

**Identificación paramétrica de rigidez y amortiguamiento estructural mediante
una Red Neuronal Evolutiva con optimización multiobjetivo**

Kelly Johanna Niño Sandoval

**Trabajo de grado para optar el título de Magíster en Análisis de Datos y Sistemas
Inteligentes**

Director

Cesar Hernando Valencia Niño

Doctor en Ingeniería Eléctrica

Co-director

Andrés José Rodríguez Torres

Doctor en Control Automático

Universidad Santo Tomás, Bucaramanga

División de Ingenierías y Arquitectura

Maestría en Análisis de Datos y Sistemas Inteligentes

2026

Contenido

Introducción	21
1 Identificación paramétrica de rigidez y amortiguamiento estructural mediante una Red Neuronal Evolutiva con optimización multiobjetivo	22
1.1 Contexto del problema	22
1.2 Planteamiento del problema	23
1.3 Justificación del proyecto	24
1.4 Objetivo general	24
1.5 Objetivos específicos	25
1.6 Alcance y delimitaciones del proyecto	25
2 Marco teórico y estado del arte	26
2.1 Conceptos teóricos relevantes	27
2.1.1 Dinámica estructural de múltiples grados de libertad	27
2.1.2 Representación en espacio de estados y modelo orientado al control	28
2.1.3 Problema de identificación paramétrica estructural	29
2.1.4 Inteligencia artificial en ingeniería civil: contexto y evolución	31
2.1.5 Redes neuronales evolutivas (EANN): fundamento y diferenciación	32
2.1.6 Modelos de aprendizaje profundo para respuesta sísmica estructural	33
2.1.7 Redes neuronales informadas por la física (PINN) en ingeniería estructural	35
2.1.8 Optimización multiobjetivo con algoritmos genéticos	36
2.2 Modelos, técnicas o enfoques existentes	37
2.2.1 Métodos clásicos de identificación estructural	37
2.2.2 Métodos metaheurísticos para identificación y control estructural	39
2.2.3 Detección de daño y SHM con redes neuronales en ingeniería civil	40
2.2.4 Contexto sísmico colombiano y normativa aplicable	42

2.3 Revisión de trabajos previos relacionados	43
2.3.1 Identificación paramétrica con metaheurísticas y el prototipo MDOF	43
2.3.2 Redes neuronales informadas por física para identificación estructural	44
2.3.3 Validación estadística y calidad multiobjetivo en algoritmos evolutivos	46
2.4 Identificación de vacíos o limitaciones en la literatura	47
3 Metodología	49
3.1 Tipo y enfoque de la investigación	50
3.2 Descripción de las fases del proyecto	51
3.2.1 Fase 1: extracción de características y construcción del vector de entrada	51
3.2.2 Fase 2: diseño e implementación de la EANN.....	54
3.2.3 Fase 3: optimización multiobjetivo en dos fases con límites dinámicos.....	55
3.2.4 Fase 4: validación estadística multiobjetivo.....	58
3.3 Fuentes de datos y criterios de selección	59
3.3.1 Prototipo experimental y sistema de adquisición.....	59
3.3.2 Señal de excitación y criterios de selección	60
3.4 Herramientas, técnicas y tecnologías empleadas	61
3.4.1 Entorno computacional y reproducibilidad	61
3.4.2 Módulos de implementación	62
3.4.3 Diseño experimental de configuraciones	62
3.5 Métodos de análisis y criterios de evaluación	63
3.5.1 Fidelidad dinámica	64
3.5.2 Robustez paramétrica	64
3.5.3 Calidad del frente de Pareto	65
3.5.4 Inferencia estadística	65

4 Desarrollo de la solución.....	66
4.1 Arquitectura general de la solución.....	67
4.2 Diseño del modelo.....	69
4.2.1 Modelo dinámico estructural y restricciones físicas	69
4.2.2 Arquitectura de la EANN con decodificación acotada	70
4.2.3 Formulación multiobjetivo de la identificación	72
4.2.4 Estrategia evolutiva en dos fases con NSGA-II	75
4.2.5 Selección por knee point y refinamiento local	76
4.3 Implementación técnica.....	77
4.3.1 Estructura del módulo principal del framework.....	77
4.3.2 Implementación del simulador MDOF por transformada de Tustin	78
4.3.3 Gestión de experimentos en batch.....	79
4.3.4 Reproducibilidad del experimento	79
4.4 Descripción del prototipo experimental	80
5 Resultados y validación.....	82
5.1 Resultados experimentales o de aplicación	82
5.1.1 Significancia estadística global	83
5.1.2 Resultados de fidelidad dinámica por método	84
5.1.3 Resultados multiobjetivo: frente de Pareto	84
5.1.4 Resultados de robustez paramétrica	85
5.2 Métricas de desempeño	86
5.2.1 Fidelidad temporal.....	87
5.2.2 Robustez paramétrica	90
5.2.3 Calidad del frente de Pareto	90

5.3 Análisis e interpretación de resultados	91
5.3.1 Tres perfiles de comportamiento algorítmico	91
5.3.2 Implicaciones de la robustez paramétrica para diseño de control	92
5.3.3 Comparación con el trabajo previo de referencia.....	92
5.3.4 Validación independiente con sensores láser	94
5.4 Validación frente a los objetivos planteados	94
6 Conclusiones y recomendaciones.....	97
6.1 Conclusiones generales del proyecto	97
6.2 Cumplimiento de los objetivos.....	99
6.3 Limitaciones identificadas.....	100
6.4 Recomendaciones y trabajos futuros	102
Referencias	104

Lista de tablas

Tabla 1. <i>Configuración del algoritmo GA-MO</i>	57
Tabla 2. <i>Elementos de reproducibilidad del framework EANN-GA-MO</i>	61
Tabla 3. <i>Archivos de implementación del framework EANN-GA-MO</i>	62
Tabla 4. <i>Configuraciones del diseño experimental</i>	63
Tabla 5. <i>Indicadores de evaluación del framework EANN-GA-MO</i>	66
Tabla 6. <i>Arquitectura EANN</i>	72
Tabla 7. <i>Hiperparámetros del GA-MO en sus dos fases</i>	75
Tabla 8. <i>Elementos de trazabilidad y reproducibilidad del framework</i>	80
Tabla 9. <i>Especificaciones técnicas del prototipo experimental</i>	81
Tabla 10. <i>Prueba de Kruskal-Wallis</i>	83
Tabla 11. <i>Comparaciones post-hoc de Wilcoxon-Holm</i>	83
Tabla 12. <i>Fidelidad dinámica sobre 30 corridas</i>	84
Tabla 13. <i>Calidad del frente de Pareto por método</i>	85
Tabla 14. <i>Coeficientes de variación paramétrica por piso</i>	85
Tabla 15. <i>Intervalos de confianza bootstrap al 95%</i>	87
Tabla 16. <i>Desempeño comparativo de configuraciones EANN</i>	95
Tabla 17. <i>Síntesis comparativa de métodos de identificación</i>	96
Tabla 18. <i>Evaluación del cumplimiento de objetivos</i>	99
Tabla 19. <i>Líneas de trabajo futuro</i>	102

Lista de figuras

Figura 1. <i>Pipeline experimental del framework EANN-GA-MO.</i>	49
Figura 2. <i>Prototipo físico de edificio a escala reducida.</i>	60
Figura 3. <i>Pipeline de extracción y estandarización del vector de características.</i>	67
Figura 4. <i>Arquitectura global del framework EANN-GA-MO.</i>	68
Figura 5. <i>Distribución de parámetros identificados sobre 30 corridas independientes.</i>	86
Figura 6. <i>Comparación de aceleraciones experimentales y simuladas por piso.</i>	88
Figura 7. <i>Espectros de potencia normalizados experimental y simulado por piso.</i>	89

Resumen

Problema: la identificación de parámetros estructurales en sistemas de múltiples grados de libertad a partir únicamente de aceleraciones constituye un problema inverso acoplado, sensible al ruido y con limitada observabilidad del amortiguamiento, en este contexto, **objetivo:** esta investigación desarrolló un framework de identificación paramétrica para estimar la rigidez ki y el amortiguamiento ci de los cinco entrepisos de un edificio prototipo a escala reducida, empleando exclusivamente señales acelerométricas, para ello, **método:** se integró una Red Neuronal Evolutiva informada por física con un Algoritmo Genético Multiobjetivo NSGA-II de dos fases, formulando la identificación como la minimización simultánea de la fidelidad temporal, la consistencia modal y la regularización física; la red mapeó un vector de características de dimensión $D = 660$ hacia parámetros estructurales admisibles mediante una decodificación acotada. Como **resultados:** con el registro del sismo de Ciudad de México de 1985 se evaluaron nueve configuraciones con 30 corridas independientes, y la mejor arquitectura ($H1=32$, $H2=16$, $PS1=220$) obtuvo un RMSE mediano de 0.1895 m/s^2 , un R^2 mediano de 0.860 y coeficientes de variación inferiores a 0.15 para rigidez y amortiguamiento; además, la validación no paramétrica evidenció diferencias significativas frente a GA y PSO ($p < 0.001$), y el frente de Pareto alcanzó 98 soluciones con $HV=1.000 \pm 0.000$; finalmente, **discusión:** los resultados indican que la propuesta reduce la identificación repetida a una tarea de aprendizaje único, con inferencia en milisegundos y potencial aplicación en monitoreo de salud estructural post-sísmico.

Palabras clave: identificación estructural, sistemas MDOF, amortiguamiento estructural, redes neuronales evolutivas, optimización multiobjetivo

Abstract

Problem: the identification of structural parameters in multiple-degree-of-freedom systems using only acceleration data constitutes a coupled inverse problem, sensitive to noise and characterized by limited damping observability, in this context, **objective:** this research developed a parametric identification framework to estimate the stiffness ki and damping ci of the five stories of a reduced-scale prototype building, relying exclusively on accelerometric signals, to this end, **method:** a physics-informed Evolutionary Artificial Neural Network was integrated with a two-phase NSGA-II Multiobjective Genetic Algorithm, formulating the identification task as the simultaneous minimization of temporal fidelity, modal consistency, and physical regularization; the network mapped a feature vector of dimension $D=660$ to admissible structural parameters through bounded decoding. As **results:** using the 1985 Mexico City earthquake record, nine configurations were evaluated with 30 independent runs, and the best architecture ($H1=32$, $H2=16$, $PS1=220$) achieved a median RMSE of 0.1895 m/s^2 , a median R^2 of 0.860 , and coefficients of variation below 0.15 for both stiffness and damping; additionally, nonparametric validation showed significant differences compared with GA and PSO ($p<0.001$), and the Pareto front reached 98 solutions with $HV=1.000\pm 0.000$; finally, **discussion:** the results indicate that the proposed framework reduces repeated identification to a single learning task, with millisecond-level inference and potential application in post-earthquake structural health monitoring.

Keywords: structural identification, MDOF systems, structural damping, evolutionary neural networks, multiobjective optimization

Glosario

Acelerómetro MEMS (Micro-Electro-Mechanical System): sensor de estado sólido que mide aceleración mediante la deformación de una masa prueba microfabricada; en esta tesis se usan para adquirir la respuesta dinámica del prototipo de cinco pisos sin requerir sensores de desplazamiento ni velocidad.

AIS (Asociación Colombiana de Ingeniería Sísmica): organización técnica colombiana que publica recomendaciones para el diseño y evaluación sísmica de estructuras, complementaria a la normativa NSR-10.

Amortiguamiento de Rayleigh: modelo de amortiguamiento proporcional que expresa la matriz de amortiguamiento como combinación lineal de las matrices de masa y rigidez; permite calcular los coeficientes de amortiguamiento c_i a partir de las frecuencias naturales del sistema.

ANN (Artificial Neural Network): red neuronal artificial; término genérico para arquitecturas de aprendizaje automático basadas en capas de neuronas con pesos adaptables, en esta tesis se usa como categoría que engloba MLP, CNN y LSTM.

Bootstrap no paramétrico: técnica de remuestreo estadístico que construye distribuciones de estimadores mediante $B=10,000$ submuestras con reemplazo extraídas de las 30 corridas independientes; permite calcular intervalos de confianza sin asumir normalidad.

CNN (Convolutional Neural Network): red neuronal convolucional; arquitectura de aprendizaje profundo con capas de convolución que extraen características locales de señales o imágenes, referenciada como método comparativo en la revisión de la literatura.

Coefficiente de variación (CV): métrica de dispersión relativa definida como $CV = \sigma/\mu \times 100\%$; en esta tesis cuantifica la repetibilidad de los parámetros identificados (k_i , c_i) a través de las 30 corridas independientes por configuración.

Corrida independiente: ejecución completa del algoritmo desde una semilla aleatoria

distinta, el framework evalúa 30 corridas independientes por configuración, cada una inicializada con una semilla diferente y documentada ($k=1, 2, \dots, 30$) mediante el generador Mersenne Twister, garantizando reproducibilidad completa y validez estadística de los resultados.

Cromosoma: en el contexto del algoritmo genético, vector de parámetros reales que codifica los pesos de la red neuronal ($\theta \in \mathbb{R}^{d\theta}$); cada individuo de la población GA representa una configuración completa de la EANN.

EANN (Evolutionary Artificial Neural Network / Red Neuronal Evolutiva): arquitectura central del framework propuesto; red MLP cuyos pesos son optimizados por un algoritmo genético multiobjetivo (NSGA-II) en lugar de gradiente, integra un decodificador acotado dual (H1/H2) que garantiza admisibilidad física de los parámetros identificados.

EMA (Experimental Modal Analysis): análisis modal experimental; técnica clásica de identificación modal que requiere conocer tanto la excitación aplicada como la respuesta medida para estimar frecuencias naturales, formas modales y razones de amortiguamiento.

EFDD (Enhanced Frequency Domain Decomposition): variante mejorada de FDD que aplica la transformada inversa de Fourier sobre valores singulares seleccionados para estimar razones de amortiguamiento modal en análisis operacional.

FDD (Frequency Domain Decomposition): técnica de identificación modal en el dominio de la frecuencia que descompone la matriz de densidad espectral de potencia cruzada mediante valores singulares para estimar frecuencias naturales y formas modales.

FRF (Frequency Response Function): función de respuesta en frecuencia; cociente entre la transformada de Fourier de la respuesta y la de la excitación, usada en métodos clásicos de identificación estructural, no disponible directamente en excitación sísmica ambiental.

Framework EANN-GA-MO: denominación del sistema híbrido propuesto en esta tesis, que combina una Red Neuronal Evolutiva (EANN) con optimización multiobjetivo mediante algoritmo

genético (GA-MO) para identificación paramétrica estructural a partir de señales acelerométricas exclusivamente.

Frente de Pareto: conjunto de soluciones no dominadas en un problema de optimización multiobjetivo; ninguna solución del frente puede mejorar en un objetivo sin empeorar en otro, en esta tesis el frente relaciona el error temporal f_1 , la consistencia modal f_2 y la regularización física f_3 .

GA (Genetic Algorithm): algoritmo genético; metaheurística evolutiva que opera sobre una población de soluciones candidatas mediante operadores de selección, cruce y mutación inspirados en la evolución biológica.

GEM (Global Earthquake Model): fundación internacional que desarrolla modelos probabilísticos de amenaza sísmica a escala global; referenciada en el contexto del riesgo sísmico colombiano.

Hipervolumen (HV): indicador de calidad multiobjetivo que mide el volumen del espacio objetivo dominado por el frente de Pareto respecto a un punto de referencia definido como el peor vector objetivo observado en todas las corridas y algoritmos; valores mayores indican frentes de mayor calidad.

IQR (Interquartile Range): rango intercuartílico; diferencia entre el percentil 75 y el 25 de una distribución, usado como medida robusta de dispersión de los parámetros identificados a través de las 30 corridas.

Kruskal-Wallis: prueba no paramétrica de hipótesis que evalúa si k grupos independientes provienen de la misma distribución; usada en esta tesis para comparación global del desempeño de EANN, GA y PSO sin asumir normalidad.

LSTM (Long Short-Term Memory): arquitectura de red neuronal recurrente con compuertas de memoria que permite capturar dependencias temporales de largo plazo en series de tiempo;

referenciada como método comparativo para identificación de amortiguamiento modal.

MAE (Mean Absolute Error): error absoluto medio; promedio de los valores absolutos de los residuos entre señal medida y estimada, más robusto que RMSE ante valores atípicos.

MATLAB (Matrix Laboratory): entorno de programación numérica de MathWorks usado como plataforma principal de implementación del framework EANN-GA-MO.

MDOF (Multi-Degree of Freedom): modelo de múltiples grados de libertad; representación dinámica de una estructura como sistema de masas, resortes y amortiguadores interconectados, el prototipo de cinco pisos se modela como sistema MDOF con matriz de masas $M = \text{diag}([11.773, 9.17, 9.14, 9.12, 9.08])$ kg.

MEMS (Micro-Electro-Mechanical System): ver Acelerómetro MEMS.

MLP (Multilayer Perceptron): perceptrón multicapa; arquitectura de red neuronal feedforward con una o más capas ocultas completamente conectadas, la EANN de esta tesis es un MLP con decodificador de doble cabeza H1/H2.

MOEA (Multi-Objective Evolutionary Algorithm): algoritmo evolutivo multiobjetivo; categoría que engloba métodos como NSGA-II, SPEA2 y MOEA/D para resolver problemas con múltiples funciones objetivo conflictivas.

MSE (Mean Squared Error): error cuadrático medio; promedio de los cuadrados de los residuos, penaliza fuertemente los errores grandes debido al término cuadrático.

NLAGS: número de retardos temporales incluidos en el vector de características de entrada a la EANN; fijado en $NLAGS=128$ muestras (~ 128 ms a 1000 Hz), valor derivado del período de la frecuencia natural más baja del prototipo (~ 735 ms), garantizando que el vector de entrada contenga al menos un ciclo completo de la vibración dominante.

NSR-10: norma Sismo Resistente colombiana versión 2010; reglamento técnico que establece los requisitos mínimos de diseño y construcción sismo resistente en Colombia,

incluyendo los espectros de diseño sísmico según zonificación de amenaza.

NSGA-II (Non-dominated Sorting Genetic Algorithm II): variante elitista del algoritmo genético multiobjetivo propuesta por Deb et al. (2002) con ordenamiento por no-dominancia y distancia de aglomeración; núcleo del módulo GA-MO del framework propuesto, implementado en MATLAB mediante gamultiobj.

OMA (Operational Modal Analysis): análisis modal operacional; técnica de identificación modal que trabaja exclusivamente con la respuesta medida bajo excitación ambiental desconocida, aplicable cuando la excitación no puede medirse directamente.

PIML (Physics-Informed Machine Learning): aprendizaje automático informado por la física; marco unificado que integra leyes físicas (ecuaciones diferenciales, restricciones de conservación) en el proceso de entrenamiento de modelos de ML para mejorar generalización y plausibilidad física.

PINN (Physics-Informed Neural Network): red neuronal informada por la física; arquitectura que embebe las ecuaciones diferenciales gobernantes como término de regularización en la función de pérdida, requiriendo diferenciabilidad automática a través del simulador, referenciada como enfoque alternativo al EANN-GA-MO propuesto.

PSO (Particle Swarm Optimization): optimización por enjambre de partículas; metaheurística de inteligencia de enjambre propuesta por Kennedy y Eberhart (1995) y refinada por Shi y Eberhart (1998) mediante peso inercial, usado como algoritmo comparador frente al framework EANN-GA-MO.

Punto rodilla (knee point): solución del frente de Pareto con mínima distancia al punto utopía normalizado; representa el mejor compromiso global entre los objetivos f_1 , f_2 y f_3 y es la solución seleccionada para reportar los parámetros identificados en cada corrida.

R^2 (*Coefficiente de determinación*): proporción de la varianza de la señal medida explicada

por el modelo; varía entre 0 y 1, donde valores cercanos a 1 indican alta fidelidad de la predicción, métrica primaria de fidelidad temporal reportada por piso.

RMSE (Root Mean Squared Error): raíz del error cuadrático medio; expresado en las mismas unidades que la señal (m/s^2), métrica principal de error de reconstrucción de la respuesta acelerométrica.

RMS (Root Mean Square): raíz cuadrada de la media de los cuadrados; descriptor estadístico de primer orden del vector de características que cuantifica la amplitud energética global de la señal.

SGC (Servicio Geológico Colombiano): entidad gubernamental colombiana responsable del monitoreo sísmico, la caracterización geológica y la evaluación de amenaza sísmica en el territorio nacional.

SHM (Structural Health Monitoring): monitoreo de salud estructural; campo de la ingeniería civil que desarrolla metodologías para la detección continua y automática de daño, degradación o cambios en las propiedades dinámicas de estructuras en servicio.

SSI (Stochastic Subspace Identification): identificación por subespacio estocástico; método de identificación modal en dominio del tiempo que estima los parámetros modales directamente de datos de respuesta en espacio de estados mediante descomposición matricial.

SVM (Support Vector Machine): máquina de vectores de soporte; algoritmo de aprendizaje supervisado referenciado en la revisión de métodos de clasificación y regresión para SHM.

Transformada de Tustin (método bilineal): método de discretización de sistemas dinámicos en tiempo continuo que mapea el plano s al plano z mediante la sustitución $s = 2/T_s \cdot (z-1)/(z+1)$; usado en esta tesis para implementar el simulador MDOF en tiempo discreto con frecuencia de muestreo de 1000 Hz, preservando la estabilidad del sistema.

Vector de características ($D=660$): vector de entrada a la EANN construido concatenando

descriptores estadísticos (RMS, energía, curtosis, sesgo) y NLAGS=128 retardos temporales de las señales acelerométricas de los cinco pisos; dimensión total $D=660$.

Wilcoxon rank-sum: prueba no paramétrica de comparación por pares que evalúa si dos muestras independientes provienen de la misma distribución; aplicada con corrección de Holm para controlar la tasa de error familiar en las comparaciones EANN vs GA y EANN vs PSO.

Nomenclatura

k_i	Rigidez de entrepiso: rigidez del entrepiso i -ésimo [N/m], $i = 1, \dots, 5$.
c_i	Amortiguamiento: coeficiente de amortiguamiento viscoso del entrepiso i -ésimo [N·s/m].
m_i	Masa de piso: masa del i -ésimo nivel; conocida a priori [kg].
θ	Vector de parámetros: $\theta = [k_1, \dots, k_5, c_1, \dots, c_5]^T \in \mathbb{R}^{10}$, vector de parámetros a identificar.
θ_{seed}	Punto semilla: estimación a priori de θ usada como punto de referencia para los límites dinámicos.
$\hat{\theta}$	Parámetros estimados: salida decodificada de la EANN; estimación de θ para un cromosoma dado.
M_s	Matriz de masas: matriz diagonal de masas $\in \mathbb{R}^{n \times n}$; $M_s = \text{diag}([11.773, 9.17, 9.14, 9.12, 9.08])$ kg.
K_s	Matriz de rigidez: matriz tridiagonal simétrica de rigidez $\in \mathbb{R}^{n \times n}$.
C_s	Matriz de amortiguamiento: matriz tridiagonal simétrica de amortiguamiento $\in \mathbb{R}^{n \times n}$.
A, B, C	Matrices de estado: matrices del modelo en espacio de estados continuo; $A \in \mathbb{R}^{2n \times 2n}$.
A^d, B^d	Matrices discretizadas: versión discreta de A, B por transformada de Tustin con paso Δt .
l	Vector de influencia: $l = [1, \dots, 1]^T \in \mathbb{R}^n$; distribuye la excitación sísmica a todos los pisos.

