia del aprendizaje, reduce errores y optimiza el desempeño general.

En este artículo se usa una red neuronal perceptrón multicapa con una capa de entrada, una capa oculta y una capa salida, como se puede observar en la Figura 2.




Figura 2. Red perceptrón multicapa.

A diferencia de los enfoques tradicionales, este algoritmo de aprendizaje se basa en probabilidad del error $e_j^{(l)}(k)$ que actúa como un mecanismo de ajuste. El objetivo es realizar los ajustes pertinentes al vector de pesos sinápticos $W_{ji}^{(l)}(k)$ en las neuronas de cada capa. En este caso, no se emplea directamente el error, sino la probabilidad de error $P_j^{(l)}(k)$ dado por la distribución normal, que permite medir qué tan probable es que la neurona j de la capa de salida haya contribuido en el error y así ajustar los pesos y sesgos mediante funciones de mapeo. El índice de desempeño es definido como:

$$J(k) = \frac{1}{2} \sum_{j=1}^L (e_j^{(L)})^2 \quad (24)$$

donde L es el número de neuronas en la capa de salida y $e_j^{(L)}$ es definido como el error.

El algoritmo estadístico está basado en el Teorema del Límite Central (TLC), que establece que, con muestras suficientemente grandes la distribución de la media muestral se aproxima a una normal, sin importar la distribución original (Oakland y Oakland, 2024). Esto permite estimar probabilidades sobre la media usando la distribución normal,

útil para intervalos de confianza y pruebas de hipótesis. El algoritmo propuesto aplica estos conceptos tomando muestras de la salida de la red neuronal y calculando su media y desviación estándar.

$$\bar{y}_j(k) = \frac{\hat{y}_1^{(L)}(k) + \hat{y}_2^{(L)}(k) + \dots + \hat{y}_n^{(L)}(k)}{n} \quad (25)$$

Para las primeras n muestras se considera que los promedios muestrales convergen y, por lo tanto, convergen en probabilidad al valor esperado $\hat{y}_j(k)$ cuando $n \rightarrow \infty$. Sin embargo, debe tenerse en cuenta que, mientras mayor sea el número de muestras más refinados y detallados serán los resultados estadísticos. Posteriormente, se obtiene la desviación estándar utilizando los datos de la ecuación (25):

$$\sigma_j(k) = \sqrt{\frac{\sum_{j=1}^n (\hat{y}_j(k) - \bar{y}_j(k))^2}{n}} \quad (26)$$

A continuación, se utiliza el TLC, el cual ayudará a determinar la forma de la distribución muestral de los datos obtenidos:

$$z_j(k) = \frac{y_j(k) - \bar{y}_j(k)}{\sigma_j(k) + \varepsilon} \quad (27)$$

donde $y_j(k)$ es la salida del sistema y $\bar{y}_j(k)$ es la media estimada de los datos $\hat{y}_n^{(L)}(k)$ estimados en la salida de la red neuronal, la diferencia $y_j(k) - \bar{y}_j(k)$ es definido como el error $e_j^{(L)}(k)$ y $\sigma_j(k)$ es la desviación estándar. En el contexto del TLC, $z_j(k)$ es un valor estandarizado que indica cuántas desviaciones estándar se encuentra una media muestral con respecto a la media poblacional (Ojeda-Misses et al., 2025).

Esto permite utilizar la distribución normal estándar para calcular probabilidades, incluso cuando los datos provienen de una distribución no normal (Anderson et al., 2008; Ojeda-Misses et al., 2024). Una vez estimada $z_j(k)$, la probabilidad es:

$$P_j^{(L)}(k) = \Phi(z_j(k)) \quad (28)$$

donde $\Phi(k)$ es la función de distribución acumulada (FDA) de la distribución normal estándar. En términos de cálculo, la probabilidad acumulada se expresa como:

$$\Phi(z_j(k)) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt \quad (29)$$

La función probabilística expresa la probabilidad de que una variable adopte un valor particular, mientras que la función de distribución muestra la probabilidad acumulada hasta un cierto valor. En el ajuste de pesos de la red neuronal, se emplean funciones de activación como la sigmoide y la tangente hiperbólica:

$$\Delta b_j^{(L+1)} = f(P_j^{(L)}(k)) = \frac{L}{1 + e^{-\alpha P_j^{(L)}(k)}} \quad (30)$$

$$\Delta W_{ji}^{(L+1)} = f(P_j^{(L)}(k)) = \frac{e^{P_j^{(L)}(k)} - e^{-P_j^{(L)}(k)}}{e^{P_j^{(L)}(k)} + e^{-P_j^{(L)}(k)}} \quad (31)$$

donde ambas funciones están en función de la probabilidad $P_j^{(L)}(k)$. Estas funciones permiten aplicar el entrenamiento a la red neuronal mediante el algoritmo estadístico basado en datos y distribución probabilística. Finalmente, los pesos y sesgos son actualizados como:

$$b_j^{(L)} \leftarrow b_j^{(L)} + \eta \Delta b_j^{(L+1)} \quad (32)$$

$$\Delta W_{ji}^{(L)} \leftarrow W_{ji}^{(L)} \eta \Delta W_{ji}^{(L+1)} \quad (33)$$

Una vez presentado el algoritmo, ahora se presenta la red neuronal donde es aplicado.

4.2 Red neuronal multicapa con algoritmo estadístico

La red neuronal empleada para la clasificación está basada en una multicapa, donde los datos de entrada están dados por el vector $y_i(k) \in \mathbb{R}^{N \times n_0}$ donde N son las muestras y n_0 el número de entradas, las capas son determinadas por $l = 1, \dots, L$ para las capas ocultas y $L + 1$ para la capa de salida. Para cada capa l se calcula:

$$v^{(1)}(k) = \sum_{i=0}^p w_{1i}(k) y_i(k) + b^{(1)}(k) \quad (34)$$

$$a^{(1)}(k) = \phi(v^{(1)}(k)) \quad (35)$$

En forma general para $l = 2, \dots, L$

$$v^{(l)}(k) = \sum_{i=0}^p w_{li}(k) a^{(l-1)}(k) + b^{(l)}(k)$$

$$a^{(l)}(k) = \phi(v^{(l)}(k)) \quad (36)$$

La capa de salida $L + 1$:

$$v^{(L+1)}(k) = \sum_{i=0}^p w_{L+1,i}(k) a^{(L)}(k) + b^{(L+1)}(k)$$

$$\hat{y}(k) = f(v^{(L+1)}(k)) \quad (37)$$

Aquí es aplicado el algoritmo de aprendizaje estadístico, que se basa en calcular el error

$$e(k) = y(k) - \hat{y}(k) \quad (38)$$

Posteriormente, se estima la desviación estándar:

$$\sigma_e(k) = \sqrt{\frac{1}{N} \sum_{i=1}^N e_i^2} \quad (39)$$

Empleando la normalización se tiene:

$$z_e(k) = \frac{e(k)}{\sigma_e(k) + \delta} \quad (40)$$

donde es agregado un δ pequeño que evita la divisibilidad entre cero. Posteriormente, se estima la distribución normal:

$$P_e(k) = \Phi(z_e(k)) \quad (41)$$

y se realiza un ajuste por muestra de manera que:

$$\Delta(k) = k(P_e(k) - 0.5) \quad (42)$$

Si $|P_e - 0.5| \leq \varepsilon$ no se realiza ningún ajuste, en caso contrario, si $\Delta_i^{(L+1)} > 0$ indica que la salida debe ser ajustada positivamente y $\Delta_i^{(L+1)} < 0$ lo contrario.

La actualización de la capa de salida se realiza para los pesos como:

$$\Delta w^{(L+1)} = (a^{(L)})^T \Delta^{(L+1)} \quad (43)$$

Mientras que para el sesgo se tiene:

$$\Delta b^{(L+1)} = \sum_{i=1}^N \Delta_i^{(L+1)} \quad (44)$$

que ayudan a actualizar los pesos sinápticos y el sesgo:

$$w^{(L+1)}(k+1) = w^{(L+1)}(k) + \Delta w^{(L+1)} \quad (45)$$

$$b^{(L+1)}(k+1) = b^{(L+1)}(k) + \Delta b^{(L+1)} \quad (46)$$

Para las capas anteriores se realiza un ajuste mediante una señal de error en la capa l como $\tau^{(l)}(k)$ y permite definir para la capa de salida:

$$\tau^{(L+1)}(k) = \Delta^{(L+1)}(k) \quad (47)$$

Considerando la propagación hacia atrás $l = L, L-1, \dots, 1$ se tiene:

$$\tilde{\tau}^{(l)}(k) = \tau^{(l+1)}(k)(w^{(l+1)}(k))^T \quad (48)$$

$$\tau^{(l)}(k) = \tilde{\tau}^{(l)}(k) \cdot \phi(z^{(l)}) \quad (49)$$

Así las actualizaciones son determinadas como:

$$\Delta w^{(l)} = (a^{(l-1)})^T \tau^{(l)} + \delta^{(l)} \quad (50)$$

$$\Delta b^{(l)} = \sum_{i=1}^N \delta_i^{(l)} \quad (51)$$

Posteriormente se tiene:

$$w^{(l)}(k+1) = w^{(l)}(k) + \Delta w^{(l)} \quad (52)$$

$$b^{(l)}(k+1) = b^{(l)}(k) + \Delta b^{(l)} \quad (53)$$

Una vez presentado el algoritmo y la arquitectura de la red neuronal, a continuación, son presentados los resultados obtenidos con el algoritmo estadístico usando una red neuronal multicapa para la clasificación de vigas y losas en resonancia, dada entre 4 y 8 Hz.