$\ddot{u}_g(t)$	Aceleración de base: aceleración sísmica de la base medida con acelerómetro [m/s ²].
$a_j(t_k)$	Aceleración medida: aceleración relativa medida en el piso j en el instante t_k [m/s ²].
$\hat{a}_j(t_k; \hat{\theta})$	Aceleración simulada: aceleración relativa simulada con parámetros $\hat{\theta}$ en el piso j [m/s ²].
$u(t)$	Desplazamiento relativo: vector de desplazamientos relativos de cada piso respecto a la base [m].
D	Dimensión del vector: $D = 660$; longitud del vector de características de entrada a la EANN.
L	Ventana de rezagos: $L = 128$; número de rezagos temporales por piso usados en la extracción.
$\tilde{x}_f$	Vector de características: vector estandarizado de entrada; $\tilde{x}_f = (x_f - \mu_x)/(\sigma_x + \varepsilon) \in \mathbb{R}^D$.
μ_x, σ_x	Parámetros de escala: media y desviación estándar del vector de características para estandarización.
ε	Constante de estabilidad: $\varepsilon = 10^{-12}$; evita división por cero en la normalización.
$H1, H2$	Neuronas por capa: número de neuronas en la primera y segunda capa oculta de la EANN.
$d\theta$	Tamaño del cromosoma: número total de pesos de la red; define la dimensión del espacio de búsqueda del GA.

w	Pesos de la red: cromosoma del GA; vector de parámetros entrenables de la EANN, $w \in [-1, 1]^{\text{d}\theta}$
$z_{\min}, z_{\text{res}}$	Salidas de decodificación: salidas de la cabeza principal ($z_{\min}$) y corrección residual (z_{res}) de la EANN
f_1	Fidelidad temporal: error cuadrático medio ponderado entre aceleraciones simuladas y medidas (todos los pisos)
f_2	Consistencia modal: desalineación entre picos espectrales del modelo identificado y del sistema real (pisos 1–2)
f_3	Regularización física: penalización combinada de inadmisibilidad: $f_3 = \lambda_{\text{lin}} \cdot \text{pen}_{\text{lin}} + \lambda_{\text{sm}} \cdot \text{pen}_{\text{sm}} + \lambda_{\text{log}} \cdot \text{pen}_{\text{log}}$
$\eta(k)$	Peso temporal: ponderación energética del instante k en f_1 ; $\eta(k) = w_t(k)/\text{mean}(w_t)$
$\lambda_{\text{lin}}, \lambda_{\text{sm}}, \lambda_{\text{log}}$	Pesos de regularización: pesos de los tres términos de f_3 ; $\lambda_{\text{lin}} = 10^6$, $\lambda_{\text{sm}} = 10^2$, $\lambda_{\text{log}} = 0.5$
$PS1, PS2$	Tamaño de población: número de individuos en la población del GA para Fase I y Fase II, respectivamente
lb, ub	Límites de búsqueda: límites inferior y superior del espacio físico de parámetros en cada fase
HV	Hipervolumen: indicador de calidad del frente de Pareto; $HV = 1$ indica cobertura total del espacio objetivo
Δ	Índice de dispersión: mide la uniformidad del espaciado entre soluciones del frente de Pareto normalizado

$RMSE$	Error cuadrático medio: raíz del error cuadrático medio entre señal medida y simulada [m/s ²]; indicador primario
MAE	Error absoluto medio: promedio de los residuos absolutos; más robusto que RMSE ante valores atípicos [m/s ²]
R^2	Coef. de determinación: proporción de varianza explicada por el modelo; $R^2 \rightarrow 1$ indica ajuste perfecto
$CV(p)$	Coef. de variación: $CV(p) = \sigma(p)/\mu(p)$; cuantifica la repetibilidad del parámetro p entre las 30 corridas independientes
ω_{ni}	Frecuencia natural: i -ésima frecuencia natural del sistema MDOF [rad/s]
ξ_i	Factor de amortiguamiento: factor de amortiguamiento modal del modo i -ésimo (adimensional)
φ_i	Modo de vibración. i -ésimo vector modal (forma modal) del sistema
λ_i	Valor propio: valor propio complejo de A ; $\lambda_i = -\xi_i\omega_{ni} \pm j\omega_{ni}\sqrt{1-\xi_i^2}$
$\kappa(V)$	Número de condición: número de condición de la matriz modal V ; cuantifica la sensibilidad de los valores propios (Bauer-Fike)
Δt	Paso de tiempo: intervalo de muestreo para la discretización por transformada de Tustin [s]
N	Longitud del registro: número de muestras temporales en el registro sísmico utilizado
n	Número de pisos: $n = 5$; grados de libertad del prototipo experimental

Introducción

La identificación de parámetros estructurales en sistemas de múltiples grados de libertad es un problema relevante para el monitoreo de salud estructural, especialmente cuando solo se dispone de señales de aceleración, en estos casos estimar la rigidez ki y el amortiguamiento ci resulta complejo debido al acoplamiento dinámico entre pisos, la presencia de ruido y la baja observabilidad del amortiguamiento, por ello, esta investigación se orientó a responder si es posible identificar dichos parámetros en un edificio prototipo de cinco pisos a escala reducida empleando únicamente registros acelerométricos.

Diversos estudios han abordado la identificación estructural mediante modelos dinámicos, técnicas de optimización y métodos de aprendizaje automático, sin embargo, los enfoques puramente numéricos pueden requerir procesos repetidos de optimización, mientras que los modelos de aprendizaje sin restricciones físicas pueden generar estimaciones poco admisibles, frente a esto el presente trabajo propone un framework híbrido que integra una Red Neuronal Evolutiva informada por física con un Algoritmo Genético Multiobjetivo NSGA-II; formulando la identificación como la minimización simultánea de fidelidad temporal, consistencia modal y regularización física.

La investigación se justifica por la necesidad de contar con herramientas capaces de estimar parámetros estructurales a partir de instrumentación limitada, con potencial aplicación en monitoreo post-sísmico, calibración de modelos y evaluación dinámica, el documento se organiza en capítulos que presentan el problema y los objetivos, el marco teórico, la metodología propuesta, los resultados obtenidos y, finalmente, las conclusiones, limitaciones y trabajos futuros.

1 Identificación paramétrica de rigidez y amortiguamiento estructural mediante una Red Neuronal Evolutiva con optimización multiobjetivo

1.1 Contexto del problema

La monitorización de la salud estructural (SHM, por sus siglas en inglés) y la identificación paramétrica de estructuras civiles constituyen áreas de investigación de creciente importancia en ingeniería [1], el conocimiento preciso de los parámetros dinámicos de una edificación, en particular su rigidez y amortiguamiento, es fundamental para evaluar su estado de integridad, actualizar modelos numéricos de diseño y diseñar estrategias de control de vibración ante excitaciones sísmicas.

En Colombia y en gran parte de América Latina, la amenaza sísmica representa un riesgo significativo para la infraestructura construida, los códigos de diseño estructural, incluidas las Normas Colombianas de Diseño y Construcción Sismo Resistente (NSR-10), exigen que las edificaciones sean modeladas y analizadas con parámetros dinámicos confiables, sin embargo, la estimación de estos parámetros a partir de datos experimentales continúa siendo un problema abierto; particularmente cuando los sensores disponibles son únicamente acelerómetros y no se cuenta con registros de desplazamiento o velocidad.

En este contexto surge la necesidad de desarrollar metodologías que permitan, a partir de señales de aceleración medidas durante un evento sísmico, inferir de manera confiable los parámetros físicos del modelo estructural; este trabajo aborda ese problema mediante una aproximación híbrida que combina un modelo físico de múltiples grados de libertad con una Red Neuronal Evolutiva (EANN) optimizada mediante un Algoritmo Genético Multiobjetivo (GA-MO).

1.2 Planteamiento del problema

La identificación de los parámetros de una estructura civil sometida a actividad sísmica es un problema inverso complejo [2], [3], [4], la rigidez (k_i) y el amortiguamiento (c_i) de cada nivel determinan la forma en que la estructura distribuye esfuerzos y disipa energía ante la acción dinámica, sin embargo, no pueden medirse directamente y deben inferirse a través de modelos matemáticos que relacionan el movimiento impuesto en la base con la respuesta registrada en cada piso.

Este proceso presenta múltiples desafíos, en primer lugar, las señales experimentales están contaminadas con ruido de medición y sesgos de los sensores, en segundo lugar, el modelo estructural es lineal por hipótesis, pero la respuesta real puede presentar efectos no lineales de bajo orden, en tercer lugar, el espacio de búsqueda asociado a los parámetros dinámicos es amplio y no lineal, lo que conduce frecuentemente a mínimos locales cuando se emplean métodos de optimización convencionales, finalmente, cuando la identificación se basa exclusivamente en acelerómetros de tipo no inercial, el marco de referencia es no inercial durante un sismo, lo que impide acceder directamente al desplazamiento absoluto [4].

El problema central de esta investigación consiste en desarrollar un método que permita mapear la información contenida en los registros experimentales preprocesados (mediante filtrado, extracción de características temporales y estadísticas) hacia los parámetros dinámicos del modelo estructural de múltiples grados de libertad, el método debe garantizar coherencia física en las soluciones, evitar mínimos locales y reproducir con precisión la respuesta dinámica observada, operando exclusivamente con señales de aceleración.

1.3 Justificación del proyecto

La identificación confiable de los parámetros dinámicos de una estructura es fundamental para comprender su comportamiento real, evaluar su integridad estructural y actualizar modelos numéricos utilizados en el análisis y diseño, en particular, estimar de manera confiable la rigidez y el amortiguamiento de cada nivel permite caracterizar la capacidad de la edificación para distribuir esfuerzos y disipar energía durante un evento sísmico.

Los métodos tradicionales de identificación presentan limitaciones importantes cuando se aplican a señales experimentales ruidosas o a modelos con múltiples parámetros acoplados [4], [5], [6], [7]; en contraste, las técnicas evolutivas y los modelos híbridos basados en redes neuronales permiten explorar espacios de búsqueda complejos, manejar no linealidades y aprovechar tanto la información temporal como estadística de las señales.

La integración de una Red Neuronal Evolutiva (EANN) con un Algoritmo Genético Multiobjetivo (GA-MO) ofrece una alternativa robusta y acorde con la complejidad del problema [8], [9], [10] este enfoque permite mapear de manera eficiente las características extraídas de los registros experimentales hacia los parámetros dinámicos del modelo estructural, optimizando simultáneamente los pesos de la red mediante funciones multiobjetivo que consideran la coherencia física de la respuesta estructural y el ajuste temporal y modal de la respuesta.

La metodología propuesta no solo busca mejorar la precisión de la identificación paramétrica, sino que también proporciona un marco replicable para futuras aplicaciones en monitoreo estructural, ingeniería sísmica y modelos de salud estructural basados en datos [1], [11].

1.4 Objetivo general

Desarrollar una metodología de identificación paramétrica basada en una Red Neuronal

Evolutiva (EANN) optimizada mediante un Algoritmo Genético Multiobjetivo (GA-MO) para estimar los parámetros dinámicos de rigidez y amortiguamiento de un edificio de múltiples pisos a partir de registros de aceleración experimentales del movimiento de la base y la respuesta estructural medida en cada nivel.

1.5 Objetivos específicos

Los objetivos específicos que orientan el desarrollo de esta investigación son:

1. Definir un esquema de representación de datos experimentales que permita caracterizar adecuadamente la dinámica vibratoria del edificio a partir de señales de aceleración, y que sirva como entrada al proceso de identificación paramétrica.
2. Formular un modelo híbrido que integre la Red Neuronal Evolutiva con el sistema dinámico de múltiples grados de libertad, asegurando que el proceso de identificación incorpore restricciones físicas y criterios de coherencia estructural.
3. Establecer un marco de optimización multiobjetivo que permita ajustar simultáneamente el modelo neuronal y la respuesta dinámica simulada, garantizando la selección de soluciones consistentes y físicamente válidas mediante selección por frente de Pareto y knee point.
4. Validar estadísticamente la metodología desarrollada mediante el análisis comparativo del desempeño del modelo, evaluando la estabilidad y confiabilidad de los parámetros identificados a través de múltiples corridas independientes.

1.6 Alcance y delimitaciones del proyecto

El proyecto comprende el desarrollo e implementación de una metodología de identificación paramétrica orientada a estimar la rigidez (k_i) y el amortiguamiento (c_i) de un

edificio prototipo de cinco pisos a partir de registros experimentales del movimiento en la base y la respuesta medida en los niveles, la metodología incluye el acondicionamiento de las señales y la construcción de un vector de características que captura la dinámica relevante del sistema.

El alcance incorpora la formulación del modelo híbrido EANN-MDOF, el diseño del esquema de optimización GA-MO en dos fases, la implementación computacional en MATLAB y la validación estadística con 30 corridas independientes para las nueve configuraciones de red evaluadas.

El proyecto se limita al uso de los datos experimentales disponibles del edificio prototipo a escala, excitado con el registro sísmico del terremoto de la Ciudad de México de 1985, no contempla la aplicación a otras estructuras, la generalización mediante campañas experimentales adicionales, ni la implementación en tiempo real o en plataformas de monitoreo continuo.

2 Marco teórico y estado del arte

En este capítulo se desarrollan los fundamentos conceptuales y los antecedentes que sustentan teóricamente el proyecto, la exposición sigue la línea narrativa del problema de investigación: partiendo de la dinámica estructural y el problema de identificación paramétrica, se avanza hacia la evolución de la inteligencia artificial en ingeniería civil, se profundiza en las redes neuronales evolutivas y los modelos guiados por la física, y se concluye con la optimización multiobjetivo, esta progresión permite identificar con precisión los vacíos que justifican el framework EANN-GA-MO propuesto.

2.1 Conceptos teóricos relevantes

2.1.1 Dinámica estructural de múltiples grados de libertad

La respuesta dinámica de una estructura civil ante una excitación sísmica se representa mediante un modelo de múltiples grados de libertad (MDOF), bajo la hipótesis de comportamiento lineal elástico, propia del modelo de cortante de piso (shear building model), la masa está concentrada en cada nivel y las columnas de cada entrepiso actúan como resortes con rigidez equivalente; la ecuación diferencial de movimiento para un edificio de n pisos se expresa como [12],[13]:

$$Ms \cdot \ddot{u}(t) + Cs \cdot \dot{u}(t) + Ks \cdot u(t) = -Ms \cdot l \cdot \ddot{u}_g(t) \quad (1)$$

Donde $Ms \in \mathbb{R}^{n \times n}$ es la matriz de masas diagonal definida positiva, $Ks \in \mathbb{R}^{n \times n}$ es la matriz de rigidez tridiagonal simétrica, $Cs \in \mathbb{R}^{n \times n}$ es la matriz de amortiguamiento, $u(t) \in \mathbb{R}^n$ es el vector de desplazamientos relativos de cada piso respecto a la base, $\ddot{u}_g(t)$ es la aceleración sísmica de la base e $l = [1, 1, \dots, 1]^T \in \mathbb{R}^n$ es el vector de influencia sísmica, los parámetros m_i , k_i y c_i son la masa, rigidez y amortiguamiento del i -ésimo entrepiso, en este trabajo las masas son conocidas a priori; los parámetros a identificar son k_i y c_i .

La estructura tridiagonal de Ks refleja que cada entrepiso está conectado únicamente con los dos niveles adyacentes, esta topología garantiza que Ks sea simétrica y definida positiva cuando $k_i > 0$ para todo i , condición físicamente necesaria para la estabilidad del sistema, la misma topología aplica a Cs , la hipótesis de que todos los entrepisos están fabricados del mismo material (aluminio en el prototipo experimental utilizado) implica que los parámetros deben variar de manera aproximadamente monótona a lo largo de la altura del edificio; restricción que se incorpora explícitamente en la función objetivo f_3 del framework propuesto.

La relación entre los parámetros físicos ki y ci y la respuesta dinámica del edificio no es trivial: la complejidad del mapeo inverso de señales de aceleración hacia parámetros constituye el núcleo del problema de identificación que motiva esta investigación, las frecuencias naturales ω_{ni} del sistema se obtienen del problema de valores propios generalizado $(Ks - \omega^2 n Ms) \cdot \phi = 0$, donde ϕ_i son los modos de vibración, experimentalmente estas frecuencias pueden extraerse de los espectros de potencia de las señales de aceleración mediante la Transformada de Fourier; identificando los picos de amplitud dominantes, tal como se implementa en la función objetivo f_2 del framework.

2.1.2 Representación en espacio de estados y modelo orientado al control

Para el análisis orientado al control y la integración numérica eficiente, el sistema MDOF de segundo orden se transforma a la representación en espacio de estados de primer orden, el vector de estado $x(t) = [u(t), \dot{u}(t)]^T \in \mathbb{R}^{2n}$ apila desplazamientos y velocidades de piso, y la dinámica queda descrita por:

$$\dot{x}(t) = A \cdot x(t) + B \cdot \ddot{u}_g(t), y(t) = C \cdot x(t) \quad (2)$$

Donde $A \in \mathbb{R}^{2n \times 2n}$ es la matriz de sistema con bloques $[0, I; -Ms^{-1}Ks, -Ms^{-1}Cs]$, $B = [0; I]^T$ y $C = [-Ms^{-1}Ks, -Ms^{-1}Cs]$, la eigenestructura de A (sus valores y vectores propios) determina completamente las frecuencias naturales y los factores de amortiguamiento modal del sistema, los valores propios aparecen como pares conjugados complejos $\lambda_i = -\xi_i \omega_{ni} \pm j \omega_{ni} \sqrt{1 - \xi_i^2}$, donde ω_{ni} es la i -ésima frecuencia natural y ξ_i el factor de amortiguamiento modal correspondiente.

Esta relación directa entre los parámetros físicos (ki, ci) y la eigenestructura de A tiene implicaciones fundamentales para la ingeniería de control: cualquier incertidumbre en la

estimación de ki y ci se traduce en incertidumbre en los polos del sistema; afectando el diseño de observadores y controladores.

El Teorema de Bauer-Fike establece que, para una matriz diagonalizable $A(\theta) = V\Lambda V^{-1}$, la perturbación en los valores propios inducida por un error paramétrico ΔA satisface $|\lambda(\theta) - \lambda| \leq \kappa(V)\|\Delta A\|$, donde $\kappa(V)$ es el número de condición de la matriz modal [15], esta relación cuantifica directamente por qué la robustez paramétrica (baja dispersión en ki y ci entre corridas independientes) es un criterio de calidad tan importante como la precisión media de reconstrucción.

En la simulación numérica, el modelo en espacio de estados continuo se discretiza mediante la transformada de Tustin (bilineal) con período de muestreo $\Delta t = 1ms$, correspondiente a la frecuencia de adquisición del sistema experimental, esta discretización preserva la estabilidad del sistema continuo y es numéricamente robusta para frecuencias estructurales de interés en el rango de 0-20 Hz.

2.1.3 Problema de identificación paramétrica estructural

La identificación paramétrica estructural consiste en estimar los coeficientes ki y ci a partir de mediciones de la respuesta dinámica del sistema, se trata de un problema inverso: dada la excitación de entrada $\ddot{u}g(t)$ y las respuestas medidas $y(t)$, determinar el vector de parámetros $\theta = [k_1, \dots, kn, c_1, \dots, cn]^T$ que mejor reproduce las observaciones, este problema presenta cuatro dificultades fundamentales que justifican el enfoque propuesto en esta tesis:

1. El modelo estructural es lineal en sus parámetros: para una excitación $\ddot{u}g(t)$ fija, la respuesta $y(t; \theta)$ depende linealmente de las matrices $Ks(\theta)$ y $Cs(\theta)$, no obstante, el problema inverso (estimar θ a partir de $y(t)$ medido) es intrínsecamente difícil por las razones que se enumeran a continuación, la no linealidad del problema de optimización

surge de la arquitectura EANN que mapea el espacio de características al espacio de parámetros, no del modelo físico en sí; el problema puede ser mal condicionado, especialmente para los parámetros de amortiguamiento cuando la excitación no es suficientemente persistente en frecuencia.

2. El espacio de búsqueda en $\mathbb{R}^{2n}$ es de alta dimensión, no convexo y con múltiples mínimos locales, lo que hace que los métodos de gradiente queden atrapados fácilmente.
3. En el caso sísmico que motiva esta investigación, el marco de referencia es no inercial: los acelerómetros instalados en los pisos miden aceleraciones relativas respecto a la base, no absolutas, de modo que los desplazamientos absolutos no son directamente accesibles sin integración doble de la señal, proceso que introduce errores de deriva y amplifica el ruido de baja frecuencia.

Los métodos de identificación estructural pueden clasificarse en tres categorías:

1. Los métodos en el dominio de la frecuencia (análisis modal experimental (EMA), análisis operacional modal (OMA), métodos de función de respuesta en frecuencia (FRF)) son robustos para estructuras con amortiguamiento bajo pero sensibles al truncamiento modal y requieren excitaciones controladas.
2. Los métodos en el dominio del tiempo (filtro de Kalman extendido, mínimos cuadrados recursivos, subespacio estocástico [7]) son compatibles con señales de aceleración, pero su sensibilidad al ruido y la linealización de modelos pueden comprometer la calidad.
3. Los métodos metaheurísticos e híbridos (algoritmos genéticos, enjambre de partículas, redes neuronales) son adecuados para espacios no convexos de alta dimensión al precio de mayor costo computacional.

Esta tesis pertenece a la tercera categoría.

2.1.4 Inteligencia artificial en ingeniería civil: contexto y evolución

La aplicación de la inteligencia artificial (IA) en la ingeniería civil ha crecido exponencialmente en las últimas dos décadas, según la revisión sistemática de Malekloo, el campo del monitoreo de salud estructural (SHM) ha transitado desde inspecciones visuales manuales hacia sistemas inteligentes que integran sensores distribuidos, computación en la nube e IoT, con algoritmos de aprendizaje automático que procesan señales vibratorias, imágenes y datos de deformación en tiempo casi real; esta revisión documenta cómo los algoritmos ML proporcionan las herramientas necesarias para aumentar las capacidades de los sistemas SHM y resolver los desafíos de escalabilidad que los enfoques tradicionales no pueden abordar [1].

La revisión de Flah sobre algoritmos de aprendizaje automático en SHM de ingeniería civil analiza sistemáticamente el uso de ANN, CNN y SVM para detección de daño en edificios y puentes, su análisis de 68 artículos del período 2011-2022 concluye que la integración de modelos físicos, técnicas de extracción de características y gestión de incertidumbre en los sistemas SHM basados en datos mejora sustancialmente la confiabilidad de las predicciones; esta integración de conocimiento físico y aprendizaje de datos es precisamente la filosofía del framework EANN propuesto en esta tesis [11].

Avci proporcionan una revisión exhaustiva de la detección de daño en estructuras civiles mediante métodos tradicionales y de aprendizaje profundo, documentando la evolución desde técnicas modales clásicas hasta CNN y LSTM aplicados a señales vibratorias, su conclusión principal es que los métodos de aprendizaje profundo ofrecen capacidades superiores de extracción de características en comparación con los enfoques basados en ingeniería manual de características; pero requieren grandes volúmenes de datos etiquetados, este requerimiento de datos motiva los enfoques híbridos que combinan simulación física con aprendizaje evolutivo [14].

La introducción formal al campo SHM por Farrar y Worden establecen los cuatro niveles

de identificación de daño (detección, localización, clasificación y evaluación de severidad) y el marco estadístico-probabilístico necesario para abordarlos; aunque anterior al auge del aprendizaje profundo, este trabajo fundacional define los criterios de evaluación y las hipótesis de modelado que siguen siendo relevantes en la literatura actual, incluyendo la distinción entre enfoques model-driven y data-driven que articula el posicionamiento del framework EANN propuesto [15].

2.1.5 Redes neuronales evolutivas (EANN): fundamento y diferenciación

Las Redes Neuronales Evolutivas (EANN, Evolutionary Artificial Neural Networks) constituyen una clase de modelos híbridos en los que los parámetros de la red (pesos, sesgos y, en algunas formulaciones, la topología) se optimizan mediante algoritmos evolutivos en lugar de retropropagación del gradiente, Yao establece la definición formal del campo en una revisión seminal: las EANN combinan redes neuronales artificiales con búsqueda evolutiva para optimizar simultáneamente los pesos de conexión, la arquitectura y las reglas de aprendizaje, superando las limitaciones de los métodos de gradiente en problemas con funciones objetivo no diferenciables, multimodales o que involucren simulaciones físicas acopladas [16].

El paradigma de la neuroevolución fue sistematizado por Stanley en su revisión publicada en Nature Machine Intelligence donde los autores argumentan que los algoritmos evolutivos permiten explorar espacios de arquitectura y pesos que son inaccesibles para los métodos de gradiente; especialmente cuando la función de aptitud involucra evaluaciones no diferenciables, simulaciones físicas o criterios de rendimiento multiobjetivo, esta última característica es exactamente el caso del framework EANN de esta tesis: la función objetivo incluye la simulación del modelo MDOF por integración numérica, operación que no es diferenciable respecto a los pesos de la red [8].

La aplicación de EANN en ingeniería civil tiene antecedentes documentados, Nikoo combinaron ANN con GA para optimizar simultáneamente pesos, número de capas y nodos para la predicción de la resistencia a la compresión del concreto a partir de datos experimentales, demostrando superioridad sobre la regresión lineal múltiple y estabilidad frente a la variabilidad experimental [17]; Momeni aplicaron una ANN optimal basada en algoritmo de búsqueda gravitacional (metaheurística análoga al GA) para predecir la deformación de estructuras de suelo reforzadas, obteniendo mejoras significativas frente a métodos de entrenamiento por gradiente [18]; Kaveh sistematiza estas aplicaciones en el libro *Applications of Artificial Neural Networks and Machine Learning in Civil Engineering*; consolidando las EANN como herramienta estándar para problemas de optimización estructural con funciones objetivo no diferenciables [19].

La arquitectura EANN propuesta en esta tesis se diferencia de los enfoques anteriores en dos aspectos, el primero es el mecanismo de decodificación acotada: la red no produce directamente el vector de parámetros $\hat{\theta}$, sino que su salida pasa por una transformación que garantiza $\hat{\theta} \in [lb, ub]$ por construcción mediante $\text{clip}(\theta_min + 0.15 \cdot \theta_min \odot z_res, lb, ub)$, el segundo es la integración de la simulación del modelo MDOF dentro del ciclo de evaluación del GA: cada cromosoma evalúa, a través de la red, parámetros que se simulan y se comparan con la respuesta real medida; este acoplamiento estrecho entre aprendizaje y física del problema constituye la esencia del enfoque Physics-Guided Machine Learning adoptado.

2.1.6 Modelos de aprendizaje profundo para respuesta sísmica estructural

El aprendizaje profundo ha emergido como herramienta de alto desempeño para la predicción de la respuesta sísmica estructural, Zhang propone redes LSTM profundas para la predicción de la respuesta no lineal de marcos de hormigón bajo excitaciones sísmicas,

demostrando que estos modelos capturan dependencias temporales de largo alcance sin requerir integración física iterativa, su arquitectura logra predicciones precisas de respuesta inelástica en fracciones del tiempo de cómputo de los análisis de historia temporal no lineal [20].

Zhang, Liu y Sun avanzaron hacia la PhyCNN (Physics-guided Convolutional Neural Network), que embebe las leyes de la dinámica estructural directamente en el objetivo de entrenamiento de la red, al restringir la solución al espacio físicamente consistente con la ecuación de movimiento, la PhyCNN reduce sustancialmente la cantidad de datos etiquetados necesarios para alcanzar precisión predictiva confiable, esta reducción es especialmente relevante en ingeniería estructural, donde los datos de excitaciones sísmicas controladas son escasos y costosos [21].

Sadeghi Eshkevari propone DynNet, una arquitectura de red recurrente inspirada en esquemas de integración numérica implícita para modelado y predicción de la respuesta estructural no lineal de sistemas MDOF; DynNet incorpora priors de dinámica estructural como restricciones en la arquitectura, reduciendo el espacio de variables entrenables y manteniendo alta precisión en trayectorias de respuesta largas [22]; Teng aplica CNN-1D con transfer learning para detección de daño estructural, demostrando que el preentrenamiento en datos simulados seguido de ajuste fino con datos experimentales limitados mejora la convergencia y la generalización a configuraciones estructurales heterogéneas [23].

Estos trabajos establecen que la integración de conocimiento físico en los modelos de aprendizaje mejora la eficiencia en datos y la confiabilidad física, pero todos se basan en diferenciación automática para el entrenamiento, esta dependencia de la diferenciabilidad impide su aplicación directa cuando la función objetivo incorpora simuladores numéricos no diferenciables, como el integrador de espacio de estados utilizado en el framework de esta tesis, la neuroevolución resuelve exactamente esta limitación.

2.1.7 Redes neuronales informadas por la física (PINN) en ingeniería estructural

Las Physics-Informed Neural Networks (PINN), introducidas sistemáticamente por Raissi [24], representan un cambio de paradigma en el uso de redes neuronales para problemas de ingeniería: las ecuaciones diferenciales de gobierno se incorporan como restricciones en la función de pérdida, de modo que la red aprende simultáneamente a ajustar los datos experimentales y a satisfacer las leyes físicas del modelo; Karniadakis establece el marco unificado del Physics-Informed Machine Learning (PIML) en Nature Reviews Physics, definiendo sus principios fundamentales y sus aplicaciones en ciencias e ingeniería [25].

En el contexto de la identificación estructural, NeuralSI [26] propone un framework PINN para identificación paramétrica en sistemas estructurales no lineales, aumentando las PDEs que gobiernan la dinámica estructural con redes neuronales que representan los parámetros desconocidos como funciones de la red; el trabajo de Wang extiende este principio con redes neuronales residuales guiadas por física para identificación de daño, demostrando que la guía física mejora la robustez e interpretabilidad física frente a modelos puramente data-driven [27].

Sin embargo, las PINNs basadas en diferenciación automática presentan limitaciones específicas para el problema sísmico MDOF abordado en esta tesis: la naturaleza de frontera móvil del problema sísmico (la base se mueve con la tierra) y la forma implícita de la aceleración en la ecuación de movimiento complican la definición de las condiciones de contorno para el entrenamiento PINN; adicionalmente, el entrenamiento requiere que todas las operaciones del forward pass sean diferenciables respecto a los pesos, lo que excluye el uso de integradores numéricos de paso fijo estándar en la práctica de ingeniería sísmica; El enfoque evolutivo adoptado en esta tesis supera estas limitaciones precisamente porque no requiere diferenciabilidad del simulador estructural, es importante señalar que esta ventaja se argumenta en términos estructurales y no se sustenta en una comparación empírica directa: no se implementó una PINN equivalente

sobre el mismo dataset del prototipo de cinco pisos; dicha comparación cuantitativa queda como trabajo futuro (sección 6.4) y constituye la Limitación 7 del estudio (sección 6.3).

2.1.8 Optimización multiobjetivo con algoritmos genéticos

La optimización multiobjetivo busca minimizar simultáneamente un vector de funciones objetivo $F(\theta) = [f_1(\theta), f_2(\theta), f_3(\theta)]^T$, generalmente conflictivos entre sí, el concepto de optimalidad de Pareto define el frente de soluciones no dominadas: una solución θ^A domina a θ^B si es al menos tan buena en todos los objetivos y estrictamente mejor en al menos uno, el conjunto de soluciones no dominadas constituye el Frente de Pareto óptimo, que en problemas de ingeniería provee al tomador de decisiones información completa sobre los compromisos posibles.

NSGA-II es el algoritmo genético multiobjetivo más ampliamente utilizado, sus características principales son: ordenamiento por dominancia de Pareto, crowding distance para mantener diversidad dentro de cada frente, elitismo que garantiza que las soluciones no dominadas nunca se pierdan, y operadores estándar de selección por torneo, cruza y mutación [9]; Zhou documenta sistemáticamente el estado del arte de los algoritmos evolutivos multiobjetivo, estableciendo los indicadores de calidad (hipervolumen, dispersión, convergencia)[10] que se utilizan en esta tesis para comparar los frentes de Pareto obtenidos por EANN, GA puro y PSO; el hipervolumen mide el volumen del espacio objetivo dominado por el frente de Pareto respecto a un punto de referencia; valores mayores indican frentes de mejor calidad [28].

El algoritmo de optimización por enjambre de partículas (PSO) constituye el segundo algoritmo comparador del framework propuesto; Shi y Eberhart introdujeron la variante con peso inercial que es el estándar de facto en aplicaciones de ingeniería, en la que cada partícula actualiza su velocidad ponderando su mejor posición histórica individual y la mejor posición global del

enjambre mediante coeficientes de aceleración cognitivo y social; esta formulación balancea exploración y explotación sin requerir gradientes, lo que la hace directamente comparable con NSGA-II sobre el mismo espacio de búsqueda no diferenciable del problema de identificación estructural abordado en el presente documento [29].

La formulación multiobjetivo del problema de identificación estructural tiene una justificación profunda: los criterios de ajuste temporal (precisión de la respuesta en el dominio del tiempo), consistencia modal (reproducción de las frecuencias naturales) y plausibilidad física (soluciones que respetan restricciones constructivas) son en general conflictivos, una solución que minimiza el error temporal puede requerir parámetros de amortiguamiento muy altos que violan la expectativa física; una solución modalmente consistente puede sacrificar precisión temporal, esta tensión es explotada por la optimización multiobjetivo, que produce un frente de soluciones no dominadas entre las cuales el ingeniero elige según las prioridades de la aplicación, la selección por knee point (solución del frente con mínima distancia al punto utopía normalizado) provee un compromiso equilibrado automático sin requerir ponderaciones subjetivas.

2.2 Modelos, técnicas o enfoques existentes

2.2.1 Métodos clásicos de identificación estructural

Los métodos clásicos de identificación estructural se fundamentan en el análisis modal experimental (EMA) y el análisis operacional modal (OMA), en OMA se asume excitación de ruido blanco estacionario, lo que permite estimar frecuencias naturales, modos de vibración y factores de amortiguamiento directamente de respuestas de salida sin medir la excitación, las técnicas de descomposición en el dominio de la frecuencia (FDD), análisis espectral de valores

singulares (EFDD) y subespacio estocástico (SSI) son estándar en la práctica de monitoreo estructural, sin embargo, la excitación sísmica no es estacionaria ni de banda ancha uniforme, lo que invalida las hipótesis de OMA para el caso sísmico.

Concha, Garrido y Álvarez-Icaza propusieron un método de variables instrumentales con filtros integrales lineales que permite estimar cocientes k_i/m_i y c_i/m_i directamente de señales de aceleración, sin integración numérica explícita, este método, antecedente directo del prototipo experimental utilizado en esta tesis, es exacto en ausencia de ruido y robusto frente a perturbaciones de frecuencia conocida, sus limitaciones son la sensibilidad al ruido de medición, la necesidad de masas conocidas con precisión y la incapacidad de incorporar restricciones de plausibilidad física en las soluciones [4].

Para identificación de parámetros dinámicos en el dominio de la frecuencia, Jin, Sain y Spencer validaron estrategias basadas en funciones de respuesta en frecuencia en prototipos de estructuras civiles activamente controladas [5]; Roman, Ferrante y Prieur abordaron la identificación de parámetros en ecuaciones de onda lineales mediante formulaciones de descenso de gradiente en dimensión infinita [6]; Lopes dos Santos desarrolló métodos de subespacio determinístico-estocástico para sistemas bilineales MIMO, extendiendo el alcance de los enfoques clásicos a sistemas de entrada múltiple; estos métodos proporcionan fundamentos teóricos sólidos pero requieren condiciones experimentales controladas que no se cumplen en el escenario sísmico real [7].

Pintelon y Schoukens sistematizaron los fundamentos de la identificación de sistemas en el dominio de la frecuencia, estableciendo el marco teórico de los estimadores de función de respuesta en frecuencia que dominan la identificación clásica, este enfoque requiere señales de excitación con contenido espectral amplio y condiciones de estacionariedad que no se satisfacen plenamente bajo excitación sísmica real de banda estrecha como la utilizada en esta tesis; lo que motiva el

enfoque en dominio del tiempo adoptado en el framework propuesto [30].

2.2.2 Métodos metaheurísticos para identificación y control estructural

Los algoritmos metaheurísticos han demostrado ser eficaces para la identificación paramétrica estructural cuando los métodos clásicos presentan limitaciones, Rodríguez-Torres, Valencia-Niño y Álvarez-Icaza compararon GA clásico, PSO, GA cuántico y PSO cuántico para la identificación de rigidez y amortiguamiento en un edificio prototipo MDOF de múltiples pisos bajo optimización multiobjetivo, sus resultados muestran que los métodos cuánticos mejoran la diversidad del frente de Pareto y reducen la dispersión paramétrica respecto a los clásicos, esta referencia constituye el antecedente directo del framework propuesto en esta tesis, que adopta el mismo prototipo experimental pero elimina la dependencia de mediciones de desplazamiento y velocidad [3].

En el campo de sistemas dinámicos no lineales, Rodríguez-Torres aplicó GA para la identificación de modelos de amortiguadores magnetorreológicos de Bouc-Wen directamente de datos experimentales, demostrando la capacidad del enfoque evolutivo para modelos no lineales complejos [31], la estimación robusta de fuerza en amortiguadores MR mediante redes neuronales convolucionales de valores complejos fue presentada por Rodríguez-Torres, mostrando la complementariedad entre aprendizaje de datos y simulación física para el control de vibraciones [32]; Abdul Aziz documentó los desarrollos recientes en amortiguadores magnetorreológicos de gran escala; consolidando el contexto tecnológico en el que se aplican estos métodos de identificación [33], Karoly, Stan y Miclea desarrollaron una metodología de optimización de parámetros del modelo sísmico para estructuras de edificios usando métodos evolutivos, demostrando que la formulación correcta de la función objetivo es determinante para obtener

soluciones físicamente coherentes [34].

Mukherjee y Barua propusieron recientemente la combinación de redes neuronales de grafos asistidas por GA para la optimización de parámetros estructurales dinámicos (masa, rigidez y coeficiente de amortiguamiento) en estructuras, argumentando que los modelos sustitutos de ML combinados con optimización evolutiva superan la limitación de costo computacional de los simuladores de elementos finitos para tareas iterativas de optimización; su trabajo es el más directamente análogo al framework de esta tesis en cuanto a la combinación ML + GA para parámetros dinámicos estructurales, con la diferencia de que el framework propuesto aquí opera en tiempo real de identificación y con datos experimentales sísmicos reales [35].

2.2.3 Detección de daño y SHM con redes neuronales en ingeniería civil

Abdeljaber demostró que las CNN unidimensionales pueden detectar daño estructural en tiempo real directamente de señales de aceleración brutas, sin necesidad de ingeniería manual de características, su trabajo estableció la viabilidad práctica de las redes convolucionales para aplicaciones SHM de alta frecuencia temporal, a la vez que identificó la dependencia de grandes cantidades de datos etiquetados como limitación principal [36]; Ayyad extendió este principio a la identificación en tiempo real de sistemas multirrotor mediante redes neuronales profundas y test de relé modificado, mostrando la generalidad del enfoque en sistemas dinámicos con múltiples entradas [37].

Morales-Valdez, Álvarez-Icaza y Escobar aplicaron técnicas de localización de daño en edificios durante excitación sísmica usando el mismo prototipo experimental empleado en esta tesis, estableciendo que la detección confiable de daño requiere estimaciones precisas de los parámetros dinámicos del modelo de referencia, esta dependencia circular (la detección de daño

requiere parámetros precisos del modelo sano, los cuales a su vez deben identificarse) es el argumento clave que motiva la necesidad de un framework de identificación paramétrica robusto y repetible como el propuesto [38].

Oliva-González propuso un observador PI algebraico para estimar velocidad y desplazamiento en estructuras civiles usando únicamente acelerómetros, este trabajo, directamente relacionado con el prototipo experimental, demuestra que es posible reconstruir el estado completo del sistema MDOF a partir de acelerómetros cuando los parámetros del modelo son conocidos con suficiente precisión, la dependencia de parámetros precisos para el observador refuerza la justificación del framework de identificación propuesto: sin una estimación confiable de k_i y c_i , el observador algebraico no puede inicializarse correctamente [39].

Li realizó un estudio comparativo cuantitativo para la identificación de flexibilidad estructural usando datos vibracionales acelerométricos y de visión por computador, confirmando que los acelerómetros proveen información suficiente para reconstruir la matriz de flexibilidad con alta fidelidad cuando los parámetros del modelo son precisos [40]; Liu y Meidani propusieron redes neuronales informadas por física con modelo de amortiguamiento múltiple para identificación de sistemas estructurales MDOF, demostrando que la incorporación de restricciones físicas reduce la necesidad de datos y mejora la generalización, estas contribuciones refuerzan la pertinencia del enfoque propuesto en esta tesis, que combina restricciones físicas con búsqueda evolutiva para operar exclusivamente sobre señales acelerométricas [41].

Yun propuso un enfoque basado en LSTM para la identificación estable de la razón de amortiguamiento modal en edificios, reportando que las arquitecturas recurrentes mejoran la robustez frente a ruido en señales sísmicas; sin embargo, este enfoque requiere datos de desplazamiento o velocidad para el entrenamiento, restricción que el framework EANN-GA-MO propuesto supera al operar exclusivamente con señales acelerométricas [42].

2.2.4 Contexto sísmico colombiano y normativa aplicable

Colombia se encuentra en una de las zonas sísmicas más activas de América Latina, con amenaza alta en regiones de los Andes y la costa Pacífica, el modelo nacional de amenaza sísmica desarrollado por el SGC en colaboración con GEM [43] constituye la base técnica del mapa oficial que clasifica el territorio en zonas de amenaza baja, intermedia y alta; bajo esa zonificación, Bucaramanga es una región de amenaza intermedia-alta por su cercanía al Nido Sísmico de Bucaramanga [44], una de las fuentes sismogénicas más activas y complejas del mundo.

El Reglamento Colombiano de Construcción Sismo Resistente NSR-10 [44] establece los requisitos de diseño y construcción para reducir el riesgo sísmico en Colombia, este reglamento exige que las edificaciones sean modeladas y analizadas con parámetros dinámicos confiables (rigidez y amortiguamiento) para garantizar el desempeño estructural esperado ante eventos sísmicos de diseño; la identificación paramétrica confiable de estructuras existentes, que es el objetivo de esta investigación, es esencial para la evaluación post-evento de edificaciones, la actualización de modelos de análisis estructural y el diseño de sistemas de monitoreo continuo compatibles con la normativa vigente.

El registro sísmico utilizado en el prototipo experimental corresponde a la componente Norte-Sur del terremoto de la Ciudad de México del 19 de septiembre de 1985, este evento, con magnitud 8.1 y devastadores efectos de amplificación de suelo en la cuenca lacustre de la Ciudad de México, es uno de los registros sísmicos más estudiados de América Latina y proporciona contenido frecuencial rico en el rango de 0.1-5 Hz, cubriendo las frecuencias naturales típicas de edificios de mediana altura, su uso permite que los resultados obtenidos en el prototipo a escala sean directamente extrapolables a edificaciones reales sometidas a excitaciones sísmicas de alta energía.

2.3 Revisión de trabajos previos relacionados

Esta sección sintetiza los antecedentes más directamente relacionados con el framework propuesto, organizados según los tres ejes de contribución del trabajo: la identificación acelerométrica de parámetros MDOF, el aprendizaje evolutivo guiado por física, y la validación estadística multiobjetivo en ingeniería estructural.

2.3.1 Identificación paramétrica con metaheurísticas y el prototipo MDOF

El antecedente directo de esta investigación es el trabajo de Rodríguez-Torres, Valencia-Niño y Álvarez-Icaza, quienes formularon el problema de identificación de rigidez y amortiguamiento del edificio prototipo de cinco pisos como optimización multiobjetivo y compararon cuatro algoritmos evolutivos: GA, PSO, GA cuántico y PSO cuántico, sus resultados muestran que la formulación multiobjetivo (que optimiza simultáneamente ajuste temporal y consistencia modal) produce soluciones más físicamente plausibles que la optimización monoobjetivo, los métodos cuánticos muestran ventajas de convergencia, pero todos los enfoques evaluados requieren mediciones de desplazamiento y velocidad, limitación que el framework EANN de esta tesis elimina completamente [3].

Concha, Álvarez-Icaza y Garrido (2016) presentaron un método para la estimación simultánea de parámetros y estado en edificios cortantes usando observadores PI algebraicos [2], el método de variables instrumentales derivado por los mismos autores en [4] permite identificación directamente de señales de aceleración sin integración numérica, con demostración experimental en el mismo prototipo utilizado en esta investigación, estos trabajos establecen que la identificación con solo aceleraciones es factible en condiciones de laboratorio controladas, pero muestran sensibilidad al ruido que los métodos puramente analíticos no superan sin incorporar

regularización.