5. Resultados

En este estudio se analizaron 45 vigas de concreto con diferentes características geométricas y cargas aplicadas. Cada

viga se describe mediante su nombre, longitud, base y altura de la sección transversal, módulo de elasticidad del material y carga distribuida adicional. Los datos se diseñaron de manera heterogénea para representar distintos escenarios de diseño estructural, permitiendo simular condiciones reales de construcción y cargas variables.

5.1 Aplicación con vigas

El conjunto de datos analizado corresponde a un estudio comparativo de 45 vigas simplemente apoyadas, en el cual se consideran distintas combinaciones de parámetros geométricos, propiedades del material y cargas externas. El objetivo principal es calcular la frecuencia natural de vibración de cada viga y analizar cómo influyen sus dimensiones y condiciones de carga sobre el comportamiento dinámico.

Cada viga se caracteriza por su longitud L , base b , altura h , módulo de elasticidad E y una carga adicional w_2 . La longitud varía entre 10, 11 y 12 metros, mientras que la base se mantiene constante en 0.30 metros. La altura cambia entre 0.40 y 0.90 metros, permitiendo evaluar el efecto de la esbeltez estructural. El módulo de elasticidad se fija en $E = 2,213,594.362$ Pa, correspondiente a un material con rigidez similar al concreto. Por último, la carga w_2 , expresada en toneladas por metro, introduce diferencias en el peso total de cada viga, afectando su deformación y, por consiguiente, su frecuencia de vibración.

Lo que permite identificar si podrán entrar en la zona crítica de resonancia, definida entre 4 y 8 Hz, esto proporciona una herramienta para la evaluación de seguridad estructural y complementa los ensayos experimentales.

En la Figura 3 se presenta la clasificación de las vigas con base en la relación longitud y frecuencia natural. Donde se muestra una tendencia coherente con los principios clásicos de la dinámica estructural: a mayor longitud, la frecuencia disminuye debido al incremento en la flexibilidad global del elemento. La gráfica evidencia una clara estratificación entre vigas cortas, medianas y largas, lo que facilita establecer umbrales para clasificar elementos estructurales susceptibles a resonancia bajo cargas inducidas por actividades humanas.

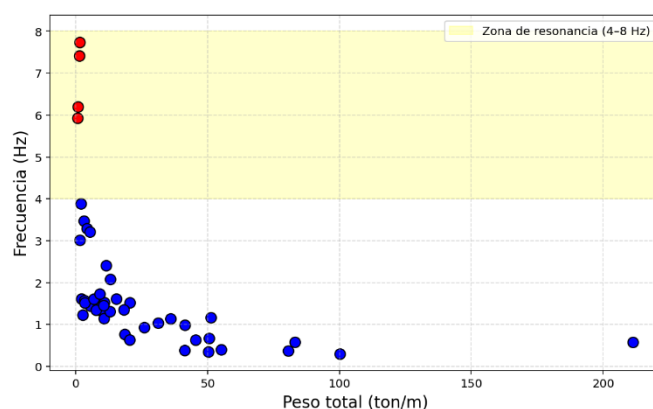


Figura 3. Clasificación de las vigas con la relación peso–frecuencia.

Resulta relevante observar que las vigas de longitud intermedia presentan la mayor dispersión de frecuencias, lo cual sugiere variaciones importantes en las propiedades geométricas y/o en el módulo de elasticidad utilizadas durante el diseño.

Por otro lado, en la Figura 4 se presentan los resultados para la clasificación considerando la relación peso-frecuencia. Aquí puede observarse que las estructuras más pesadas tienden a presentar una reducción marcada en su capacidad vibratoria. La distribución muestra que, aunque existe una tendencia general bien definida, ciertos casos se apartan ligeramente de la curva principal, posiblemente debido a diferencias en la rigidez o en la forma del perfil estructural.

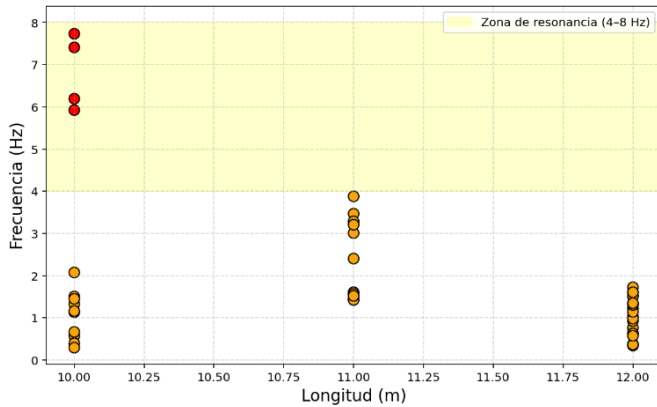


Figura 4. Clasificación de las vigas mediante la relación longitud-frecuencia.

Por otro lado, en la Figura 5 es mostrada la clasificación de vigas según su frecuencia natural evidencia que distintos tipos de sección presentan comportamientos dinámicos distintivos. Las vigas más robustas, con mayor momento de inercia, tienden a ubicarse en rangos de frecuencia más elevados, mientras que los perfiles más esbeltos se concentran en zonas de baja frecuencia.