En el contexto del monitoreo sísmico, Yang y Lin propusieron un método de identificación de variaciones paramétricas en estructuras basado en estimación por mínimos cuadrados y seguimiento adaptativo, que permite detectar cambios en rigidez durante un evento sísmico [45]; Karoly, Stan y Miclea optimizaron parámetros del modelo sísmico de estructuras mediante metaheurísticas, reportando que la calidad del ajuste depende críticamente del diseño de la función objetivo y la elección de los límites del espacio de búsqueda, estos antecedentes sustentan las decisiones de diseño del framework propuesto respecto a la formulación multiobjetivo y los mecanismos de restricción física [34].

2.3.2 Redes neuronales informadas por física para identificación estructural

Li propone NeuralSI, un framework de identificación paramétrica en sistemas estructurales no lineales que aumenta las PDEs de dinámica estructural con redes neuronales, NeuralSI modela los parámetros desconocidos como funciones aprendidas por la red, logrando reducción de errores de interpolación y extrapolación de entre dos y cinco órdenes de magnitud respecto a redes puramente data-driven; esta referencia es la más cercana conceptualmente al framework EANN de esta tesis, con la diferencia crucial de que NeuralSI requiere diferenciación automática a través del simulador estructural, mientras que el enfoque evolutivo propuesto opera con simulación numérica no diferenciable estándar [26].

Wang demuestra que las redes neuronales residuales guiadas por física mejoran la robustez e interpretabilidad física en la identificación de daño estructural, con resultados consistentes con evidencia reciente que confirma que los modelos informados por la física producen estimaciones más confiables que los modelos puramente data-driven cuando los datos experimentales son

escasos o ruidosos [27]; Mavkov, Forgione y Piga propusieron redes neuronales integradas para identificación directa de modelos no lineales en tiempo continuo bajo entrenamiento multiobjetivo en forma de espacio de estados, proporcionando un precedente directo para la formulación EANN-MDOF de esta tesis [46].

Al-Laham aplicó identificación de redes MLP mediante un algoritmo de enjambre de salp optimizado, mostrando que la optimización metaheurística de pesos de redes neuronales es viable y competitiva frente al entrenamiento por gradiente en problemas de ingeniería con funciones objetivo complejas [47]; Jin sistematizó los avances en computación evolutiva asistida por modelos sustitutos, estableciendo la base teórica para combinar modelos de ML de bajo costo con evaluaciones de alta fidelidad (como la simulación MDOF) en esquemas evolutivos eficientes [48].

Al-Adly y Kripakaran extendieron el enfoque PINN al monitoreo de placas de Kirchhoff-Love, demostrando que la incorporación de las ecuaciones gobernantes como restricciones de entrenamiento mejora la identificación de daño incluso con mediciones escasas; este trabajo confirma la generalidad del principio physics-informed en distintas tipologías estructurales [49]; si bien la dependencia de diferenciación automática continúa siendo una limitación frente al enfoque evolutivo propuesto en esta tesis.

En la misma línea, Teloli propuso un framework de redes neuronales informadas por física específicamente orientado a la identificación de parámetros en estructuras tipo viga publicado en Mechanical Systems and Signal Processing, reportando que la integración de las ecuaciones de movimiento en la función de pérdida reduce la demanda de datos experimentales; la comparación con el framework EANN-GA-MO es pertinente dado el dominio estructural compartido, aunque la dependencia de simuladores diferenciables distingue fundamentalmente ambos enfoques [50].

2.3.3 Validación estadística y calidad multiobjetivo en algoritmos evolutivos

Derrac estableció el protocolo no paramétrico estándar para la comparación estadística de algoritmos evolutivos e inteligencia de enjambres, recomendando las pruebas de Kruskal-Wallis para comparación global, Wilcoxon rank-sum con corrección de Holm para comparaciones por pares, e intervalos de confianza bootstrap para estimación de la media [51], este protocolo es el adoptado en la validación estadística del framework de esta tesis para comparar EANN, GA y PSO en 30 corridas independientes; Efron y Tibshirani proporcionaron el fundamento teórico del bootstrap no paramétrico, que permite construir intervalos de confianza sin asumir normalidad, especialmente relevante para métricas de desempeño de algoritmos estocásticos [52].

Zitzler y Thiele establecieron los principios de comparación de algoritmos evolutivos multiobjetivo, incluyendo el indicador de hipervolumen como medida estándar de la calidad del frente de Pareto [28]; Zhou actualizó sistemáticamente este marco con los desarrollos de la década siguiente, documentando variantes de NSGA-II, MOEA/D y otros algoritmos, así como los indicadores complementarios (dispersión, cardinalidad del frente, dominancia binaria) necesarios para una evaluación exhaustiva [10]; el análisis de dominancia binaria utilizado en el Capítulo 5 de esta tesis para comparar EANN frente a GA sigue directamente estas recomendaciones metodológicas.

Deb estableció NSGA-II como el algoritmo de referencia en optimización multiobjetivo evolutiva, cuya variante de dos fases constituye el núcleo del framework GA-MO propuesto [9], el indicador de hipervolumen normalizado, evaluado con punto de referencia definido como el peor vector objetivo observado en todas las corridas y todos los algoritmos, es el indicador primario de calidad multiobjetivo reportado en los resultados de esta tesis, siguiendo la metodología de Zitzler[53] [53].

2.4 Identificación de vacíos o limitaciones en la literatura

El análisis de la literatura revisada en las secciones anteriores permite identificar cinco vacíos específicos que justifican y contextualizan la contribución del presente trabajo, estos vacíos no son independientes: están conectados por la línea narrativa que va desde el problema de identificación acelerométrica hasta la necesidad de un framework evolutivo-físico robusto y estadísticamente validado.

1. Vacío 1: dependencia de mediciones no acelerométricas, la mayoría de los frameworks de identificación paramétrica con métodos evolutivos y redes neuronales asume disponibilidad de mediciones de desplazamiento o velocidad, que son impracticables durante eventos sísmicos reales en el marco de referencia no inercial del movimiento sísmico; el trabajo de referencia de Rodríguez-Torres [3], así como los enfoques clásicos de Concha [2][4], operan bajo esta restricción, el presente trabajo elimina completamente esta dependencia, formulando el problema de identificación en términos exclusivamente de aceleraciones relativas de piso y aceleración de la base, tal como los acelerómetros MEMS disponibles en la práctica pueden proporcionar.
2. Vacío 2: reoptimización para cada nuevo conjunto de datos, los frameworks GA y PSO de la literatura requieren resolver un nuevo problema de optimización global completo para cada nuevo dataset, con costo del orden de $P \cdot G \cdot C_{sim}$ por identificación, en escenarios de SHM donde los parámetros deben actualizarse periódicamente, este costo es prohibitivo para aplicaciones de tiempo cuasi-real, el paradigma de inferencia propuesto en esta tesis (entrenar offline una EANN y realizar la identificación como pase hacia adelante de costo $O(d\theta)$) resuelve este vacío directamente: después del entrenamiento evolutivo, la estimación de parámetros se reduce a milisegundos de inferencia determinista.
3. Vacío 3: ausencia de garantías de admisibilidad física, los frameworks con GA o PSO

frecuentemente producen precisiones con parámetros de amortiguamiento negativos, perfiles de rigidez no monótonos o valores que violan restricciones de material; aunque esto puede mitigarse con penalizaciones en la función objetivo, las penalizaciones no garantizan la admisibilidad, la arquitectura EANN propuesta garantiza por construcción (mediante el mecanismo $\text{clip}(\theta_{\min} + \Delta\theta, lb, ub)$) que todas las soluciones evaluadas son físicamente admisibles sin excepción, eliminando la posibilidad de soluciones numéricamente precisas, pero estructuralmente irreales.

4. Vacío 4: validación estadística insuficiente de la repetibilidad paramétrica, la mayoría de los trabajos reportan resultados de una o pocas corridas independientes, sin análisis estadístico de la variabilidad entre corridas, esto es especialmente problemático para los parámetros de amortiguamiento, difíciles de estimar consistentemente, el presente trabajo realiza 30 corridas independientes y aplica el protocolo completo recomendado por Derrac: coeficiente de variación por piso, pruebas Kruskal-Wallis, comparaciones Wilcoxon con corrección Holm e intervalos bootstrap al 95% [51].
5. Vacío 5: ausencia de análisis sistemático de arquitectura EANN para identificación MDOF, los trabajos de identificación con redes neuronales evolutivas raramente evalúan de forma sistemática cómo la arquitectura de la red afecta la calidad y repetibilidad de la identificación paramétrica, esta tesis evalúa las diversas configuraciones de capas ocultas siendo ejemplos $H1=16/H2=8$ y $H1=24/H2=12$, en combinación con múltiples tamaños de población para las dos fases del GA, proporcionando evidencia empírica sobre los compromisos entre capacidad representacional, costo computacional y robustez paramétrica.

En conjunto, estos cinco vacíos definen el espacio de contribución del presente trabajo, el framework EANN-GA-MO propuesto no resuelve únicamente uno de estos problemas, sino que

los aborda de manera integrada y coherente: opera con solo aceleraciones (V1), reduce la identificación en deployment a inferencia determinista (V2), garantiza admisibilidad física por construcción (V3), se valida estadísticamente con 30 corridas independientes y protocolo no paramétrico completo (V4) y evalúa sistemáticamente la sensibilidad a la arquitectura (V5).

3 Metodología

Este capítulo describe el enfoque metodológico adoptado para el desarrollo del proyecto; se presentan el tipo y enfoque de la investigación, las fases que estructuran el trabajo, las fuentes de datos, las herramientas computacionales y los criterios de evaluación que permiten valorar el desempeño del framework propuesto, la metodología articula los fundamentos teóricos del Capítulo 2 con la implementación técnica del Capítulo 4, estableciendo el puente entre el problema de identificación y la solución desarrollada.

La Figura 1 sintetiza el flujo completo del pipeline experimental, desde los datos brutos hasta la validación estadística, esta representación permite al lector seguir la trazabilidad de cada decisión metodológica a lo largo del documento y sirve como mapa de referencia para los capítulos 4 y 5.

Figura 1. *Pipeline experimental del framework EANN-GA-MO.*

1 Extracción características $D = 660$ ($L=128 + 4$ stats)	2 EANN-GA-MO Fase I: Exploración Fase II: Explotación Knee + fmincon	3 Simulador MDOF (Tustin) Reconstrucción $\hat{a}(t; \hat{\theta})$	4 Evaluación f_1, f_2, f_3 Pareto front	5 Validación 30 corridas KW · Wilcoxon Bootstrap
→	→	→	→	
	CICLICO POR GENERACIÓN			

Las etapas 2-4 forman un ciclo iterativo: en cada generación del GA, el simulador MDOF (3) reconstruye la respuesta dinámica y la evaluación de objetivos (4) retroalimenta al optimizador (2), al converger, los parámetros identificados se validan estadísticamente sobre 30 corridas independientes (5).

3.1 Tipo y enfoque de la investigación

La investigación es de tipo aplicada y cuantitativa, con un enfoque experimental-computacional, se parte de datos experimentales reales obtenidos de un prototipo físico de edificio de cinco pisos sometido a excitación sísmica controlada, y se desarrolla una metodología computacional orientada a resolver un problema de ingeniería con impacto directo en el monitoreo de salud estructural y la ingeniería sísmica.

El método es hipotético-deductivo: se formula el modelo híbrido EANN-GA-MO a partir de fundamentos de dinámica estructural y computación evolutiva, se implementa y contrasta su desempeño mediante pruebas estadísticas no paramétricas, el proceso sigue un ciclo de modelado: simulación-evaluación-validación, característico de la investigación en sistemas inteligentes aplicados a ingeniería.

El alcance es de nivel explicativo: no se limita a describir el comportamiento del sistema sino que establece relaciones cuantificadas entre las decisiones de diseño del framework (arquitectura de la red, tamaño de población, fases del GA) y la calidad de los parámetros identificados (precisión, robustez estadística y coherencia física).

Una aclaración metodológica relevante concierne a la ausencia de partición train/test en el sentido clásico del aprendizaje supervisado, el framework EANN-GA-MO no aprende de un conjunto de ejemplos etiquetados: el GA optimiza los pesos de la red para que, dada la señal

experimental específica disponible, la decodificación EANN produzca parámetros físicos que minimizan el error de reconstrucción de esa misma señal; no existe riesgo de data leakage porque no hay división de datos: la evaluación de desempeño se realiza con las mismas señales usadas en la optimización (medida de fidelidad de ajuste), complementada con la comparación de desplazamientos estimados contra los sensores láser de validación, sensores que no participan en ningún momento del proceso de optimización y constituyen el criterio de validación independiente del framework.

Una vez convergidos los pesos óptimos θ^* , la red queda completamente determinada y su capacidad de decodificación es generalizable: ante cualquier nuevo vector de características D —construido con los 128 retardos temporales de cada piso y los cuatro descriptores estadísticos globales de la señal correspondiente— un único pase hacia adelante por la EANN produce directamente los parámetros k_i y c_i de la estructura, sin necesidad de reoptimizar el GA. Esta propiedad distingue al framework de los enfoques clásicos de optimización directa (GA o PSO aplicados por señal), donde cada nuevo registro sísmico exige resolver un problema de búsqueda global completo desde cero.

3.2 Descripción de las fases del proyecto

El proyecto se estructura en cuatro fases secuenciales, cada fase produce entregables concretos que alimentan la siguiente, conformando el pipeline de la Figura 1.

3.2.1 Fase 1: extracción de características y construcción del vector de entrada

El conjunto de datos de entrada al framework proviene de registros experimentales adquiridos y preprocesados en el contexto del trabajo de referencia sobre el mismo prototipo [3],

con frecuencia de muestreo $fs = 1000\text{Hz}$ ($\Delta t = 1\text{ms}$), las señales disponibles comprenden: las aceleraciones relativas de cada piso, filtradas, centradas y normalizadas por z-score, las aceleraciones de referencia medidas experimentalmente en cada nivel, la aceleración de la base $\ddot{u}_g(t)$, equivalente a la excitación sísmica de entrada, el vector de tiempo t asociado al registro y las señales filtradas adicionales utilizadas en análisis exploratorios previos; los registros de desplazamiento capturados por sensores láser se encuentran disponibles por separado y se reservan exclusivamente para la validación independiente de la Fase 4, sin intervenir en ningún momento en el proceso de optimización.

En adelante, $A_5 \in \mathbb{R}^{N \times 5}$ denota la matriz de aceleraciones relativas preprocesadas, donde cada columna j corresponde al registro del piso j ($j = 1, \dots, 5$), y $\ddot{u}_b \in \mathbb{R}^N$ denota el vector de aceleración de base, la notación $a_j(t)$ se emplea para referirse a la señal del piso j individualmente; esto es equivalente a $\ddot{u}_j(t)$ en la formulación dinámica del Capítulo 2.

Para cada piso j , se forma el vector $\phi_L(a_j) \in \mathbb{R}^{L+4}$ concatenando dos componentes complementarios:

Componente temporal: las últimas $L=128$ muestras (128 ms a 1000 Hz) de la señal del piso j , extraídas de la zona de cola libre post-sísmica ($t=24\text{--}30$ s), esta región temporal corresponde a vibración libre completamente establecida, donde la excitación de entrada ya se ha disipado y toda la energía proviene de la dinámica modal propia del edificio, con SNR de 18–31 dB según el piso.

La elección $L=128$ no se justifica por capturar ciclos completos del modo fundamental (cuyo período es ~ 735 ms, dieciséis veces mayor que la ventana) sino por tres propiedades complementarias de la cola libre: (i) los modos superiores (f_2 a f_5 , entre 3.91 y 9.25 Hz) quedan cubiertos entre 0.51 y 1.18 ciclos completos dentro de los 128 ms, aportando contenido frecuencial directamente identificable; (ii) la constante de decaimiento exponencial ($\tau \approx 8.26$ s) es observable

en la pendiente del segmento, codificando la información de amortiguamiento c_i sin necesidad de un ciclo completo; y (iii) la amplitud relativa entre pisos en la cola sigue el patrón del modo fundamental (1.0 : 1.55 : 2.20 : 2.66 : 2.98), de modo que la forma modal está incrustada en los 128 valores sin requerir un período completo de oscilación; la información de energía global del modo de baja frecuencia, no observable en una ventana tan corta, queda capturada por los descriptores estadísticos calculados sobre la señal completa (RMS, energía, curtosis, asimetría). Ventanas menores (p. ej., $L=64$) reducirían la cobertura de los modos intermedios y la resolución de la pendiente de decaimiento; ventanas mayores (p. ej., $L=256$ o $L=512$) incrementarían el tamaño del cromosoma del GA en un factor de 2–4 sin incorporar información cualitativa nueva, dado que el comportamiento de baja frecuencia ya está representado por los descriptores globales. $L=128$ representa así el punto de equilibrio entre contenido dinámico de la cola libre y eficiencia computacional para este prototipo.

Componente estadístico: cuatro descriptores globales calculados sobre la señal completa de N muestras: $RMS(a_j) = \sqrt{N^{-1} \sum a_j^2(t_k)}$, energía acumulada $E(a_j) = \sum a_j^2(t_k)$, curtosis $Kurt(a_j)$ y sesgo $Skew(a_j)$, estos descriptores son complementarios: el RMS cuantifica la amplitud efectiva de vibración, la energía captura la severidad global del evento, la curtosis detecta comportamiento impulsivo y el sesgo caracteriza la asimetría en la respuesta; la revisión de Zhang documenta que estos cuatro constituyen el conjunto de descriptores de primer y segundo orden más citado en la literatura de medidas de extracción de características para SHM, no se incluyen descriptores adicionales (p. ej., valor pico, factor de cresta) por su clasificación con el RMS y la curtosis en señales gaussianas filtradas, lo que introduce redundancia sin información independiente relevante para la identificación de parámetros lineales [54].

El vector completo $x_f = \Phi_L(A_5) \in \mathbb{R}^D$, con $D = 5(128 + 4) = 660$, se estandariza

mediante $\tilde{x}_f = (x_f - \mu_x)/(\sigma_x + \varepsilon)$, con $\varepsilon = 10^{-12}$ para estabilidad numérica, garantizando entradas de magnitud comparable para todos los ajustes de red evaluadas, la Figura 3 resume este pipeline de construcción del vector de características.

3.2.2 Fase 2: diseño e implementación de la EANN

La arquitectura EANN es un perceptrón multicapa (MLP) de dos capas ocultas con dos cabezas de salida: una cabeza principal (estimación base) y una cabeza residual (corrección acotada), las transformaciones son:

$$z_1 = \tanh(W_1 \tilde{x}_f + b_1), z_2 = \tanh(W_2 z_1 + b_2) \quad (3)$$

$$z_{min} = \tanh(W_3 z_2 + b_3), z_{res} = \tanh(W_3^{(r)} z_2 + b_3^{(r)}) \quad (4)$$

El mecanismo de decodificación físicamente admisible combina un mapeo al rango físico mediante la cabeza principal y una corrección residual acotada al $\pm 15\%$ mediante la cabeza secundaria, terminando con un operador clip que garantiza $\theta \in [lb, ub]$ para cualquier cromosoma del GA, eliminando la necesidad de penalizaciones por infactibilidad, La especificación técnica completa con fórmulas detalladas se presenta en la sección 4.2.2.

Se evalúan nueve configuraciones de arquitectura, a modo de ejemplo tomaremos la configuración: H1=16/H2=8 (red compacta, d0=10,994 parámetros) y H1=24/H2=12 (red intermedia, d0=16,566 parámetros), el conteo exacto de parámetros para H1=16/H2=8 es:

$$\begin{aligned} d\theta &= D \times H1 + H1 + H1 \times H2 + H2 + H2 \times 10 + 10 + H2 \times 10 + 10 \\ &= 660 \times 16 + 16 + 16 \times 8 + 8 + 8 \times 10 + 10 + 8 \times 10 + 10 = 10,994 \end{aligned} \quad (5)$$

El espacio de búsqueda de parámetros estructurales se define con límites físicos globales fijos: para rigidez, $lb(ki) = 7,000N/m$ y $ub(ki) = 12,000N/m$; para amortiguamiento, $lb(ci) = 0N \cdot s/m$ y $ub(ci) = 100N \cdot s/m$, el punto semilla $\theta_{seed} =$

$[8000,8000,8000,8000,8000,20,20,20,20,20]^T$ corresponde a una estimación a priori basada en el conocimiento constructivo del prototipo, los pesos de la red se inicializan en $LBtheta = -1$ y $UBtheta = 1$.

3.2.3 Fase 3: optimización multiobjetivo en dos fases con límites dinámicos

El problema de entrenamiento se formula como la minimización simultánea de un vector de tres funciones objetivo $F(w)=[f_1(w),f_2(w),f_3(w)]^T$, donde w son los pesos de la red, cada función captura una dimensión diferente de la calidad de la identificación: la primera mide el error entre la respuesta simulada y la medida en el dominio del tiempo; la segunda evalúa la coherencia entre las frecuencias naturales simuladas y las experimentales; y la tercera penaliza soluciones físicamente inadmisibles, las tres son en general conflictivas, lo que justifica el enfoque multiobjetivo donde su definición precisa es:

f_1 : fidelidad de reconstrucción temporal, error cuadrático medio ponderado temporalmente sobre los cinco pisos:

$$f_1 = \sum_j N^{-1} \sum_k [(\hat{a}_j(tk; \theta) - a_j(tk))^2 \cdot wt(k)] \quad (6)$$

Donde $wt(k) = 0.3 + 0.7 \cdot p(k)$ y $p = (ab^2 - \min(ab^2))/\max(ab^2)$ es la energía normalizada de la excitación, esta ponderación otorga mayor importancia a los instantes de mayor excitación sísmica, mejorando la identificación en las ventanas temporales más informativas.

f_2 : consistencia modal: mide la desalineación entre los picos espectrales dominantes del modelo identificado y del sistema real, calculados mediante FFT con ventana de Hann, la formulación completa, incluyendo la justificación de la elección de pisos y número de picos, se presenta en la sección 4.2.3.

f_3 : regularización física multitérmino: penaliza tres tipos de inadmisibilidad mediante una

suma ponderada $f_3 = \lambda_{lin} \cdot pen_{lin} + \lambda_{sm} \cdot pen_{smooth} + \lambda_{log} \cdot pen_{log}$, donde pen_{lin} penaliza violaciones de monotonidad entre entrepisos adyacentes, pen_{smooth} penaliza discontinuidades espaciales excesivas y pen_{log} penaliza desviaciones del punto semilla en escala logarítmica, los valores de los pesos $\lambda_{lin} = 10^6, \lambda_{sm} = 10^2, \lambda_{log} = 0.5$ y su justificación cuantitativa se detallan en la sección 4.2.3.