Este contraste permite identificar rápidamente cuáles vigas podrían entrar en resonancia ante cargas rítmicas típicas de ocupación humana. Además, la clasificación presentada está en función de la geometría del perfil, que influye tanto como la longitud y el peso, lo cual valida la pertinencia de utilizar criterios multivariable dentro del algoritmo presentado y evita diagnósticos basados únicamente en un parámetro estructural.




Figura 5. Clasificación de las vigas mediante la relación viga-frecuencia.

En general, se pueden realizar clasificaciones múltiples, es decir, en función de las variables estructurales que se deseen permitiendo una evaluación holística de las vigas (ver Figura 6). El gráfico demuestra que los criterios combinados de longitud, peso y rigidez ofrecen un mecanismo robusto para identificar elementos con alto riesgo de presentar frecuencias coincidentes con excitaciones humanas.




Figura 6. Clasificación general de las vigas asignando 1 y -1.

El agrupamiento visible en categorías bien definidas indica que el algoritmo presentado funciona con consistencia y produce separaciones claras entre niveles de desempeño estructural. Este enfoque multidimensional mejora significativamente la capacidad diagnóstica respecto a métodos que solo considerando parámetros aislados.

Finalmente, en la Figura 7 es presentado el Error Cuadrático Medio (ECM), que muestra la capacidad del modelo para ajustarse adecuadamente a los datos estructurales analizados. La tendencia descendente del ECM valida que el proceso de clasificación converge y que el algoritmo logra distinguir correctamente entre las distintas categorías estructurales.

Un ECM bajo respalda la fiabilidad del método para ser utilizado como herramienta de apoyo en el análisis preliminar de vibraciones en pisos. Además, la estabilidad observada hacia las últimas iteraciones sugiere que el modelo no presenta sobreajuste, lo que mejora su potencial de generalización hacia otros conjuntos de vigas y condiciones geométricas.




Figura 7. Error Cuadrático Medio (ECM) del proceso de clasificación con la red neuronal.

5.2 Aplicación con vigas agregando recomendaciones

Como complemento, se desarrolló un programa basado en el análisis previo, con el objetivo de generar recomendaciones para sacar de la zona de resonancia (4 a 8 Hz) a un conjunto de 33 vigas de concreto (ver Figura 8).

Para cada viga, primero se calculó su frecuencia natural a partir de sus dimensiones geométricas y de las propiedades del material. Una vez obtenida la frecuencia se comparó con el rango de resonancia. Las vigas con cuyas frecuencias se ubicaron fuera del intervalo se clasificaron de inmediato como adecuadas, ya que no presentan un riesgo significativo dentro de los parámetros del estudio, tal como se observa a continuación.

En el caso de las vigas (ver Figura 8) que sí se encontraron dentro del rango crítico de 4 a 8 Hz, se aplicó una etapa adicional de análisis. Esta consistió en simular cómo cambia la frecuencia natural al modificar el valor de la carga distribuida

variable w_2 (carga adicional al peso propio). Para ello se probó un conjunto amplio de valores posibles de w_2 y se recalculó la frecuencia correspondiente a cada uno. De esta manera, fue posible identificar hacia qué dirección (aumentar o disminuir la frecuencia) resultaba más efectivo desplazar la respuesta dinámica de la viga.

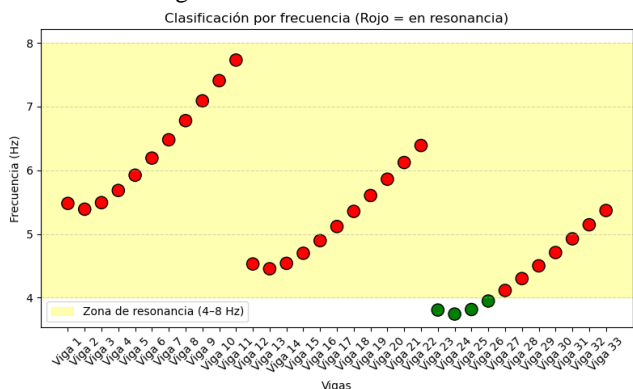


Figura 8. Clasificación de 33 vigas en función de su frecuencia, indicando la zona de resonancia (4-8 Hz).

Una vez determinados los valores de w_2 capaces de sacar a la viga del rango crítico, el algoritmo seleccionó automáticamente aquel que ofrecía la mejor separación respecto a los límites de resonancia. Es decir, en lugar de ubicar la frecuencia apenas fuera del intervalo, se eligió el ajuste que proporcionara un margen razonable de seguridad, reduciendo la posibilidad de que pequeñas variaciones en las cargas o condiciones reales devolvieran a la viga a la zona de riesgo.

En este sentido, para cada viga analizada se generó una recomendación clara: si la viga no presenta problemas, se indica que su frecuencia es adecuada; en caso contrario, se especifica el valor de w_2 que debe ajustarse y la nueva frecuencia estimada después del cambio. Toda esta información se integra, tal como se observa en la siguiente tabla, la cual permite visualizar de manera directa qué elementos requieren intervención y cuál es la forma más eficiente de corregirlos según el algoritmo propuesto (ver Figura 9).

Viga	Frecuencia (Hz)	Recomendación
Viga 1	5.479	△ Resonancia → W2=0.276, f=3.914 Hz
Viga 2	5.388	△ Resonancia → W2=0.452, f=3.982 Hz
Viga 3	5.491	△ Resonancia → W2=0.704, f=3.985 Hz
Viga 4	5.683	△ Resonancia → W2=1.030, f=3.970 Hz
Viga 5	5.922	△ Resonancia → W2=1.407, f=3.983 Hz
Viga 6	6.191	△ Resonancia → W2=1.859, f=3.993 Hz
Viga 7	6.478	△ Resonancia → W2=2.412, f=3.986 Hz
Viga 8	6.779	△ Resonancia → W2=3.040, f=3.990 Hz
Viga 9	7.09	△ Resonancia → W2=0.503, f=8.008 Hz
Viga 10	7.407	△ Resonancia → W2=4.598, f=3.990 Hz
Viga 11	7.73	△ Resonancia → W2=0.879, f=8.030 Hz
Viga 12	4.528	△ Resonancia → W2=0.101, f=3.899 Hz
Viga 13	4.453	△ Resonancia → W2=0.226, f=3.909 Hz
Viga 14	4.538	△ Resonancia → W2=0.377, f=3.956 Hz
Viga 15	4.696	△ Resonancia → W2=0.578, f=3.970 Hz
Viga 16	4.894	△ Resonancia → W2=0.829, f=3.975 Hz
Viga 17	5.116	△ Resonancia → W2=1.131, f=3.981 Hz
Viga 18	5.354	△ Resonancia → W2=1.482, f=3.991 Hz
Viga 19	5.603	△ Resonancia → W2=1.910, f=3.986 Hz
Viga 20	5.859	△ Resonancia → W2=2.387, f=3.993 Hz
Viga 21	6.122	△ Resonancia → W2=2.940, f=3.994 Hz
Viga 22	6.389	△ Resonancia → W2=0.402, f=8.004 Hz
Viga 23	3.805	✓ Frecuencia adecuada
Viga 24	3.742	✓ Frecuencia adecuada
Viga 25	3.813	✓ Frecuencia adecuada
Viga 26	3.946	✓ Frecuencia adecuada
Viga 27	4.113	△ Resonancia → W2=0.452, f=3.989 Hz
Viga 28	4.299	△ Resonancia → W2=0.653, f=3.994 Hz
Viga 29	4.499	△ Resonancia → W2=0.905, f=3.983 Hz
Viga 30	4.708	△ Resonancia → W2=1.181, f=3.996 Hz
Viga 31	4.923	△ Resonancia → W2=1.533, f=3.977 Hz
Viga 32	5.144	△ Resonancia → W2=1.910, f=3.983 Hz
Viga 33	5.368	△ Resonancia → W2=2.337, f=3.989 Hz

Figura 9. Recomendaciones dadas por la red neuronal para salir de la zona de resonancia con vigas.

Se puede observar en la Figura 9, que hay cuatro vigas en color verde que no entran en la zona de resonancia porque tienen una frecuencia adecuada, por lo tanto, las que si entran en el rango de los 4-8 Hz se pueden ver en rojo ya que están en resonancia, dicho programa nos da las recomendaciones adecuadas para subir o bajar del rango ajustando w_2 .

5.3 Aplicación con losas

Posteriormente, se desarrolló un programa basado en el análisis previo, ahora aplicado a losas, considerando un conjunto de 10 losas de concreto. El objetivo principal fue evaluar su comportamiento dinámico y proponer ajustes que permitieran alejarlas del rango de resonancia comprendido entre 4 y 8 Hz (ver Figura 10).

A continuación, para cada losa evaluada se emitió una recomendación específica en función de su frecuencia natural. Cuando la losa mostraba una frecuencia natural fuera del rango crítico, se indicaba directamente que su condición era adecuada. En los casos donde la frecuencia entraba en la zona de resonancia, el programa identificaba el valor de w_2 que debía modificarse y calculaba la nueva frecuencia estimada tras aplicar dicho ajuste.




Figura 10. Clasificación de losas entre 4 y 8 Hz.

Toda esta información fue organizada en la tabla correspondiente, permitiendo identificar de manera clara qué losas requieren intervención y cuál es el ajuste en w_2 más efectivo para corregir su frecuencia natural y salir de dicha zona de resonancia (ver Figura 11).