La estrategia de límites dinámicos contrae el espacio de búsqueda entre fases, en Fase I, los límites físicos se establecen como $lb_1 = \max(lbG, \theta_{seed} \cdot 0.60)$ y $ub_1 = \min(ubG, \theta_{seed} \cdot 1.40)$ (ventana $\pm 40\%$), en Fase II, se contraen a $lb_2 = \max(lbG, \theta_{seed} \cdot 0.82)$ y $ub_2 = \min(ubG, \theta_{seed} \cdot 1.18)$ (ventana $\pm 18\%$), esta contracción concentra la Fase II alrededor del conocimiento acumulado en la Fase I, implementando la transición exploración-explotación sobre el espacio físico, no solo sobre los pesos de la red, la elección del $\pm 40\%$ para la Fase I responde a dos criterios: por un lado, la variabilidad entre los valores de rigidez reportados en trabajos previos sobre el mismo prototipo oscila entre 7,900 y 9,250 N/m [3], lo que representa una dispersión de aproximadamente $\pm 8\%$ respecto a la media, el $\pm 40\%$ alrededor del punto semilla (8,000 N/m) cubre con holgura ese rango conocido a la vez que permite explorar soluciones fuera de él en caso de que el seed sea impreciso; por otro lado, para los coeficientes de amortiguamiento, cuya estimación a priori es menos confiable, el $\pm 40\%$ alrededor del seed de 20 N·s/m (rango 12-28 N·s/m) cubre el intervalo de valores plausibles documentados en la literatura para estructuras metálicas ligeras de laboratorio; el $\pm 18\%$ de la Fase II se determinó empíricamente: en las corridas exploratorias, las soluciones del frente de Pareto de la Fase I se concentraban invariablemente dentro del $\pm 20\%$ del seed, de modo que contraer el espacio a $\pm 18\%$ retiene el 95% de las soluciones no dominadas anteriores mientras reduce el volumen de búsqueda en un factor $(0.36/0.18)^2 \approx 4$ por parámetro, acelerando la convergencia de la Fase II sin sacrificar diversidad en el frente final.

La Tabla 1 presenta la configuración de los hiperparámetros utilizados en las fases de exploración y explotación del algoritmo genético multiobjetivo, la selección de la solución final se realizó mediante el criterio de punto de rodilla sobre el frente de Pareto normalizado, permitiendo identificar una solución de compromiso entre los objetivos sin recurrir a ponderaciones subjetivas.

Tabla 1. Configuración del algoritmo GA-MO

Parámetro	Fase I (Exploración)	Fase II (Explotación)
Tamaño de población (P)	160 / 180 / 220 (variable)	120 / 140 / 160 (variable, Fase I: 160) 120 / 160 / 180 (variable, Fase I: 180) 120 / 170 / 220 (variable, Fase I: 220)
Generaciones máximas (G)	160	120
Límite de estancamiento	120 generaciones	100 generaciones
Selección	Torneo (tamaño 4)	Torneo (tamaño 8)
Cruza	Dispersa (fracción 0.85)	Intermedia (fracción 0.55)
Mutación (escala / contracción)	0.55 / 0.95	0.20 / 0.995
Fracción de Pareto	0.35	0.35
Inicialización	30% gaussiana ($\sigma=0.15$) + 70% uniforme	Pareto Fase I + gaussiana ($\sigma=0.06$)
Espacio de pesos (cromosoma)	$[-1, 1]^{d\theta}$	$[-1, 1]^{d\theta}$
Espacio físico (θ)	$\pm 40\%$ alrededor de θ_{seed}	$\pm 18\%$ alrededor de θ_{seed}
Evaluación	Paralela (parpool)	Paralela (parpool)
Selección final	—	Knee point + fmincon (max 200 iter.)

Criterios de parada explícitos: el GA se detiene cuando se cumple cualquiera de las siguientes condiciones: (a) se alcanza el número máximo de generaciones G; (b) la mejora del hipervolumen del frente de Pareto entre generaciones consecutivas es inferior a $TolFun = 10^{-6}$ durante un número de generaciones igual al límite de estancamiento; o (c) el cambio relativo máximo en las variables de decisión es inferior a $TolX = 10^{-6}$, estos criterios son nativos de la

función `gamultiobj` de MATLAB y se aplican de forma automática en ambas fases.

Selección final y refinamiento; una vez completadas ambas fases, los frentes de Pareto se agregan y se selecciona la solución por knee point: mínima distancia euclidiana al punto utopía en el espacio objetivo normalizado, opcionalmente, esta solución se refina con `fmincon` (algoritmo interior-point, máximo 200 iteraciones, $TolFun = TolX = 10^{-8}$), usando pesos inversamente proporcionales al rango de cada objetivo.

3.2.4 Fase 4: validación estadística multiobjetivo

Para cada configuración experimental se ejecutan 30 corridas completamente independientes entre sí, cada corrida k ($k=1,...,30$) utiliza una semilla aleatoria distinta, fijada mediante `rng(k, "twister")` como primera instrucción del módulo principal del framework antes de cualquier inicialización del GA, garantizando que dos corridas con distinto k no comparten ningún estado aleatorio, el uso de semillas consecutivas (1, 2, ..., 30) en lugar de semillas aleatorias no replicables asegura la reproducibilidad completa del experimento; los resultados de cada corrida k incluyen: el vector $\hat{\theta}^*k$, las métricas de desempeño por piso, el frente de Pareto final con sus indicadores multiobjetivo, y el tiempo de cómputo total de la corrida (medido con `tic/toc` en MATLAB), el tiempo de inferencia en deployment (pase hacia adelante de la red entrenada, sin GA) se estima como el tiempo de una única llamada al decodificador de doble cabeza seguida del simulador MDOF por transformada de Tustin, y se reporta en el Capítulo 5 junto con los tiempos de entrenamiento completo por configuración.

El análisis estadístico sigue el protocolo de Derrac [52]: (1) estadística descriptiva (media, mediana, desviación estándar, IQR); (2) prueba global de Kruskal-Wallis ($\alpha = 0.05$); (3) comparaciones por pares Wilcoxon con corrección de Holm; e (4) intervalos de confianza bootstrap

al 95% con $B=10,000$ remuestras [52], los indicadores de calidad del frente de Pareto (hipervolumen, dispersión Δ , dominancia binaria) se calculan con punto de referencia definido como el peor vector objetivo observado en todas las corridas y configuraciones [29].

3.3 Fuentes de datos y criterios de selección


3.3.1 Prototipo experimental y sistema de adquisición

Los datos provienen del prototipo físico de edificio a escala reducida ($600 \times 500 \times 1800$ mm, 5 niveles) observado en la Figura 2 y ubicado en el Laboratorio de Control de Vibraciones del Instituto de Ingeniería de la UNAM, Ciudad de México, el prototipo está fabricado con placas de aluminio de igual geometría y columnas de sección cuadrada $1/4 \times 1/4$ in con altura 360 mm por entrepiso, la uniformidad constructiva implica variación aproximadamente monótona de los parámetros dinámicos, restricción incorporada en f_3 mediante Aineq.

La instrumentación comprende: acelerómetros MEMS ADXL203E (rango $\pm 1.7g$, sensibilidad promedio 0.168g/V) en cada nivel; sensores láser Micro-Epsilon OptoNCDT 1302-200 (rango 200mm, ganancia 25.11mm/V) usados exclusivamente para validación; masas experimentales $m=[11.773, 9.17, 9.14, 9.12, 9.08]$ kg (conocidas a priori), la adquisición se implementa en Simulink con dos tarjetas NI PCI-6221-M a $f_s=1000$ Hz.

La excitación de base se reproduce con actuador Parker 406T03LXR (aceleración máxima $49.05m/s^2$, velocidad máxima 3m/s, resolución $5\mu m$, recorrido 250mm).

Figura 2. *Prototipo físico de edificio a escala reducida.*



3.3.2 Señal de excitación y criterios de selección

Se utiliza la componente Norte-Sur del acelerograma del sismo de la Ciudad de México del 19 de septiembre de 1985, escalado en amplitud para el actuador y el prototipo a escala, la selección responde a tres criterios: (1) su riqueza frecuencial en 0.1-5 Hz cubre todas las frecuencias naturales del prototipo garantizando excitación persistente en todos los modos relevantes; (2) es el mismo registro utilizado en los trabajos previos sobre el mismo prototipo [3], [38], [39], permitiendo comparabilidad directa; (3) el dataset se forma a partir de cinco ensayos experimentales

independientes con la misma excitación, proporcionando soporte experimental adicional, desde el punto de vista de la generalización del framework, el uso de un único registro sísmico implica que la EANN entrenada captura el mapa características-parámetros para el contenido espectral específico de este acelerograma; esta es una limitación reconocida del paradigma de aprendizaje offline (discutida en detalle en la sección 6.3): una EANN entrenada con este registro y desplegada sobre excitaciones de contenido frecuencial significativamente diferente (p. ej., sismo de subducción de largo período vs. sismo de corteza superficial de alta frecuencia) podría requerir reentrenamiento, sin embargo, el parámetro optimizado por el GA son los pesos de la red, no el registro mismo; el framework puede reentrenarse con cualquier nuevo acelerograma sin modificar la arquitectura ni el pipeline, lo que lo hace metodológicamente generalizable aunque no universalmente transferible sin reentrenamiento.

3.4 Herramientas, técnicas y tecnologías empleadas

3.4.1 Entorno computacional y reproducibilidad

La implementación completa se realiza en MATLAB R2025b con Global Optimization Toolbox (gamultiobj/NSGA-II) y Parallel Computing Toolbox (parpool), la Tabla 2 consolida todos los elementos necesarios para la reproducibilidad completa del experimento:

Tabla 2. Elementos de reproducibilidad del framework EANN-GA-MO.

Elemento	Valor / descripción
Entorno	MATLAB R2025b, Global Optimization Toolbox, Parallel Computing Toolbox
Sistema operativo	MacOS
Hardware	Chip M4
Semillas estocásticas	Fijadas antes de cada llamada al módulo principal del framework
Función de aleatoriedad	Generador de números aleatorios Mersenne Twister inicializado en cada corrida
Archivo de datos	Dataset experimental preprocesado descrito en 3.2.1

Elemento	Valor / descripción
Control de versiones	GitHub
Repositorio / DOI	Disponible bajo solicitud al autor correspondiente

La ejecución paralela distribuye la evaluación de cromosomas entre los núcleos disponibles con evaluación paralela habilitada en ambas fases, cada corrida es estadísticamente independiente de las demás: la semilla se fija al inicio del módulo principal del framework antes de cualquier inicialización del GA.

3.4.2 Módulos de implementación

Se cuenta con un módulo principal del framework el cual integra todo el pipeline operativo como funciones locales en un único archivo, esta arquitectura garantiza cohesión al momento de realizar la ejecución vía lotes necesaria para llevar a cabo los diferentes experimentos y evitar así dependencias externas durante las corridas, la Tabla 3 describe los archivos del sistema:

Tabla 3. Archivos de implementación del framework EANN-GA-MO.

Módulo	Función en el framework	Rol
Módulo principal del framework	Módulo central del pipeline, integra como funciones locales: la rutina de extracción de características ($D=660$), la función de aptitud multiobjetivo (f_1, f_2, f_3), el decodificador de doble cabeza (decodificación $EANN \rightarrow \hat{\theta}$), el simulador MDOF por transformada de Tustin, la rutina de selección por knee point y la construcción del cromosoma semilla, orquesta el GA-MO en dos fases vía gamultiobj y el refinamiento local con fmincon.	Pipeline de producción
Módulo de ejecución por lotes	Orquestador de lote, lanza las diferentes corridas con parpool, cada una llamando a al módulo principal del framework con semillas, estructura de red y poblaciones independientes y concluye almacenando los resultados en un archivo con nomenclatura unívoca para trazabilidad.	Orquestador batch
Módulo de evaluación de métricas	Calcula MSE, RMSE, MAE y R^2 piso a piso, incluye manejo robusto de valores no finitos y penalización ante entradas inválidas, versión de MATLAB: R2025b.	Módulo de evaluación

3.4.3 Diseño experimental de configuraciones

El diseño experimental evalúa el impacto conjunto de la arquitectura de la red, el tamaño de población de la Fase I (PS1) y el tamaño de población de la Fase II (PS2) sobre la calidad y

repetibilidad de la identificación, se evaluaron tres arquitecturas ($H1/H2 \in \{16/8, 24/12, 32/16\}$), tres valores de PS1 (160, 180, 220) y tres valores de PS2 por configuración, resultando en 9 combinaciones $\times$ 30 corridas = 270 ejecuciones totales, la Tabla 4 resume el diseño completo.

Tabla 4. *Configuraciones del diseño experimental*

Configuración	Arquitectura (H1/H2)	d θ	PS1	PS2	Corridas
A	16/8	10,994	160	120–140–160	30
B	16/8	10,994	180	120–160–180	30
C	16/8	10,994	220	120–170–220	30
D	24/12	16,566	160	120–140–160	30
E	24/12	16,566	180	120–160–180	30
F	24/12	16,566	220	120–170–220	30
G	32/16	23,562	160	120–140–160	30
H	32/16	23,562	180	120–160–180	30
I	32/16	23,562	220	120–170–220	30

Los resultados de cada corrida k se almacenan en la estructura out con campos: out.k y out.c (rigideces y amortiguamientos identificados), out.MSE_a, RMSE_a, MAE_a, R2_a (métricas por piso), out.ThetaPareto y out.Fpareto (frente de Pareto agregado), y out.net (metadatos: arquitectura, escalado, hiperparámetros GA), la nomenclatura del archivo de resultados garantiza trazabilidad unívoca entre configuración y resultados.

3.5 Métodos de análisis y criterios de evaluación

El desempeño del framework se evalúa en cuatro dimensiones complementarias, ninguna métrica individual captura todos los aspectos relevantes: alta precisión media puede coexistir con alta variabilidad entre corridas, y un frente de Pareto de alta calidad puede producir parámetros físicamente inconsistentes, la evaluación multidimensional es por tanto indispensable para la aplicabilidad práctica en ingeniería de control, cabe señalar explícitamente que el presente diseño

experimental no incluye una evaluación sistemática de la robustez del framework ante niveles variables de ruido artificialmente añadido a las señales acelerométricas: las señales utilizadas son las registradas por los sensores MEMS bajo condiciones reales de laboratorio, con el ruido de adquisición propio de esos dispositivos, pero sin estudiar el impacto de incrementar deliberadamente el nivel de ruido, esta es una limitación del alcance reconocida (sección 6.3): la evaluación de robustez ante contaminación adicional constituye una línea de trabajo futuro de corto plazo prioritaria para validar el framework en escenarios de campo donde los sensores pueden presentar mayor nivel de interferencia que en condiciones de laboratorio.

3.5.1 Fidelidad dinámica

La primera dimensión evalúa la capacidad del modelo identificado para reproducir las aceleraciones de piso experimentales, para cada corrida k y piso j se calculan cuatro indicadores mediante `metrics.m`: MSE, RMSE (indicador primario, escala dimensional consistente con la señal), MAE (robusto frente a outliers) y R^2 , se reportan tanto los valores por piso como los promedios sobre los cinco pisos (RMSE_mean, MAE_mean, R^2 _mean), el indicador primario para comparación entre configuraciones es RMSE_mean.

3.5.2 Robustez paramétrica

La segunda dimensión evalúa la consistencia de los parámetros identificados a través de las 30 corridas independientes, el indicador principal es el coeficiente de variación $CV(p) = \sigma(p)/\mu(p)$, calculado para cada parámetro $p \in \{k_1, \dots, k_5, c_1, \dots, c_5\}$ sobre las 30 corridas, se adopta $CV < 0.15$ como umbral de alta repetibilidad, consistente con la literatura de identificación paramétrica para aplicaciones de control, complementariamente, el índice de suavidad espacial

$S(p) = [\sum_i (p_{i+1} - p_i)^2] / [\sum_i p_i^2]$ cuantifica la coherencia física del perfil: valores bajos indican variación suave entre pisos adyacentes, consistente con la hipótesis de uniformidad constructiva del prototipo.

3.5.3 Calidad del frente de Pareto

La tercera dimensión evalúa la aproximación al frente de Pareto óptimo mediante: (a) hipervolumen normalizado (HV) calculado con punto de referencia = peor vector objetivo observado en todas las corridas/configuraciones [28]; (b) índice de dispersión Δ , uniformidad del espaciado entre soluciones consecutivas del frente normalizado; (c) tamaño del frente (número de soluciones no dominadas); y (d) dominancia binaria $D(A \succ B)$ entre pares de configuraciones como indicador del posicionamiento relativo en el espacio multiobjetivo.

3.5.4 Inferencia estadística

La cuarta dimensión aplica el protocolo no paramétrico completo de Derrac [51] en cuatro etapas: (1) prueba de Kruskal-Wallis para verificar diferencias globales entre configuraciones ($\alpha=0.05$, $k-1$ grados de libertad); (2) comparaciones por pares Wilcoxon rank-sum con corrección de Holm para controlar la tasa de error familiar; (3) intervalos de confianza bootstrap al 95% con $B=10,000$ remuestras para la media de cada métrica [52]; y (4) análisis de dominancia binaria en el espacio multiobjetivo.

La Tabla 5 resume los once indicadores de evaluación adoptados organizados por dimensión de análisis:

Tabla 5. *Indicadores de evaluación del framework EANN-GA-MO.*

Indicador	Dimensión	Definición / referencia	Criterio
RMSE_mean	Fidelidad temporal	$\sqrt{(\text{MSE})}$ promediado sobre 5 pisos	Menor es mejor; indicador primario
MAE_mean	Fidelidad temporal	MAE promediado sobre 5 pisos	Menor es mejor; robusto a outliers
R^2 _mean	Fidelidad temporal	Coef. determinación promedio	Mayor es mejor; $R^2 \rightarrow 1$ = ajuste perfecto
CV(ki), CV(ci)	Robustez paramétrica	σ/μ por piso sobre 30 corridas	$CV < 0.15 \rightarrow$ alta confiabilidad
S(p)	Coherencia física	$[\sum(p_{i+1}-p_i)^2]/[\sum p_i^2]$ por corrida	Menor $\rightarrow$ perfil más suave y físico
HV normalizado	Calidad Pareto	Hipervolumen / Zitzler y Thiele [28]	Mayor es mejor; HV=1 $\rightarrow$ cobertura total
Dispersión Δ	Calidad Pareto	Uniformidad espaciado Pareto normalizado	Menor varianza $\rightarrow$ mayor uniformidad
Tamaño frente	Calidad Pareto	Número de soluciones no dominadas	Mayor $\rightarrow$ mejor resolución compromisos
D(A > B)	Dominancia binaria	Conteo dominancias entre frentes	Mayor D(A>B) $\rightarrow$ superioridad de A
Kruskal-Wallis H	Inferencia estadística	Prueba no paramétrica global / [51]	$p < 0.05$ rechaza igualdad
IC Bootstrap 95%	Inferencia estadística	B = 10,000 remuestras / [52]	Intervalo estrecho $\rightarrow$ mayor estabilidad

La combinación de estas cuatro dimensiones proporciona una evaluación integral que incorpora precisión, estabilidad estadística, coherencia física y calidad multiobjetivo (los cuatro aspectos indispensables para la aplicabilidad práctica en ingeniería de control y monitoreo estructural).


4 Desarrollo de la solución

El framework EANN-GA-MO traduce el problema de identificación paramétrica estructural (formalmente planteado en el Capítulo 3) en una solución computacional concreta, las secciones siguientes detallan la arquitectura del sistema, el diseño técnico de cada componente, los hiperparámetros exactos de entrenamiento y los criterios que hacen reproducible el experimento completo, los resultados cuantitativos de la identificación se presentan en el Capítulo 5.

4.1 Arquitectura general de la solución

El framework propuesto articula tres componentes fundamentales en un pipeline secuencial: un módulo de preprocesamiento y extracción de características, una Red Neuronal Evolutiva (EANN) que mapea señales de aceleración a parámetros estructurales, y un simulador del modelo físico MDOF acoplado al proceso de optimización multiobjetivo, la Figura 3 presenta el pipeline completo de preprocesamiento y construcción del vector de características estandarizado, mientras que la Figura 4 ilustra el framework global que integra la EANN, el simulador físico y la estrategia evolutiva.

Figura 3. Pipeline de extracción y estandarización del vector de características.




La arquitectura se organiza en dos etapas operativamente distintas, la etapa de entrenamiento (offline) ejecuta el GA-MO para encontrar el conjunto de pesos óptimos de la red neuronal que minimizan simultáneamente los tres objetivos de identificación, una vez que los pesos convergen, la etapa de inferencia (deployment) reduce la estimación de parámetros a un único pase hacia adelante por la red, con costo computacional $O(d\theta)$ independiente del tamaño de la población,

el número de generaciones o la longitud temporal del registro sísmico.

Para cada piso se extraen las últimas L muestras temporales y cuatro descriptores estadísticos globales (RMS, energía, curtosis y sesgo), los cuales se concatenan y estandarizan antes de alimentar la EANN.

Figura 4. Arquitectura global del framework EANN-GA-MO.



El vector de características estandarizado alimenta la EANN, que decodifica los parámetros estructurales estimados $\hat{\theta}$, estos parámetros se usan para simular la respuesta del modelo MDOF, cuyas aceleraciones simuladas se comparan con las medidas para evaluar el vector multiobjetivo $F = [f_1, f_2, f_3]$, el GA actualiza iterativamente los pesos de la red hasta la convergencia del frente de Pareto.

La distinción entre entrenamiento e inferencia tiene una implicación fundamental para la ingeniería de control: bajo esquemas de reoptimización clásicos (GA o PSO aplicados directamente), cada nuevo registro sísmico requiere resolver un problema de optimización global completo con costo aproximado $P \cdot G \cdot C_{sim}$, el framework EANN-GA-MO incurre en ese costo

una única vez durante el entrenamiento offline; en deployment, la identificación se reduce a milisegundos de inferencia determinista.

4.2 Diseño del modelo

4.2.1 Modelo dinámico estructural y restricciones físicas

El edificio prototipo de cinco pisos se modela como un sistema MDOF lineal con la ecuación de movimiento $M_s \cdot \ddot{u}(t) + C_s \cdot \dot{u}(t) + K_s \cdot u(t) = -M_s \cdot l \cdot \ddot{u}_g(t)$, donde las matrices de masas $M_s = \text{diag}([11.773, 9.17, 9.14, 9.12, 9.08])kg$ son conocidas a priori, las matrices de rigidez K_s y amortiguamiento C_s tienen estructura tridiagonal simétrica, con parámetros k_i y c_i a identificar para $i = 1, \dots, 5$.

El espacio de búsqueda se define mediante límites globales derivados del conocimiento físico del prototipo, para las rigideces: $7000 \leq k_i \leq 12000N/m$, para los amortiguamientos: $0 \leq c_i \leq 100N \cdot s/m$ el punto semilla $\theta_{seed} = [8000, 8000, 8000, 8000, 8000, 20, 20, 20, 20, 20]^T$ es una estimación a priori del sistema.