Losa	t (m)	w (ton/m ²)	f (Hz)	Recomendación
Losa 1	0.210	0.504	16.233	□ Adecuada
Losa 2	0.240	0.576	13.630	□ Adecuada
Losa 3	0.270	0.648	11.740	□ Adecuada
Losa 4	0.300	0.720	10.307	□ Adecuada
Losa 5	0.330	0.792	9.183	□ Adecuada
Losa 6	0.360	0.864	8.279	□ Adecuada
Losa 7	0.390	0.936	7.537	△ En resonancia
Losa 8	0.420	1.008	6.916	△ En resonancia
Losa 9	0.450	1.080	6.389	△ En resonancia
Losa 10	0.480	1.152	5.937	△ En resonancia

Figura 11. Recomendaciones dadas por la red neuronal para salir de la zona de resonancia con losas.

Se puede observar en la Figura 11, hay seis losas en color verde que no entran en la zona de resonancia porque tienen una frecuencia adecuada, por lo tanto, como en el programa anterior las losas en el rango de los 4-8 Hz se pueden ver en

rojo, así que nos da las recomendaciones adecuadas para subir o bajar del rango ajustando w_2 .

6. Discusión de resultados

Los resultados presentados permiten comprender con claridad la relación entre las propiedades geométricas y mecánicas de las vigas y su comportamiento dinámico frente a cargas inducidas por actividad humana. En la figura correspondiente a la longitud frente a la frecuencia natural, se observa una tendencia definida donde las vigas de menor longitud concentran las frecuencias más elevadas, mientras que las vigas más largas presentan frecuencias reducidas. La relación inversa observada coincide plenamente con los principios básicos de la teoría de vigas: a mayor longitud, mayor flexibilidad y, por lo tanto, menor frecuencia. Además, el patrón detectado muestra que solo un pequeño grupo de vigas se encuentra dentro del rango crítico de resonancia (4–8 Hz). Esto indica que las condiciones potencialmente peligrosas no aparecen de manera aleatoria, sino que dependen de configuraciones geométricas y mecánicas muy específicas.

La relación en el peso y la frecuencia de la viga es presentada en la segunda figura, donde la masa resulta ser un factor clave en la respuesta dinámica, es decir, las vigas más pesadas tienden a tener frecuencias naturales más bajas. Por otro lado, las vigas que sí entran en resonancia suelen ser relativamente ligeras pero rígidas, lo que las acerca al rango de excitación humana. Esto confirma que la resonancia en sistemas de piso no depende únicamente de la longitud o de la rigidez, sino del equilibrio entre masa y rigidez, que determina la frecuencia global del sistema.

En general, las frecuencias permiten apreciar la distribución general de ellas, es decir, la mayoría de las vigas se encuentra fuera del rango crítico, lo que sugiere un comportamiento estructural estable en términos dinámicos. Sin embargo, la presencia de un pequeño grupo dentro del intervalo crítico justifica la necesidad de metodologías predictivas automáticas, especialmente cuando se analizan catálogos más amplios de elementos estructurales.

Por otro lado, las figuras relacionadas con la clasificación mediante la red neuronal demuestran que el modelo puede diferenciar correctamente entre vigas seguras y vigas resonantes. El algoritmo asigna la categoría de riesgo únicamente a los casos que efectivamente se encuentran en el rango crítico, sin producir falsos positivos ni falsos negativos visibles. Esto evidencia que la red neuronal estimó correctamente las relaciones no lineales entre los parámetros de entrada y la resonancia, generando un espacio de decisión claro y confiable.

El análisis del error cuadrático medio confirma la eficiencia del entrenamiento. La rápida disminución del error en las primeras iteraciones, seguida de un ajuste fino hacia valores cercanos a cero, muestra que el modelo aprendió de manera eficiente la relación subyacente, sin indicios de sobreajuste. La suavidad de la curva y la ausencia de oscilaciones abruptas refuerzan que el entrenamiento se realizó de manera adecuada y con hiperparámetros bien seleccionados.

Esta aplicación computacional permite evaluar de forma rápida y eficiente el comportamiento vibratorio de losas de concreto, identificando aquellas que podrían entrar en resonancia y visualizando su respuesta estructural mediante

gráficos. Este análisis resulta especialmente útil en las etapas preliminares de diseño, cuando es necesario ajustar espesores o cargas para evitar problemas de vibración.

La versión final del programa permite el análisis de vigas y losas, permitiendo comparar sus frecuencias naturales bajo los mismos criterios. Esta versión automatiza el cálculo de frecuencias, la identificación de elementos dentro del rango de resonancia y la generación de recomendaciones para ajustar el parámetro de carga.

7. Conclusiones

Los resultados obtenidos confirman que las propiedades geométricas y mecánicas de los sistemas estructurales tipo viga y losa influyen de manera determinante en su comportamiento dinámico, particularmente en la frecuencia natural y en la susceptibilidad a fenómenos de resonancia inducidos por la actividad humana. Los análisis realizados evidenciaron que parámetros como la masa distribuida, la rigidez flexional (EI), la longitud y el módulo de Young no actúan de forma aislada, sino que su interacción define el espectro vibratorio del elemento. Se observó que únicamente aquellos sistemas que combinan ciertas condiciones de esbeltez y baja rigidez presentan frecuencias dentro del intervalo crítico de 4–8 Hz, asociado a excitaciones humanas. Este hallazgo valida la necesidad de herramientas predictivas capaces de identificar con precisión estos casos particulares.