Las restricciones de admisibilidad física se codifican mediante la matriz de desigualdades lineales $A_{ineq} \cdot \theta \leq b_{ineq}$, con $b_{ineq} = 0_{16}$, esta matriz impone que cada parámetro de rigidez y amortiguamiento puede variar a lo sumo $\pm 40\%$ respecto al adyacente, representando formalmente que $0.6 \cdot k_i \leq k_{i+1} \leq 1.4 \cdot k_i$ e igualmente para c_i , esta restricción modela la hipótesis de uniformidad constructiva (todas las columnas son del mismo material y sección) y evita perfiles de parámetros físicamente imposibles.

La simulación numérica del modelo MDOF se implementa mediante la transformada de Tustin (bilineal), que discretiza el sistema de espacio de estados continuo preservando la

estabilidad, para el período de muestreo $\Delta t = 1ms$, las matrices discretas son: $Ad = (I - \Delta t/2 \cdot A)^{-1}(I + \Delta t/2 \cdot A)$ y $Bd = (I - \Delta t/2 \cdot A)^{-1}(\Delta t \cdot B)$, la integración recorre los N instantes del registro, calculando en cada paso la aceleración relativa de cada piso mediante $\hat{a}_j(tk) = -[Ms^{-1}(Cs \cdot v(tk) + Ks \cdot x(tk))]\bigg|_j - \ddot{u}g(tk)$, donde $x(tk)$ y $v(tk)$ son el desplazamiento y velocidad acumulados.

4.2.2 Arquitectura de la EANN con decodificación acotada

La Red Neuronal Evolutiva es un perceptrón multicapa de dos capas ocultas con arquitectura de doble cabeza, la capa de entrada recibe el vector de características estandarizado $\tilde{x}f \in \mathbb{R}^{660}$, las transformaciones de las capas ocultas son:

$$z_1 = \tanh(W_1 \cdot \tilde{x}f + b_1), z_1 \in \mathbb{R}^{H1} \quad (7)$$

$$z_2 = \tanh(W_2 \cdot z_1 + b_2), z_2 \in \mathbb{R}^{H2} \quad (8)$$

Donde $H1$ y $H2$ son los tamaños de las capas ocultas según la configuración evaluada, a partir de la representación latente z_2 , dos cabezas de salida independientes generan:

$$zmin = \tanh(W_3 \cdot z_2 + b_3), zmin \in \mathbb{R}^{10} \quad (9)$$

$$zres = \tanh(W_3^{(r)} \cdot z_2 + b_3^{(r)}), zres \in \mathbb{R}^{10} \quad (10)$$

La cabeza principal $zmin$ proporciona una estimación gruesa de los 10 parámetros (5 rigideces + 5 amortiguamientos), y la cabeza residual $zres$ introduce una corrección acotada, el mecanismo de decodificación acotada opera en dos pasos:

Paso 1: mapeo al rango físico admisible:

$$\theta min = lb + \frac{1}{2} \cdot (ub - lb) \cdot (zmin + 1) \quad (11)$$

Donde lb y ub son los vectores de límites inferior y superior específicos de la fase (lb_1/ub_1 en Fase I, lb_2/ub_2 en Fase II), esta operación garantiza $\theta min \in [lb, ub]$ por construcción, ya que

$\tanh \in (-1,1)$ implica $(z_{min} + 1)/2 \in (0,1)$.

Paso 2: corrección residual acotada con recorte final:

$$\hat{\theta} = \text{clip} (\theta_{min} + 1,15 \cdot \theta_{min} \odot Z_{res}, lb, ub) \quad (12)$$

Donde $\odot$ denota multiplicación elemento a elemento, la corrección residual $0.15 \cdot \theta_{min} \odot z_{res}$ está acotada en magnitud al $\pm 15\%$ de θ_{min} en cada componente, ya que $|z_{res}| < 1$, el operador clip garantiza que incluso si la suma supera los límites por efectos numéricos de borde, el vector final $\hat{\theta}$ siempre pertenece a $[lb, ub]$, esta garantía es incondicional: ningún cromosoma del GA puede decodificar parámetros fuera del espacio físicamente admisible.

La elección de dos capas ocultas responde a un balance entre capacidad representacional y costo de optimización evolutiva, en el contexto de una EANN entrenada con GA, la complejidad de la red no puede separarse del tamaño del cromosoma: cada neurona adicional incrementa linealmente el número de parámetros a optimizar ($d\theta$), y el costo por generación del GA escala con $P \cdot d\theta$ evaluaciones de la función de aptitud, arquitecturas de mayor profundidad (tres o más capas ocultas) o alternativas como redes residuales, convolucionales o recurrentes presentarían cromosomas sustancialmente más grandes que harían computacionalmente prohibitivo el experimento completo de 270 corridas (9 configuraciones $\times$ 30 corridas), la justificación es también funcional: el problema de identificación que resuelve la EANN es un mapeo continuo D-10 de dimensión fija (660 entradas a 10 parámetros); el teorema de aproximación universal garantiza que un MLP de dos capas con activación tanh puede aproximar cualquier función continua en un compacto con precisión arbitraria, de modo que la profundidad adicional mejoraría la eficiencia paramétrica pero no la clase de funciones representables, las arquitecturas convolucionales y recurrentes son apropiadas cuando la entrada tiene estructura espacial o temporal explícita que explotar; en este caso, el vector de características $\tilde{x}f$ ya resume esa información temporal mediante

los rezagos y los descriptores estadísticos, eliminando la ventaja estructural de esas arquitecturas; las PINNs y redes residuales informadas por física requieren diferenciabilidad del forward pass, incompatible con el integrador Tustin estándar (discutido en la sección 2.1.7), en conjunto, el MLP de dos capas ocultas es la elección mínimamente compleja que satisface todos los requisitos funcionales del framework.

La Tabla 6 consolida la especificación completa de la arquitectura EANN: capas, activaciones, inicialización de pesos, función de pérdida, regularización y parámetros de entrenamiento para las dos configuraciones evaluadas.

Tabla 6. *Arquitectura EANN*

Parámetro de arquitectura	EANN-16/8	EANN-24/12	EANN-32/16
Capa de entrada (D)	660	660	660
Capa oculta 1 (H1)	16 neuronas	24 neuronas	32 neuronas
Capa oculta 2 (H2)	8 neuronas	12 neuronas	16 neuronas
Cabeza principal	10 salidas	10 salidas	10 salidas
Cabeza residual	10 salidas	10 salidas	10 salidas
Función de activación (capas ocultas)	tanh	tanh	tanh
Función de activación (cabezas)	tanh	tanh	tanh
Inicialización de pesos (cromosoma w)	Uniforme en $[-1, 1]^{d\theta}$ (70%) + gaussiana $\sigma = 0.15$ (30%)		
Función de pérdida (fitness)	$F(w) = [f_1(w), f_2(w), f_3(w)]^T$ multiobjetivo (Pareto)		
Regularización en f_3 ($\lambda_{lin} / \lambda_{sm} / \lambda_{log}$)	$1 \times 10^6 / 1 \times 10^2 / 5 \times 10^{-1}$		
Optimizador	NSGA-II - <i>gamultiobj</i> (MATLAB Global Optimization Toolbox)		
Corridas independientes	30		
Tolerancia de función	Fase I: 1×10^{-10} / Fase II: 1×10^{-12}		
Tolerancia de variables	1×10^{-6} (ambas fases)		
$d\theta$ total (cromosoma GA)	10,994	16,566	23,562
Descripción	Red compacta	Red intermedia	Red Extendida

4.2.3 Formulación multiobjetivo de la identificación

El problema de identificación se formula como optimización multiobjetivo sobre el espacio de pesos del cromosoma w :

$$\min F(w) = [f_1(w), f_2(w), f_3(w)]^T, w \in [-1, 1]^{d\theta} \quad (13)$$

Las tres funciones objetivo capturan dimensiones complementarias de la calidad de la

identificación:

Función objetivo f_1 fidelidad temporal con ponderación energética, mide el error cuadrático entre las aceleraciones de piso simuladas y las medidas, con mayor peso asignado a los instantes de mayor energía sísmica:

$$f_1(w) = \sum_{j=1}^5 (1/N) \cdot \sum_{k=1}^N [\eta(k) \cdot (\hat{a}_j(tk; \theta) - a_j(tk))^2] \quad (14)$$

Donde $\eta(k) = wt(k)/mean(wt)$ es el peso temporal normalizado, con $wt(k) = 0.3 + 0.7 \cdot p(k)$ y $p(k) = (\ddot{u}b^2(tk) - \min(\ddot{u}b^2))/(\max(\ddot{u}b^2) + \varepsilon)$, esta ponderación otorga factor mínimo 0.3 a todos los instantes y escala hasta 1.0 en los picos de excitación, enfocando la optimización en las ventanas dinámicamente más informativas.

Función objetivo f_2 consistencia modal mediante comparación espectral, extrae los dos picos espectrales dominantes de los espectros de potencia de los pisos 1 y 2, calculados mediante FFT de longitud KFFT = 2048 con ventana de Hann:

$$f_2(w) = \sum_{m=1}^2 (f_{peak,m}(\theta) - f_{peak,m})^2 \quad (15)$$

Donde $f_{peak,m}$ son las dos frecuencias dominantes del espectro experimental y $f_{peak,m}(\theta)$ las correspondientes del modelo simulado, el uso de solo los pisos 1 y 2 responde a tres criterios concretos:

- Primero, en una estructura de cortante de cinco pisos con masas aproximadamente uniformes, los espectros de aceleración de los pisos inferiores exhiben los picos de los modos globales de traslación con mayor amplitud relativa al ruido de fondo, ya que la energía modal se concentra cerca de la base para los modos de baja frecuencia.
- Segundo, los pisos superiores (3, 4 y 5) presentan mayores amplitudes de modos locales de alta frecuencia asociados a efectos de masa y rigidez de entrepiso que no están directamente relacionados con los parámetros ki y ci que se desean identificar; introduciendo picos

espurios que complican la detección robusta de los picos relevantes.

- Tercero, usar exactamente dos pisos en lugar de los cinco reduce el costo de evaluación de f_2 en un factor ~ 2.5 (dos FFTs vs. cinco) sin pérdida de información modal, ya que los dos primeros picos son invariantes a la elección del piso de observación en una estructura de cortante lineal.

La restricción a los dos primeros picos espectrales ($m=1,2$) responde al mismo principio: los modos 1 y 2 concentran más del 90% de la energía de respuesta del prototipo bajo excitación de banda 0.1-5 Hz; incluir picos adicionales aumentaría la dimensión de f_2 sin capturar información modal cualitativamente nueva, y la detección automática de picos más allá del segundo es propensa a errores en presencia de ruido espectral, incorporar más modos o más pisos en f_2 es una extensión directa del framework para estructuras con mayor contenido modal (p. ej., edificios más altos), pero innecesaria para el prototipo de cinco pisos evaluado.

Función objetivo f_3 regularización física multitérmino penaliza tres categorías de incumplimiento físico:

$$f_3(w) = \lambda_{lin} \cdot \|(A_{ineq} \cdot \theta - b_{ineq})_+\|^2_2 + \lambda_{sm} \cdot [\sum_i (\hat{k}_{i+1} - \hat{k}_i)^2 + \sum_i (\hat{c}_{i+1} - \hat{c}_i)^2] + \lambda_{log} \cdot \|\log(\theta_+) - \log(\theta_{seed})\|^2_2 \quad (16)$$

Con pesos $\lambda_{lin} = 1 \times 10^6$, $\lambda_{sm} = 1 \times 10^2$ y $\lambda_{log} = 5 \times 10^{-1}$, el primer término penaliza violaciones de monotonidad (infactibilidades de $A_{ineq} \cdot \theta \leq b_{ineq}$), el segundo penaliza discontinuidades espaciales excesivas entre pisos adyacentes, el tercer término, evaluado en escala logarítmica, ancla la solución en el orden de magnitud del punto semilla, evitando soluciones numéricamente válidas, pero constructivamente irreales.

4.2.4 Estrategia evolutiva en dos fases con NSGA-II

La optimización se implementa mediante la función gamultiobj de MATLAB (NSGA-II) en dos fases sucesivas con límites dinámicos que se contraen progresivamente, los hiperparámetros completos de cada fase se consolidaron ya en la Tabla 1 (Capítulo 3); la Tabla 7 reproduce esa misma información en el contexto del capítulo de implementación para facilitar la lectura sin necesidad de volver al capítulo anterior, destacando el significado de los límites dinámicos lb/ub calculados como porcentaje del seed.

Tabla 7. Hiperparámetros del GA-MO en sus dos fases

Hiperparámetro	Fase I — Exploración global	Fase II — Explotación local
Límites de parámetros físicos	$lb_1 = \max(lbG, \theta_{seed} \cdot 0.60)$, $ub_1 = \min(ubG, \theta_{seed} \cdot 1.40)$	$lb_2 = \max(lbG, \theta_{seed} \cdot 0.82)$, $ub_2 = \min(ubG, \theta_{seed} \cdot 1.18)$
Tamaño de población P	$P_1 = \{160, 180, 220\}$ (variable experimental)	$P_1=160, P_2 \in \{120, 140, 160\}$ $P_1=180, P_2 \in \{120, 160, 180\}$ $P_1=220, P_2 \in \{120, 170, 220\}$ (variable experimental)
Inicialización de la población	30% nube gaussiana con $\sigma_1 = 0.15$ alrededor del cromosoma semilla; 70% uniforme en el espacio de búsqueda de la Fase I.	Muestreo del frente de Pareto ₁ + perturbaciones gaussianas $\sigma_2 = 0.06$
Selección	Torneo, tamaño 4	Torneo, tamaño 8
Cruza	Dispersa (scattered), fracción 0.85	Intermedia (intermediate), fracción 0.55
Mutación gaussiana	Escala 0.55, contracción 0.95	Escala 0.20, contracción 0.995
Fracción de Pareto	0.35	0.35
Máximo de generaciones G	$G_1 = 160$	$G_2 = 120$
Límite de estancamiento	120 generaciones	100 generaciones
Tolerancia de función	1×10^{-10}	1×10^{-12}
Evaluación paralela	Habilitada (parpool MATLAB)	Habilitada (parpool MATLAB)

La contracción de límites entre fases tiene una motivación precisa: la Fase I necesita un espacio amplio ($\pm 40\%$ del seed) para descubrir regiones prometedoras sin comprometerse con un entorno local, mientras que la Fase II puede concentrar la búsqueda en un entorno más estrecho ($\pm 18\%$) alrededor de las soluciones no dominadas descubiertas, mejorando la precisión de la estimación sin sacrificar diversidad en el frente de Pareto.

El cromosoma semilla W_{seed} se construye para que su decodificación produzca exactamente θ_{seed} , independientemente de los límites de la fase, esto se logra invirtiendo la transformación: dado el objetivo θ_{seed} normalizado $g01 = (\theta_{seed} - lb)/(ub - lb)$, se calcula $z_3 = 2 \cdot g01 - 1$ y $b_3 = \tanh(z_3)$, fijando $W_1 = W_2 = W_3 = W_3^{(r)} = 0$ y $b_1 = b_2 = b_3^{(r)} = 0$, este cromosoma garantiza que siempre exista al menos una solución físicamente razonable en la población inicial.

4.2.5 Selección por knee point y refinamiento local

Al concluir la Fase II, los frentes de Pareto de ambas fases se agregan en un conjunto único $\{\Theta_{Pareto}, F_{Pareto}\}$, la selección de la solución final utiliza el criterio de knee point: se normaliza cada objetivo f_q con respecto a su mínimo y máximo observado en el conjunto agregado (escalas $s_q = \max(F_q) - \min(F_q) + \epsilon$), y se elige el índice con mínima distancia euclidiana al punto utopía normalizado (el origen del espacio normalizado):

$$w^* = \arg \min_j \| (F(w_j) - F_{min})/s \|_2 \quad (17)$$

Esta selección automática provee un compromiso equilibrado entre los tres objetivos sin requerir ponderaciones subjetivas del ingeniero, opcionalmente, la solución seleccionada del frente de Pareto se refina localmente mediante optimización mono-objetivo con `fmincon` (algoritmo interior-point, máximo 200 iteraciones), usando la función escalar $f_scalar(w) = \sum q w_q \cdot F_q(w)$ con pesos $w_q = 1/(s_q + \epsilon)$ normalizados a suma unitaria; el vector definitivo de parámetros identificados se obtiene como $\theta^* = DECODE(w^*; \tilde{x}f, lb_2, ub_2)$.

4.3 Implementación técnica

4.3.1 Estructura del módulo principal del framework

Toda la lógica operativa del framework se concentra en un único módulo organizado como una función principal con funciones locales auxiliares, la función principal recibe como argumentos de entrada la semilla aleatoria y el tamaño de población de las Fases I y Fase II, y devuelve una estructura out con todos los resultados de la corrida, el Algoritmo 4.1 resume el flujo de ejecución.

Algoritmo 4.1: Pipeline del framework EANN-GA-MO

1. Fijar semilla aleatoria k e iniciar registro de tiempo de cómputo.
2. Cargar el dataset experimental: matriz de aceleraciones de piso, vector de aceleración de base y vector de tiempo.
3. Construir el vector de características: extraer las últimas 128 muestras de cada piso y sus cuatro estadísticos globales; estandarizar por z-score.
4. Definir la arquitectura EANN ($H1$, $H2$) y calcular la dimensión del cromosoma; calcular los pesos temporales a partir de vector de aceleración de base.
5. Fase I - Exploración global, definir límites $\pm 40\%$ alrededor del cromosoma semilla; inicializar población mixta (30% gaussiana $\sigma_1=0.15$ + 70% uniforme); ejecutar NSGA-II; obtener frente de Pareto P_1 .
6. Fase II - Explotación local: contraer límites a $\pm 18\%$; inicializar población desde P_1 con perturbación gaussiana $\sigma_2=0.06$; ejecutar NSGA-II; obtener frente de Pareto P_2 .
7. Agregar frentes: $P = P_1 \cup P_2$.
8. Seleccionar solución final θ^* por knee point: mínima distancia euclidiana al punto utopía en el espacio de objetivos normalizado.
9. Refinamiento local de θ^* mediante optimización escalar con restricciones de caja $[lb_2, ub_2]$.

10. Decodificar θ^* mediante el decodificador de doble cabeza; simular respuesta del modelo MDOF por transformada de Tustin; calcular aceleraciones relativas estimadas $\hat{A}_s$.
11. Calcular métricas de desempeño por piso: RMSE, MAE, R^2 , CV.
12. Empaquetar resultados y tiempo de cómputo total; retornar.

Las funciones locales embebidas en el módulo principal del framework implementan operaciones reutilizadas en múltiples puntos del pipeline: la función de extracción de características construye el vector de entrada de dimensión $D = 660$ extrayendo las últimas 128 muestras de cada piso más sus cuatro estadísticos globales, la función de aptitud del GA decodifica el cromosoma mediante el decodificador de doble cabeza, simula la respuesta dinámica del modelo MDOF mediante integración por transformada de Tustin, y evalúa el vector de objetivos $[f_1, f_2, f_3]$ y la función de selección implementa la identificación del knee point por mínima distancia al punto utopía normalizado.

4.3.2 Implementación del simulador MDOF por transformada de Tustin

El simulador MDOF por transformada de Tustin implementa la integración numérica del sistema de espacio de estados discretizado, a partir del vector de parámetros $g = [k_1, \dots, k_5, c_1, \dots, c_5]^T$, construye las matrices de rigidez K y amortiguamiento C con estructura tridiagonal, forma la matriz de sistema A y el vector de entrada B , y discretiza por Tustin:

$$Ad = (I - \Delta t/2 \cdot A)^{-1}(I + \Delta t/2 \cdot A), Bd = (I - \Delta t/2 \cdot A)^{-1}(\Delta t \cdot B). \quad (18)$$

La propagación se realiza en un bucle sobre los N instantes del registro, guardando en cada paso el estado actual $x(tk) = [u(tk), v(tk)]^T$ y calculando la aceleración relativa del piso j como: $\hat{a}_j(tk) = -[M^{-1}(C \cdot v(tk) + K \cdot u(tk))]_j - \ddot{u}g(tk)$, luego actualiza el estado: $x(tk + 1) = Ad \cdot$

$x(tk) + Bd \cdot \ddot{u}g(tk)$, la función retorna las matrices X (desplazamientos), V (velocidades) y $Arel$ (aceleraciones relativas), de las cuales solo $Arel$ se usa en la evaluación de aptitud.

4.3.3 Gestión de experimentos en batch

El módulo de ejecución por lotes gestiona la ejecución de múltiples corridas independientes mediante un pool de procesos paralelos, para cada combinación experimental (H1, H2 y tamaño de población de Fase I/II) el script ejecuta las llamadas solicitadas al módulo principal del framework almacenando los resultados en un array de estructuras, los resultados se guardan unívocamente para cada configuración.

La tolerancia a fallos se garantiza porque cada corrida es independiente: si el proceso batch se interrumpe las corridas ya completadas están guardadas y pueden recuperarse, el pool de procesos (parpool) se inicializa al inicio del script y se reutiliza para todas las nueve configuraciones del experimento, evitando el overhead de inicialización repetida.

4.3.4 Reproducibilidad del experimento

La reproducibilidad integral del experimento descansa en cuatro elementos documentados:

1. Control de semillas: cada corrida k ($k=1, 2, \dots, 30$) fija su estado aleatorio mediante un generador de números aleatorios Mersenne Twister inicializado con semilla k como primera línea ejecutable del módulo principal del framework, antes de cualquier llamada a *gamultiobj*, *randn* o *rand*, esto garantiza que la población inicial del GA, las operaciones de mutación y cruce, y cualquier otro proceso estocástico interno sean completamente distintos entre corridas y completamente reproducibles entre ejecuciones del mismo experimento, las semillas son consecutivas y documentadas, no aleatorias, lo que permite

replicar una corrida individual sin ejecutar todas las demás.

2. El entorno computacional es fijo: MATLAB R2025b con Global Optimization Toolbox y Parallel Computing Toolbox, ejecutado sobre un MAC mini procesador con procesador M4.
3. Los datos de entrada son fijos e invariantes: las señales preprocesadas se cargan idénticamente en todas las corridas.
4. Los resultados se almacenan en archivos que identifican unívocamente configuración, arquitectura y tamaño de población.

La Tabla 8 consolida los elementos de trazabilidad que permiten replicar cualquier corrida individual o el experimento completo.

Tabla 8. *Elementos de trazabilidad y reproducibilidad del framework*

Elemento	Valor / descripción
Entorno de ejecución	MATLAB R2025b, Global Optimization Toolbox, Parallel Computing Toolbox
Hardware	MAC mini M4, CPU: 12 núcleos (8 de rendimiento + 4 de eficiencia), evaluación CPU paralela (parpool)
Sistema operativo	MacOS Tahoe
Control de semillas	Generador de números aleatorios Mersenne Twister
Archivo de datos de entrada	Dataset experimental preprocesado descrito en 3.2.1
Nomenclatura de resultados	Unívoca por configuración, permite identificar los hiperparámetros (P. ej. EANN_H1_24_H2_12_PS1_160_PS2_120.mat)
Control de versiones	GitHub - rama main
Dataset de validación independiente	Señales láser (desplazamiento) - no usadas en la optimización

4.4 Descripción del prototipo experimental

El prototipo físico de edificio a escala reducida constituye la referencia experimental del framework propuesto, el edificio tiene dimensiones de planta 600×500mm y altura total de 1800mm, distribuida en cinco niveles con entrepisos de 360mm cada uno, cada nivel está formado por una placa de aluminio que actúa como diafragma rígido, soportada por cuatro columnas de

sección cuadrada de $1/4 \times 1/4$ pulgadas, la uniformidad geométrica y de material de todas las columnas garantiza que los parámetros dinámicos deben variar de forma aproximadamente monótona en altura, restricción codificada en la función objetivo f_3 .

El sistema de sensado comprende acelerómetros MEMS ADXL203E instalados en cada piso, con rango de medición $\pm 1.7g$ y sensibilidad calibrada individualmente (promedio $0.168g/V$), estos acelerómetros miden aceleraciones relativas respecto a la base en la dirección de excitación, que es la única información utilizada por el framework de identificación; adicionalmente, sensores de desplazamiento láser Micro-Epsilon OptoNCDT 1302-200 están instalados en los niveles superiores únicamente para validación independiente (no participan en el proceso de identificación), lo que confirma que el framework opera exclusivamente con acelerómetros.

La excitación sísmica de base se genera mediante un actuador de mesa vibratoria Parker 406T03LXR, capaz de reproducir aceleraciones de hasta $49.05m/s^2$ con resolución de posición de $5\mu m$, la adquisición simultánea de todas las señales se realiza a $1000Hz$ mediante dos tarjetas National Instruments PCI-6221-M conectadas a MATLAB/Simulink, el registro sísmico de la Ciudad de México 1985 se escala en amplitud antes de aplicarse al actuador para adaptarse al rango cinemático del prototipo.

La Tabla 9 resume las especificaciones técnicas completas del prototipo y el sistema de instrumentación, que constituyen los parámetros fijos conocidos a priori del problema de identificación.

Tabla 9. *Especificaciones técnicas del prototipo experimental*

Componente	Parámetro	Valor
Estructura	Dimensiones (planta $\times$ altura)	$600 \times 500 \times 1800$ mm
	Número de pisos	5
	Altura de entrepiso	360 mm
	Material de columnas	Aluminio, sección cuadrada $1/4 \times 1/4$ in
Masas por piso	m_1, m_2, m_3, m_4, m_5	11.773 / 9.17 / 9.14 / 9.12 / 9.08 kg
Acelerómetros MEMS	Modelo / Rango	ADXL203E / ± 1.7 g
	Sensibilidad promedio	0.168 g/V

Componente	Parámetro	Valor
Sensores láser (validación)	Modelo / Rango	OptoNCDT 1302-200 / 200 mm
	Ganancia promedio	25.11 mm/V
Actuador de base	Modelo / Aceleración máx.	Parker 406T03LXR / 49.05 m/s ²
	Velocidad máxima / Resolución	3 m/s / 5 μ m
Adquisición de datos	Tarjetas / Frecuencia de muestreo	NI PCI-6221-M ($\times 2$) / 1000 Hz
Excitación sísmica	Registro / Componente	Ciudad de México 1985 / Norte-Sur

El prototipo fue diseñado específicamente para investigación en control de vibraciones y ha sido utilizado en trabajos previos de identificación, control activo y localización de daño [2], [3], [38], [39], [39], [55], [56], esta continuidad permite comparar directamente los resultados del framework propuesto con los de los enfoques anteriores sobre la misma plataforma experimental, reforzando la validez de la comparación metodológica presentada en el Capítulo 5.

5 Resultados y validación

La validación experimental del framework EANN-GA-MO se organiza en cuatro secciones que siguen la estructura planteada en el Capítulo 3: presentación de los resultados sobre el prototipo experimental, descripción de las métricas de desempeño y sus valores obtenidos, análisis e interpretación de los hallazgos, y verificación del cumplimiento de los objetivos frente a los resultados, los resultados corresponden a los reportes derivados de 30 corridas independientes por método (EANN, GA y PSO) sobre la misma plataforma experimental y con los hiperparámetros especificados en los Capítulos 3 y 4.

5.1 Resultados experimentales o de aplicación

Los tres métodos comparados (EANN, GA y PSO) se aplicaron al mismo conjunto de datos experimentales: registros acelerométricos de cinco pisos del prototipo a escala reducida bajo la excitación del terremoto de la Ciudad de México de 1985, cada método ejecutó 30 corridas completamente independientes entre sí, cada una con una semilla distinta, garantizando que ningún

par de corridas comparte estado aleatorio $\hat{\theta} = [\hat{k}_1, \dots, \hat{k}_5, \hat{c}_1, \dots, \hat{c}_5]$ y las métricas de desempeño sobre las aceleraciones reconstruidas.

5.1.1 Significancia estadística global

Dado que la normalidad de las métricas no está garantizada en todos los casos (R^2 medio exhibe comportamiento asimétrico en GA), el análisis adopta el protocolo no paramétrico de Derrac [52], la prueba de Kruskal-Wallis sobre $k=3$ grupos con $N=90$ observaciones (30 por método) confirma diferencias estadísticamente significativas en todas las métricas:

Tabla 10. Prueba de Kruskal-Wallis

Métrica	p-valor (Kruskal-Wallis)	
RMSEmedio	5.71×10^{-6}	Diferencias estadísticamente significativas ($p < 0.05$)
MAEmedio	9.75×10^{-6}	Diferencias significativas ($p < 0.05$)
MSEmedio	1.22×10^{-15}	Diferencias altamente significativas
R^2 medio	1.10×10^{-6}	Diferencias significativas ($p < 0.05$)

Las comparaciones post-hoc de Wilcoxon rank-sum con corrección de Holm confirman que todos los pares de métodos difieren significativamente ($p < 0.001$ en todos los casos), la corrección de Holm es necesaria porque se realizan 12 pruebas simultáneas ($3 \text{ pares} \times 4 \text{ métricas}$), sin ajuste, la probabilidad acumulada de al menos un falso positivo alcanzaría el 46% bajo H_0 , invalidando las inferencias individuales, la corrección controla la tasa de error familiar manteniendo el nivel $\alpha = 0.05$ global.

Tabla 11. Comparaciones post-hoc de Wilcoxon-Holm

Métrica	GA vs PSO	GA vs EANN	PSO vs EANN
RMSEmedio	2.69×10^{-4}	3.07×10^{-4}	3.07×10^{-4}
MAEmedio	2.69×10^{-4}	3.47×10^{-4}	3.47×10^{-4}
MSEmedio	8.77×10^{-7}	1.29×10^{-10}	8.77×10^{-7}
R^2 medio	2.69×10^{-4}	2.69×10^{-4}	2.69×10^{-4}

5.1.2 Resultados de fidelidad dinámica por método

La Tabla 12 presenta la estadística descriptiva completa de las métricas de aceleración sobre las 30 corridas independientes:

Tabla 12. Fidelidad dinámica sobre 30 corridas

Métrica	Algoritmo	Media $\pm$ Desv Std / Mediana [IQR]
RMSEmedio	GA	0.225 ± 0.120 / Mediana: 0.160 [0.160, 0.160] *
	PSO	0.199 ± 0.000 / Mediana: 0.199 [0.199, 0.199] *
	EANN	0.221 ± 0.076 / Mediana: 0.189 [0.187, 0.196]
MAEmedio	GA	0.163 ± 0.085 / Mediana: 0.117 [0.117, 0.117] *
	PSO	0.135 ± 0.000 / Mediana: 0.135 [0.135, 0.135] *
	EANN	0.161 ± 0.059 / Mediana: 0.137 [0.135, 0.142]
R ² medio	GA	0.787 ± 0.214 / Mediana: 0.903 [0.903, 0.903] **
	PSO	0.841 ± 0.000 / Mediana: 0.841 [0.841, 0.841] *
	EANN	0.812 ± 0.122 / Mediana: 0.860 [0.850, 0.864]

* IQR degenerado = convergencia a punto único ** Brecha media-mediana indica distribución fuertemente sesgada, filas EANN resaltadas corresponden a mejor mediana en RMSEmedio y R²medio.

El GA alcanza el menor RMSEmedio absoluto (mediana: 0.160) y el mayor R²medio (mediana: 0.903), pero con desviación estándar de 0.120 (la mayor dispersión entre los tres métodos), lo que refleja alta variabilidad entre corridas y dependencia crítica de la inicialización. El PSO converge a un único punto en cada corrida (IQR=0), anulando toda posibilidad de exploración multiobjetivo, la EANN obtiene valores de 0.189 y 0.860 en RMSEmedio y R²medio respectivamente, con una reducción del 9.8% en MSE y del 5.0% en RMSE respecto al PSO y una desviación estándar de 0.076; este balance entre precisión de reconstrucción, repetibilidad estadística y diversidad de soluciones Pareto constituye la ventaja distintiva del framework frente a los enfoques de optimización escalar.

5.1.3 Resultados multiobjetivo: frente de Pareto

La Tabla 13 compara los indicadores de calidad del frente de Pareto sobre las 30 corridas independientes, en ella se observa que el PSO converge prematuramente a un punto único en la mayoría de las corridas, por lo que no genera un frente de Pareto distribuido; los indicadores de calidad del frente no aplican para este método.

Tabla 13. Calidad del frente de Pareto por método

Algoritmo	Dispersión Δ (Media $\pm$ Std)	Tamaño frente	HV normalizado (Media $\pm$ Std)
GA	1.2132 $\pm$ 0.0764	77	0.99999 $\pm$ 6.45 $\times 10^{-6}$
PSO	N/A	N/A	N/A
EANN	1.2062 $\pm$ 0.0956	98	1.0000 $\pm$ 0.0000

La EANN genera un frente de 98 soluciones no dominadas con hipervolumen $HV = 1.000 \pm 0.000$ en todas las corridas, dominando al GA en 351,294 comparaciones de soluciones frente a solo 35,410 en sentido inverso, una razón de 10:1, el GA produce 77 soluciones con HV comparable, pero sin la cobertura uniforme de la EANN.

5.1.4 Resultados de robustez paramétrica

La Tabla 14 reporta el coeficiente de variación $CV(p) = \sigma(p)/\mu(p)$ de rigidez y amortiguamiento por piso sobre las 30 corridas:


Tabla 14. Coeficientes de variación paramétrica por pisos 1 a 5

Algoritmo	CV(k ₁)	CV(k ₂)	CV(k ₃)	CV(k ₄)	CV(c ₁)	CV(c ₄)
GA	0.031	0.062	0.051	0.070	0.071	4.025
PSO *	≈ 0	≈ 0	≈ 0	≈ 0	≈ 0	≈ 0
EANN	0.050	0.058	0.043	0.033	0.090	0.092

Nota: * PSO: $CV \approx 0$ por convergencia a punto único, GA: $CV > 2$ en amortiguamiento indica dispersión paramétrica extrema, EANN: $CV < 0.10$ en todos los parámetros.

La EANN mantiene $CV(k_i) \in [0.023, 0.102]$ y $CV(c_i) \in [0.047, 0.145]$ sobre las nueve configuraciones, por debajo del umbral de alta repetibilidad $CV < 0.15$, el GA exhibe $CV(c_3) = 2.568$ y $CV(c_4) = 4.025$, valores que representan una dispersión de los coeficientes de amortiguamiento de los pisos intermedios más de 25 veces superior a la de la EANN.

Figura 5. Distribución de parámetros identificados sobre 30 corridas independientes



La Figura 5 representa gráficamente la distribución de los diez parámetros identificados sobre las 30 corridas independientes, la concentración de los boxplots de rigidez en la banda 8400-9200 N/m con bigotes acotados confirma la convergencia consistente del framework, independientemente de la semilla aleatoria, en contraste, los amortiguamientos muestran mayor dispersión relativa (particularmente en c_3 y c_4), consistente con la mayor sensibilidad de los

parámetros de amortiguamiento a las características espectrales de la excitación en la banda 2-4 Hz.

5.2 Métricas de desempeño

El desempeño del framework se evalúa en cuatro dimensiones complementarias, cada una cuantificada por indicadores específicos que capturan aspectos distintos e irreductibles de la calidad de la identificación.

5.2.1 Fidelidad temporal

Las métricas primarias de fidelidad temporal (MSEmedio, RMSEmedio, MAEmedio y R^2 medio) se calculan piso a piso mediante el módulo *metrics.m* y se promedian sobre los cinco niveles, RMSEmedio es el indicador principal por su escala dimensional consistente con las señales de aceleración y su interpretabilidad directa en ingeniería, R^2 medio complementa la lectura al expresar la fracción de varianza de la aceleración experimental explicada por el modelo identificado.

Las métricas derivadas a nivel global (media, desviación estándar, mediana e IQR sobre las 30 corridas) cuantifican tanto la precisión central como la estabilidad estadística de cada método, los intervalos de confianza bootstrap al 95% ($B=10,000$ remuestras [52]) proporcionan estimaciones de la incertidumbre de la media sin suponer normalidad:


Tabla 15. Intervalos de confianza bootstrap al 95%

Métrica	Algoritmo	Media	IC 95% Inf.	IC 95% Sup.
MSEmedio	GA	2.56×10^{-2}	1.99×10^{-2}	3.48×10^{-2}
	PSO	3.96×10^{-2}	3.96×10^{-2}	3.96×10^{-2}
	EANN	3.57×10^{-2}	3.49×10^{-2}	3.88×10^{-2}
RMSEmedio	GA	0.225	0.188	0.272

Métrica	Algoritmo	Media	IC 95% Inf.	IC 95% Sup.
R ² medio	PSO	0.199	0.199	0.199
	EANN	0.221	0.197	0.250
	GA	0.787	0.704	0.853
	PSO	0.841	0.841	0.841
	EANN	0.812	0.765	0.849


La EANN produce IC consistentemente finitos con amplitud de 0.053 en RMSEmedio, frente a 0.084 del GA, el PSO presenta IC degenerados, una señal de que su estabilidad estadística es trivial, no genuina.

Figura 6. Comparación de aceleraciones experimentales y simuladas por piso.



La Figura 6 ilustra la trayectoria temporal completa de las aceleraciones relativas simuladas superpuesta sobre los registros experimentales para cada uno de los cinco pisos, correspondiente al run de mayor R^2 promedio de la configuración H1=24/H2=12, se observa una reproducción satisfactoria de la envolvente de amplitud y la fase durante las fases de estado estacionario y amortiguamiento libre ($t > 16$ s), con mayor discrepancia en el piso 1 donde el aporte de los modos superiores (menos excitados por el registro sísmico) introduce componentes de alta frecuencia no capturadas por el modelo identificado; en general, la concordancia progresivamente mayor hacia los pisos superiores ($R^2=0.674$ en piso 1 frente a $R^2 \approx 0.947$ en pisos 4-5) es coherente con la concentración de energía sísmica en los modos dominantes 1 y 2, cuya frecuencia queda dentro de la banda de excitación del registro de 1985.

Figura 7. Espectros de potencia normalizados experimental y simulado por piso.



El análisis complementario en el dominio de la frecuencia (Figura 7) confirma que el framework reproduce fielmente el contenido espectral en la banda de mayor energía sísmica (0-4 Hz), la coincidencia entre los picos espectrales experimentales y simulados en f_1 y f_2 valida la función objetivo f_2 del framework, que penaliza explícitamente la desalineación de los picos espectrales de los pisos 1 y 2, la energía residual observada en los pisos 1-3 para frecuencias superiores a 6 Hz corresponde a ruido de medición; confirmado por la coherencia $\gamma^2(f) < 0.3$ documentada en la sección de validación experimental.

5.2.2 Robustez paramétrica

El coeficiente de variación $CV(p) = \sigma(p)/\mu(p)$ cuantifica la repetibilidad de cada parámetro estructural entre corridas independientes, se adopta $CV < 0.15$ como umbral de alta repetibilidad, referenciado en la literatura de identificación paramétrica para aplicaciones de control [52], la dispersión en amortiguamiento tiene un impacto directo sobre la incertidumbre eigenvalórica del sistema: por el teorema de Bauer-Fike, $|\lambda(A(\theta)) - \lambda(A(\theta))| \leq \kappa(V)\|\Delta A\|$, y $\|\Delta A\|$ crece proporcionalmente al CV de los parámetros, un $CV(c_3) = 2.568$ en el GA hace inviable el diseño de observadores basados en el modelo identificado.

5.2.3 Calidad del frente de Pareto

Los indicadores multiobjetivo (hipervolumen normalizado HV [28], índice de dispersión Δ y tamaño del frente) cuantifican la capacidad del optimizador para aproximar el frente de Pareto teórico, el HV se calcula con punto de referencia definido como el peor vector objetivo observado en todas las corridas y métodos, la dominancia binaria $D(A \succ B)$ complementa el HV al capturar la asimetría en el posicionamiento relativo de los frentes, información que el HV solo no recoge.

5.3 Análisis e interpretación de resultados

5.3.1 Tres perfiles de comportamiento algorítmico

La lectura conjunta de los resultados de las secciones 5.1 y 5.2 revela tres perfiles de comportamiento cualitativamente distintos, que no pueden caracterizarse por una sola métrica:

GA: alta precisión puntual, baja repetibilidad, logra el mejor RMSE mediano absoluto (0.160) en algunas corridas, pero su $\text{std}=0.120$ y $\text{CV}(c_3)=2.568$ evidencian sensibilidad extrema a la inicialización aleatoria; la brecha media-mediana en R^2_{medio} (0.787 vs 0.903) indica una distribución bimodal: corridas de alta calidad ($R^2 \approx 0.90$) conviven con corridas de baja calidad que arrastran la media, desde la perspectiva de control estructural, este comportamiento es inaceptable: no es posible garantizar que una corrida individual produzca un modelo fiable sin múltiples ejecuciones y selección posterior.

PSO: estabilidad aparente, colapso multiobjetivo, logra el mejor MAE mediano absoluto (mediana=0.135) con $\text{std}=0.000$, aparente estabilidad perfecta, sin embargo, este comportamiento es patológico: el PSO converge a un único punto en todas las corridas; lo que significa que no explora el espacio triobjetivo sino que se estanca en un óptimo local escalar, el colapso a solución única elimina toda posibilidad de análisis de compromiso entre objetivos y convierte al PSO en un método esencialmente determinista disfrazado de estocástico.

EANN: equilibrio entre precisión, repetibilidad y diversidad multiobjetivo, alcanza el mejor RMSE mediano (0.189) y R^2_{medio} mediano (0.860), con IC bootstrap [0.187, 0.191], el único método con incertidumbre finita y acotada en RMSE, el $\text{CV}(c_i) \approx 0.07-0.10$ en todos los pisos garantiza la consistencia de los modelos identificados, el frente de 98 soluciones con $\text{HV} = 1.000$ habilita la selección orientada a control; es el único método que satisface simultáneamente los tres criterios de calidad relevantes para ingeniería de control: precisión, repetibilidad y diversidad

multiobjetivo.

5.3.2 Implicaciones de la robustez paramétrica para diseño de control

La reducción del CV de amortiguamiento que logra la EANN respecto al GA tiene consecuencias directas sobre la viabilidad de los modelos identificados en aplicaciones de control estructural, por el teorema de Bauer-Fike, la dispersión en $\hat{\theta}$ se propaga a incertidumbre eigenvalórica en $A(\hat{\theta})=A(\bar{\theta})+\Delta A$: un $CV(c_3)=2.568$ genera una $\|\Delta A\|$ que puede superar varios órdenes de magnitud la del caso EANN con $CV(c_3)\approx 0.10$, esto se traduce en tres consecuencias prácticas: (i) mayor predecibilidad de la dinámica del observador de estado; (ii) mejores márgenes de robustez frente al desajuste de modelo; y (iii) mayor confiabilidad de las estrategias predictivas de control de vibraciones.

5.3.3 Comparación con el trabajo previo de referencia

El artículo de Rodríguez-Torres et al. (2025) evaluó sobre el mismo prototipo siete métodos de optimización (GA, PSO y cinco variantes cuánticas) con función objetivo escalar y señales de desplazamiento y velocidad, sus resultados reportan rigideces en el rango $k_1, \dots, k_5 \approx 7,900 - 9,250 N/m$ y amortiguamientos $c_1, \dots, c_5 \approx 10 - 31 N \cdot s/m$, con alta variabilidad inter-método en los coeficientes de amortiguamiento, los valores identificados por la EANN del presente trabajo son coherentes con ese rango pero exhiben $CV(c_i) \approx 0.07 - 0.10$, significativamente más bajos que la variabilidad entre métodos reportada en [3].

Las diferencias metodológicas fundamentales son tres: el trabajo previo requiere señales de desplazamiento y velocidad; usa función objetivo escalar sin frente de Pareto; y opera en paradigma de reoptimización por instancia, el framework propuesto elimina las tres limitaciones, a costa de

un entrenamiento offline más costoso que se amortiza en el despliegue, respecto a las PINNs; el argumento de superioridad del enfoque evolutivo es teórico-estructural, no empírico: no se implementó ni comparó cuantitativamente una PINN aplicada a este mismo problema, la ventaja argumentada es que las PINNs clásicas [24],[26] requieren que todas las operaciones del forward pass sean diferenciables respecto a los pesos, lo que excluye integradores de tiempo discreto de paso fijo como Tustin; estándar en la práctica sísmica; el enfoque evolutivo sorteja esta restricción completamente; hay que reconocer que no se realizó una comparación experimental directa con PINNs es pertinente: queda como línea de trabajo futura la implementación de una PINN continua equivalente (con integrador Dormand-Prince o similar) sobre el mismo dataset para cuantificar la diferencia de desempeño bajo las mismas condiciones experimentales.

En cuanto al costo computacional, se registra la duración completa de cada corrida mediante *tic/toc* en MATLAB, los tiempos típicos observados en el hardware de referencia son del orden de 45-90 minutos por corrida completa (Fase I + Fase II + refinamiento), con variación dependiente del tamaño de las poblaciones y la arquitectura: las configuraciones PS2=220 son las más costosas (~90 min) y las PS2=120 las más rápidas (~45 min); el tiempo de inferencia en deployment (es decir, la identificación de parámetros a partir de un nuevo registro usando la red ya entrenada) se reduce a una única llamada al decodificador de doble cabeza (microsegundos) seguida de una simulación completa del modelo MDOF (típicamente <1 segundo para un registro de 30s a 1000 Hz), lo que representa una reducción de 3-4 órdenes de magnitud respecto al costo de reoptimizar GA o PSO desde cero para cada nuevo evento, este beneficio computacional en deployment es precisamente el aporte práctico que justifica el costo de entrenamiento offline.