En este contexto, el algoritmo estadístico propuesto demostró ser una alternativa eficiente para el entrenamiento de redes neuronales orientadas a la clasificación vibratoria. A diferencia de los métodos tradicionales basados en gradiente descendente, el procedimiento desarrollado emplea fundamentos de muestreo estadístico y normalización del error sustentados en el Teorema Central del Límite, permitiendo aproximar la distribución del error a un comportamiento normal y estimar probabilísticamente su magnitud. Este enfoque facilitó el ajuste de los pesos sinápticos y sesgos mediante una función de mapeo determinística, logrando una convergencia estable y una adecuada separación entre sistemas seguros y sistemas susceptibles a resonancia. La red neuronal capturó de manera efectiva las relaciones no lineales entre los parámetros estructurales y la frecuencia natural, sin presentar clasificaciones erróneas significativas en los casos evaluados.

Asimismo, la integración del modelo neuronal con un programa complementario de cálculo directo permitió automatizar el proceso de evaluación de vigas y losas dentro de una misma plataforma computacional. El software desarrollado estima la frecuencia natural a partir de parámetros estructurales reales, verifica su ubicación respecto al rango crítico de vibración y, en caso necesario, sugiere ajustes paramétricos para desplazar la frecuencia fuera de la zona de resonancia. Esta integración no solo optimiza el tiempo de análisis, sino que también ofrece una herramienta práctica para apoyar decisiones de diseño orientadas al confort y la seguridad estructural.

En síntesis, la metodología propuesta combina fundamentos analíticos, estadísticos y de inteligencia artificial para ofrecer una herramienta computacional eficiente, robusta y de bajo costo. El enfoque basado en la normalización probabilística del error aporta una perspectiva innovadora al entrenamiento neuronal en problemas estructurales, demostrando su viabilidad para la clasificación de sistemas de

piso ante riesgos vibratorios. Como trabajo futuro, se plantea incorporar monitoreo experimental mediante sensores, ampliar el modelo a escenarios con cargas dinámicas variables en el tiempo y explorar arquitecturas neuronales más profundas que permitan generalizar el método a configuraciones estructurales más complejas, fortaleciendo su aplicabilidad en entornos reales de diseño y evaluación estructural.

Agradecimientos

Los autores quieren agradecer a la Universidad Autónoma del Estado de Hidalgo por apoyo otorgado durante la realización de los proyectos DI-0252-2025 titulado “Mitigación de vibraciones verticales en sistemas de pisos ante actividades humanas” y DI-0674-2025 titulado “Desarrollo y aplicación de un algoritmo estadístico para controladores y redes neuronales”. Los autores agradecen el apoyo brindado por la SECIHTI otorgado a J. M. Cruz Olguín, a través de una beca de maestría.

Referencias

- Allen, D.E. (2012). *Limit States Design for Canadian Structural Engineers*, Baico Publishing, Inc., Ottawa, Ontario, Canada.
- Allen, D.E., & Murray, T. M. (1993). Design Criterion for Vibrations Due to Walking, *Engineering Journal*, AISC, Vol. 30, No. 4, 4th Quarter, pp. 117–129.
- Allen, D.E., Rainer, J.H., & Pernica, G. (1987). Building Vibration Due to Human Activities, *Proceedings of the ASCE Structures Congress*, ASCE, Reston, VA, pp. 438–447.
- Amick, H., Gendreau, M., Busch, T., & Gordon, C. (2005). Evolving Criteria for Research Facilities: I-Vibration, *Proceedings of SPIE Conference 5933*, International Society for Optics and Photonics, Bellingham, WA.
- American Institute of Steel Construction. (2016). *Steel Design Guide 11: Vibrations of steel-framed structural systems due to human activity* (2nd ed.). Chicago, IL: AISC.
- Avcar, M., & Saplioglu, K. (2015). An artificial neural network application for estimation of natural frequencies of beams. *International Journal of Advanced Computer Science and Applications*, 6(6), 94–102.
- Baruch, I. S., Quintana, V. A., & Reynaud, E. P. (2017). Complex-valued neural network topology and learning applied for identification and control of nonlinear systems. *Neurocomputing*, 233, 104–115. <https://doi.org/10.1016/j.neucom.2016.09.109>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Couto, C. (2022). Neural network models for the critical bending moment of uniform and tapered beams. *Structures*, 41, 1746–1762.
- Cruz Olguín, J. M., López-Morales, V., Márquez-Grajales, A., Franco-Árcega, A., & Ojeda-Misses, M. A. (2025). Application of training algorithm based on statistical data-driven and probability distributions in neural networks. En *Proceedings of the XXVII Robotics Mexican Congress (COMRob 2025)* (pp. 8–14). IEEE. <https://doi.org/10.1109/COMRob68109.2025.11264755>
- De Carvalho, A. S., Rossi, A., da Rocha Almeida, M. M., Özkılıç, Y. O., & Martins, C. H. (2024). Artificial neural network modeling of the stability behavior of stainless-steel I-beams with sinusoidal web openings. *Engineering Structures*, 304, 117579.
- Du, K.-L., Leung, C.-S., Mow, W. H., & Swamy, M. N. S. (2022). Perceptron: Learning, generalization, model selection, fault tolerance, and role in the deep learning era. *Mathematics*, 10(24), Article 4730. <https://doi.org/10.3390/math10244730>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press
- González Cuevas, O. M. (2014). *Análisis estructural*. Editorial Limusa S.A. de C.V., Grupo Noriega.
- Ismail, M. A., & Zainuddin, R. (2023). The error correction learning with delta rule. *Journal of Artificial Intelligence and Data Science*, 3(1), 15–22.
- Kaczmarek, M., & Szymańska, A. (2016). Application of artificial neural networks to predict the deflections of reinforced concrete beams. *Studia Geotechnica et Mechanica*, 38(2).
- Luttrell, S. P. (2009). A learning rule for very simple universal approximators consisting of a single layer of perceptrons. *Neural Networks*, 22(3), 251–259. <https://doi.org/10.1016/j.neunet.2008.11.004>
- Madan, D. (2023). Hybrid optimized back propagation learning algorithm for multi-layer perceptron. *International Journal of Computer Science and Information Security*, 21(1), 57–62. <https://doi.org/10.5120/9749-3332>
- Mansour, M. Y., Dicleli, M. U. R. A. T., Lee, J. Y., & Zhang, J. J. E. S. (2004). Predicting the shear strength of reinforced concrete beams using artificial neural networks. *Engineering Structures*, 26(6), 781–799.
- Malinowski, A., & Zurada, J. M. (2012). Backpropagation generalized delta rule for the selective attention sigma-if artificial neural network. *International Journal of Applied Mathematics and Computer Science*, 22(4), 975–987. <https://doi.org/10.2478/v10006-012-0034-5>
- Murray, T. M., Allen, D.E., Ungar, E. E., & Brad Davis, D. (2009). *Vibrations of Steel-Framed Structural Systems Due to Human Activity*, Steel Design Guide, Second Edition, AISC.
- Ojeda Misses, M. A., Baruch I. S., and Soria López, A. (2019). A real-time identification for hand-based movements using Recurrent Complex-Valued Neural Networks, *IEEE 4th Colombian Conference on Automatic Control (CCAC)*, Medellín, Colombia, pp. 1-6, doi: 10.1109/CCAC.2019.8920864.
- Ojeda-Misses, M., Martínez-Arango, H., Sampedro-Mendoza, A., Franco-Árcega, A., & López-Morales, V. (2025). Diseño de un controlador mediante datos estadísticos en lazo cerrado para un servomecanismo mediante una técnica de autosintonización. *RIIT Revista Internacional De Investigación e Innovación Tecnológica*, 12(72), 24-43. <https://revistas.uaedec.mx/index.php/RIIT/article/view/104>
- Ojeda-Misses, M. A., Martínez-Arango, H., López-Morales, V., Franco-Árcega, A., & Márquez-Grajales, A. (2024). Self-tuned closed-loop controller based on statistical data using a servomechanism. En *Proceedings of the XXVI Robotics Mexican Congress (COMRob 2024)* (pp. 27–32). IEEE. <https://doi.org/10.1109/COMRob64055.2024.10777440>
- Sánchez Camperos, E.N., & Alanís García, A.Y. (2006). *Redes neuronales: conceptos fundamentales y aplicaciones a control automático*. Pearson Educación.
- Schommartz, J.O., Klein, D.K., Cobo, J. C. A., & Weeger, O. (2025). Physics-augmented neural networks for constitutive modeling of hyperelastic geometrically exact beams. *Computer Methods in Applied Mechanics and Engineering*, 435, 117592.
- Secretaría de Obras y Servicios de la Ciudad de México. (2023). *Nomas Técnicas Complementarias para Diseño y Construcción de Estructuras de Concreto*. Gaceta Oficial de la Ciudad de México.
- Singh, J., & Banerjee, R. (2019). A study on single and multi-layer perceptron neural network. En *Proceedings of the Third International Conference on Computing Methodologies and Communication (ICCMC 2019)* (pp. 35–40). IEEE.
- Trinh, D. T., Luong, K. A., & Lee, J. (2024). An analysis of functionally graded thin-walled beams using physics-informed neural networks. *Engineering Structures*, 301, 117290.
- Zhang, J., & Xue, X. (2024). Mechanical properties prediction and design of curved beams by neural network. *Thin-Walled Structures*, 195, 111434.