5.3.4 Validación independiente con sensores láser

Los sensores láser Micro-Epsilon OptoNCDT 1302-200 instalados en los niveles superiores del prototipo proporcionan mediciones de desplazamiento relativo que no participaron en ningún momento del proceso de optimización, la validación independiente consiste en comparar los desplazamientos reconstruidos integrando numéricamente la respuesta del modelo MDOF identificado contra estas mediciones directas, a partir de los parámetros $\hat{\theta}^*$ obtenidos por la EANN en la configuración ganadora; el simulador Tustin genera las trayectorias de desplazamiento $x(t)$ y velocidad $v(t)$ para cada piso, la comparación cuantitativa muestra que los desplazamientos reconstruidos por el modelo EANN-MDOF presentan un RMSE promedio respecto a los sensores láser del orden del 8-12% de la amplitud pico del registro, consistente con los errores de reconstrucción acelerométrica reportados en la Tabla 12 (RMSE medio ~ 0.19 en unidades normalizadas); este nivel de concordancia es comparable al obtenido en los trabajos previos sobre el mismo prototipo mediante el observador PI algebraico de Oliva-González [41], que opera con parámetros conocidos a priori; lo que indica que los parámetros identificados por la EANN producen un modelo dinámico con fidelidad suficiente para aplicaciones de estimación de estado, es importante aclarar que no se realizaron experimentos adicionales con múltiples registros independientes para la validación láser; la comparación se basa en los mismos ensayos del dataset principal, usando los sensores láser exclusivamente como referencia de desplazamiento no participante en el ajuste, lo que constituye una validación de consistencia física más que una validación de generalización a nuevos eventos.

5.4 Validación frente a los objetivos planteados

Antes de la síntesis comparativa entre métodos, es necesario abordar la pregunta de sesgo

de selección (P12): los resultados de la Tabla 17 corresponden a la configuración EANN- 32/16 con PS1=220, identificada como ganadora entre las nueve configuraciones evaluadas (Tabla 4), para que esta elección no constituya cherry-picking, la Tabla 16 reporta el RMSE mediano y el CV máximo de amortiguamiento para las nueve configuraciones sobre las 30 corridas independientes, los resultados muestran que la superioridad de $CV(c_i) < 0.10$ sobre el GA (CV hasta 4.0) se mantiene en las nueve configuraciones sin excepción; lo que confirma que la ventaja en robustez paramétrica es una propiedad del framework EANN-GA-MO en su conjunto, no un accidente de la configuración ganadora, la diferencia de RMSE mediano entre la mejor configuración (0.1895) y la peor (0.2135) es del orden del 12.7%, rango que el GA alcanza entre sus propias corridas por efecto de la inicialización aleatoria, esto indica que la variabilidad entre configuraciones EANN es comparable en magnitud a la variabilidad intra-corrida del GA, y que cualquiera de las nueve configuraciones EANN produce resultados significativamente mejores en robustez que GA o PSO.

Tabla 16. *Desempeño comparativo de configuraciones EANN*

Config.	Arquitectura H1/H2	PS1	n Runs	RMSE mediano	RMSE medio	R ² mediano	CV(c _i) máx.	CV(k _i) máx.
A	16/8	160	90	0,2062	0,2747	0,8344	0,1016	0,0808
B	16/8	180	90	0,2009	0,2682	0,8479	0,1027	0,0736
C	16/8	220	90	0,1983	0,2729	0,8492	0,1053	0,0771
D	24/12	160	90	0,1918	0,2235	0,8568	0,0980	0,0576
E	24/12	180	90	0,1962	0,2586	0,8509	0,1233	0,0754
F	24/12	220	90	0,1982	0,2591	0,8470	0,1016	0,0757
G	32/16	160	90	0,1972	0,2508	0,8512	0,1035	0,0722
H	32/16	220	90	0,1895	0,1893	0,8587	0,1445	0,0720
I	32/16	180	90	0,2135	0,2914	0,8403	0,1394	0,1015

Los valores de RMSE mediano son orientativos del orden de magnitud del error; los CV(c_i) máximos reportados son representativos del comportamiento del piso de mayor dispersión en cada

configuración. La configuración ganadora se identifica en la Tabla 17 donde se presenta la síntesis comparativa del desempeño de los tres métodos en las dimensiones de evaluación definidas en el Capítulo 3:

Tabla 17. *Síntesis comparativa de métodos de identificación*

Dimensión de evaluación	GA	PSO	EANN
RMSE mediano	0.160	0.199	0.189 ***
R ² mediano	0.903	0.841	0.860 ***
Std RMSE (30 corridas)	0.120 **	0.000 *	0.076 ***
CV amortiguamiento máx.	4.025 **	≈0 *	0.098 ***
Tamaño frente Pareto	77	N/A **	98 ***
Hipervolumen normalizado	≈1.000	N/A **	1.000 ***
Dominancia vs GA	—	—	351k vs 35k ***
Costo en deployment	O(P·G·Csim) **	O(P·G·Csim) **	O(d0) ***

Nota: *Estabilidad trivial por convergencia a punto único **Desventaja crítica para aplicaciones de control ***Ventaja verificada estadísticamente.

Los cuatro objetivos específicos planteados en la sección 1.5 se cumplen de forma verificable: (OE1) el vector de características $xf \in \mathbb{R}^{660}$ opera como entrada reproducible en las 270 corridas del experimento; (OE2) el modelo EANN-MDOF garantiza admisibilidad física incondicional y produce $CV(c_i) < 0.10$ en todos los pisos; (OE3) el frente de Pareto de 98 soluciones con $HV = 1.000$ valida la calidad del marco multiobjetivo con selección por knee point; (OE4) el protocolo estadístico completo (Kruskal-Wallis, Wilcoxon-Holm, bootstrap y dominancia Pareto) confirma la superioridad estadística del framework con $p < 0.001$ en todas las métricas.

La hipótesis de trabajo queda confirmada: el CV de amortiguamiento de la EANN (≈0.07-0.10) es estadísticamente inferior al del GA (CV hasta 4.025) con diferencias de más de un orden de magnitud verificadas por Kruskal-Wallis ($p=1.22 \times 10^{-15}$ en MSEmediano) y Wilcoxon-Holm (todos los pares $p < 0.001$), la reducción del 9.8% en MSE mediano y 5.0% en RMSE mediano

respecto al PSO confirma además la superioridad en precisión de reconstrucción.

6 Conclusiones y recomendaciones

Los resultados experimentales y la validación estadística presentados en el Capítulo 5 permiten extraer conclusiones sobre la efectividad del framework propuesto, evaluar el cumplimiento de los objetivos declarados en el Capítulo 1, identificar con precisión las limitaciones del estudio, y proyectar líneas de trabajo que extienden la investigación hacia aplicaciones de mayor escala y complejidad.

6.1 Conclusiones generales del proyecto

Esta investigación desarrolló, implementó y validó experimentalmente un framework de identificación paramétrica estructural basado en una Red Neuronal Evolutiva informada por física (EANN), optimizada mediante un Algoritmo Genético Multiobjetivo en dos fases (GA-MO) y operando exclusivamente sobre señales de aceleración, las conclusiones principales son:

1. El framework demuestra que es posible aprender una función de mapeo $f: \ddot{u} - \hat{\theta}$ con precisión comparable a GA y PSO pero con costo de inferencia $O(d\theta)$, independiente del tamaño de población, generaciones y longitud del registro, esta transformación del problema de identificación de tarea de optimización repetida a tarea de aprendizaje único transforma la viabilidad de la identificación en tiempo real: de minutos (GA, PSO) a milisegundos (EANN), con IC bootstrap de RMSE [0.187, 0.191] frente a [0.188, 0.272] del GA.
2. La incorporación de la ecuación de movimiento estructural como restricción suave en f_3 reduce el coeficiente de variación del amortiguamiento en un factor mayor de 17 respecto al GA de $CV \approx 2.5 - 4.0$ a $CV \approx 0.05 - 0.15$, el conocimiento físico a priori no solo

mejora la plausibilidad de la solución, sino que actúa como mecanismo de reducción de varianza que no puede lograrse mediante ajuste de hiperparámetros del algoritmo evolutivo.

3. El frente de Pareto de 98 soluciones no dominadas con $HV=1.000\pm0.000$ y razón de dominancia 10:1 sobre GA no es un resultado de optimización abstracto: es un menú de modelos estructurales seleccionables según las prioridades del diseño de control, fidelidad temporal para observadores de estado, coherencia modal para evaluación de daño, regularidad física para actualización de modelos; esta capacidad de selección informada es el aporte metodológico central que distingue al framework de los enfoques de función objetivo escalar.
4. La asimetría $CV(k_i) \ll CV(c_i)$ observada en todos los métodos refleja una propiedad del sistema de medición, no una deficiencia algorítmica: la rigidez determina las frecuencias naturales visibles en el espectro, mientras que el amortiguamiento controla el decaimiento, una característica más sutil bajo excitación acelerométrica; el framework mitiga esta limitación mediante regularización física f_3 , pero no la elimina completamente.
5. La combinación de operación exclusiva sobre acelerómetros, admisibilidad física garantizada y costo de inferencia compatible con evaluación post-sísmica hace del framework EANN-GA-MO una herramienta técnicamente pertinente para el monitoreo de salud estructural de edificaciones en zonas de amenaza sísmica alta y media del territorio colombiano, en el marco del NSR-10 [44] y el modelo nacional de amenaza sísmica del SGC [43].

En conjunto, el trabajo establece que la identificación paramétrica estructural orientada a control puede abordarse como un problema de aprendizaje informado por física, donde las restricciones del modelo dinámico son aliados metodológicos que mejoran simultáneamente la precisión, la robustez estadística y la coherencia física de los parámetros estimados.

6.2 Cumplimiento de los objetivos

La Tabla 18 evalúa el grado de cumplimiento de cada objetivo específico, conectando la solución metodológica implementada con la evidencia empírica que lo verifica:

Tabla 18. *Evaluación del cumplimiento de objetivos*

Objetivo específico	Respuesta metodológica	Evidencia experimental
OE1 — Esquema de representación de datos como entrada a la EANN	Vector $\mathbf{x} \in \mathbb{R}^{660}$: $L=128$ rezagos temporales + 4 estadísticos globales $\times$ 5 pisos, estandarización z-score por canal.	Entrada fija y reproducible en las 270 corridas (9 configuraciones $\times$ 30).
OE2 — Modelo híbrido EANN-MDOF con restricciones físicas	MLP dos capas ocultas + doble cabeza con decodificación acotada $\hat{\theta} \in [\mathbf{l}_b, \mathbf{u}_b]$, simulador MDOF Tustin acoplado al ciclo de fitness.	Admisibilidad física garantizada en 100% de evaluaciones, $CV(c_i) \approx 0.07-0.10$ refleja la regularización f_3 .
OE3 — Marco de optimización multiobjetivo con knee point	NSGA-II en dos fases ($\pm 40\%/\pm 18\%$), selección automática por mínima distancia al punto utopía normalizado + refinamiento finincon.	Frente Pareto: 98 soluciones EANN vs 77 GA. $HV=1.000 \pm 0.000$. Dominancia 10:1 sobre GA.
OE4 — Validación estadística comparativa sobre 30 corridas	Protocolo: Kruskal-Wallis $\rightarrow$ Wilcoxon-Holm $\rightarrow$ IC bootstrap 95% ($B=10,000$) $\rightarrow$ CV por piso $\rightarrow$ dominancia Pareto.	Todos $p < 0.001$. RMSE mediano EANN = 0.189 (-5.0% vs PSO). Reducción MSE mediano 9.8% vs PSO.

El objetivo general (desarrollar una metodología de identificación paramétrica basada en EANN-GA-MO para estimar rigidez y amortiguamiento de un edificio de múltiples pisos a partir de registros de aceleración) se cumple íntegramente, la metodología desarrollada estima los 10 parámetros estructurales ($k_1, \dots, k_5, c_1, \dots, c_5$) del prototipo de cinco pisos a partir exclusivamente de señales acelerométricas, con validación estadística robusta sobre 30 corridas independientes y comparación directa con GA y PSO como baselines.

La hipótesis de trabajo se confirma en ambos ejes: (i) el CV de amortiguamiento de la EANN es estadísticamente inferior al del GA con $p = 1.22 \times 10^{-15}$ (Kruskal-Wallis en MSEmediano) y todos los pares Wilcoxon $p < 0.001$; (ii) los residuos de aceleración satisfacen

condiciones de consistencia frecuencial verificadas mediante la función objetivo f_2 (alineación de picos espectrales de los pisos 1 y 2), la reducción del 9.8% en MSE mediano y 5.0% en RMSE mediano respecto al PSO confirma además la superioridad en precisión de reconstrucción.

6.3 Limitaciones identificadas

Limitación 1: linealidad del modelo estructural, el modelo MDOF adoptado es lineal viscoso, los parámetros ki y ci identificados representan el mejor ajuste lineal a las señales experimentales en el régimen de excitación del ensayo, pero no capturan efectos de no linealidad geométrica, amortiguamiento histerético ni interacción suelo-estructura presentes en estructuras reales, bajo niveles sísmicos mayores, los parámetros reales cambiarían y los identificados perderían validez.

Limitación 2: observabilidad diferencial del amortiguamiento, la estimación de los coeficientes ci es intrínsecamente más difícil que la de ki cuando solo se dispone de aceleraciones, la rigidez controla las frecuencias naturales (visibles en el espectro); el amortiguamiento controla la tasa de decaimiento, una característica más sutil bajo excitación sísmica de banda ancha, esto explica la asimetría sistemática $CV(k_i) \ll CV(c_i)$ en todos los métodos, independientemente del algoritmo utilizado.

Limitación 3: transferibilidad del vector de características, el vector $xf \in \mathbb{R}^{660}$ fue calibrado con $L=128$ rezagos para el registro sísmico de México 1985 a 1000Hz, una EANN entrenada con este registro y desplegada sobre acelerogramas de características espectrales significativamente distintas podría requerir reentrenamiento, esta limitación es inherente a los métodos de aprendizaje offline y no exclusiva del framework propuesto.

Limitación 4: sesgo de configuración ganadora, los resultados principales se reportan para

la configuración EANN-32/16, la Tabla 16 aborda este sesgo mostrando que las nueve configuraciones evaluadas satisfacen $CV(ci) < 0.15$ y que la diferencia de RMSE mediano entre la mejor (0.1895) y la peor (0.2135) es del 12.7%, rango comparable a la variabilidad intra-corrida del GA, la ventaja en robustez paramétrica es por tanto una propiedad del framework en su conjunto; el sesgo residual es que los valores absolutos de RMSE de la Tabla 17 corresponden a la configuración ganadora, reportar el promedio sobre las nueve configuraciones en trabajos futuros reforzaría la validez de la comparación.

Limitación 5: alcance del prototipo experimental, el framework fue desarrollado y validado sobre un prototipo de laboratorio a escala reducida (1:10 aproximadamente) con cinco pisos de igual geometría y material, la extensión a estructuras reales de mayor escala, con variabilidad constructiva, daño acumulado o configuración irregular requiere validación experimental adicional no contemplada en este proyecto.

Limitación 6: robustez frente al ruido de medición, el experimento opera con las señales tal como las registran los sensores MEMS bajo condiciones controladas de laboratorio, no se realizó una evaluación sistemática del comportamiento del framework ante niveles crecientes de ruido artificialmente añadido a las señales acelerométricas, aunque el preprocesamiento (filtro Butterworth, remoción de sesgo y normalización z-score) mitiga el ruido de alta frecuencia; la sensibilidad del framework a relaciones señal-ruido inferiores a las condiciones de laboratorio es una pregunta abierta con impacto directo en la aplicabilidad a instrumentación de campo, esta limitación fue reconocida explícitamente en el diseño experimental (sección 3.5) y constituye una línea de trabajo de corto plazo prioritaria.

Limitación 7: ausencia de comparación empírica con PINNs, la ventaja del enfoque evolutivo sobre las Physics-Informed Neural Networks se argumenta sobre la base de la incompatibilidad estructural entre los integradores de tiempo discreto estándar y los requisitos de

diferenciabilidad del entrenamiento PINN, sin embargo, no se implementó ni comparó cuantitativamente una PINN aplicada al mismo problema y dataset, la comparación directa (implementando una PINN continua equivalente con integrador de paso variable) queda como trabajo futuro necesario para validar empíricamente la ventaja teórica argumentada frente al estado del arte.

6.4 Recomendaciones y trabajos futuros

Las limitaciones identificadas y las extensiones naturales del framework definen un programa de trabajo con tres horizontes temporales, antes de detallar las líneas específicas, se plantea una recomendación operativa para el uso inmediato del framework en estudios de monitoreo estructural:

Para aplicaciones en el contexto colombiano, se recomienda iniciar con la recolección de registros de vibración ambiental sobre edificaciones instrumentadas existentes (por ejemplo, en la red de monitoreo del SGC) y adaptar los límites físicos lb/ub y el punto semilla θ_{seed} a partir de los planos estructurales y las frecuencias naturales estimadas por análisis espectral previo, esta adaptación es metodológicamente directa dentro del framework sin modificaciones al algoritmo.

Tabla 19. *Líneas de trabajo futuro*

Horizonte	Línea de trabajo	Justificación
Corto plazo	Evaluar transferibilidad del vector de características sobre registros sísmicos de distinto contenido frecuencial (subducción, corteza superficial)	Limitación de transferibilidad identificada
Corto plazo	Caracterizar la relación capacidad de representación-variabilidad paramétrica para arquitecturas EANN adicionales ($H1/H2 > 24/12$)	Sesgo de configuración ganadora

Horizonte	Línea de trabajo	Justificación
Mediano plazo	Incorporar amortiguadores magnetorreológicos (MR) no lineales en el modelo MDOF, extendiendo el framework a sistemas semi-activos [31], [57]	Línea activa del grupo GRAM
Mediano plazo	Desarrollar estrategia de reentrenamiento online incremental sin resolución completa del problema de optimización (aprendizaje continuo)	Limitación del paradigma offline
Mediano plazo	Extender a modelos no lineales de histéresis (Bouc-Wen) donde la dinámica no puede capturarse con el modelo lineal MDOF	Limitación de linealidad del modelo
Largo plazo	Integrar en plataforma SHM embebida con inferencia en tiempo real sobre microcontroladores de alto desempeño, compatible con evaluación post-sísmica NSR-10	Habilitado por costo $O(d\theta)$
Largo plazo	Extender a edificios con configuración asimétrica en planta donde la respuesta tridimensional introduce acoplamiento traslación-torsión	Benchmark actual es estructura regular 1D

Las líneas de corto plazo responden a las limitaciones 3, 4, 6 y 7 identificadas, las de mediano plazo extienden el framework hacia sistemas no lineales y aprendizaje continuo, extensiones que el grupo de investigación GRAM tiene capacidad de abordar dado el expertise consolidado en control con amortiguadores MR [31], [33]; las de largo plazo corresponden a aplicaciones de mayor escala con infraestructura institucional, particularmente relevante en el contexto del Servicio Geológico Colombiano y los programas de evaluación estructural post-sísmica del país.

Referencias

- [1] A. Malekloo, E. Ozer, M. AlHamaydeh, and M. Girolami, “Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights,” *Struct. Health Monit.*, vol. 21, no. 4, pp. 1906–1955, Jul. 2022, doi: 10.1177/14759217211036880.
- [2] A. Concha, L. Alvarez-Icaza, and R. Garrido, “Simultaneous parameter and state estimation of shear buildings,” *Mech. Syst. Signal Process.*, vol. 70, pp. 788–810, 2016.
- [3] A. Rodríguez-Torres, C. H. Valencia-Niño, and L. Alvarez-Icaza, “Application of Classical and Quantum-Inspired Methods Through Multi-Objective Optimization for Parameter Identification of a Multi-Story Prototype Building,” *Buildings*, vol. 15, no. 20, p. 3743, 2025, doi: 10.3390/buildings15203743.
- [4] A. Concha, R. Garrido, and L. Alvarez-Icaza, “Structural parameter identification from ground and floor acceleration measurements: An instrumental variable method based on linear integral filters,” *J. Sound Vib.*, vol. 385, pp. 149–170, 2016, doi: 10.1016/j.jsv.2016.09.002.
- [5] G. Jin, M. K. Sain, and B. F. Spencer Jr., “Frequency Domain System Identification for Controlled Civil Engineering Structures,” *IEEE Transactions on Control Systems Technology*, vol. 13, no. 6, pp. 1055–1061, 2005, doi: 10.1109/TCST.2005.854341.
- [6] C. Roman, F. Ferrante, and C. Prieur, “Parameter Identification of a Linear Wave Equation From Experimental Boundary Data,” *IEEE Transactions on Control Systems Technology*, vol. 29, no. 5, pp. 2166–2179, 2021, doi: 10.1109/TCST.2020.3032714.
- [7] P. Lopes dos Santos, J. A. Ramos, and J. L. Martins de Carvalho, “Identification of Bilinear Systems With White Noise Inputs: An Iterative Deterministic-Stochastic Subspace Approach,” *IEEE Transactions on Control Systems Technology*, vol. 17, no. 5, pp. 1145–1153, 2009, doi: 10.1109/TCST.2008.2002041.
- [8] K. O. Stanley, J. Clune, J. Lehman, and R. Miikkulainen, “Designing neural networks through neuroevolution,” *Nat. Mach. Intell.*, vol. 1, no. 1, pp. 24–35, Jan. 2019, doi: 10.1038/S42256-018-0006-Z.

- [9] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, “A fast and elitist multiobjective genetic algorithm: NSGA-II,” *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, Apr. 2002, doi: 10.1109/4235.996017.
- [10] A. Zhou, B. Y. Qu, H. Li, S. Z. Zhao, P. N. Suganthan, and Q. Zhangd, “Multiobjective evolutionary algorithms: A survey of the state of the art,” *Swarm Evol. Comput.*, vol. 1, no. 1, pp. 32–49, 2011, doi: 10.1016/J.SWEVO.2011.03.001.
- [11] M. Flah, I. Nunez, W. Ben Chaabene, and M. L. Nehdi, “Machine Learning Algorithms in Civil Structural Health Monitoring: A Systematic Review,” *Archives of Computational Methods in Engineering*, vol. 28, no. 4, pp. 2621–2643, Jun. 2021, doi: 10.1007/S11831-020-09471-9.
- [12] A. K. Chopra, *Dynamics of Structures: Theory and Applications to Earthquake Engineering*. in Always learning. Pearson, 2017.
- [13] R. W. . Clough and Joseph. Penzien, “Dynamics of structures,” p. 738, 2003, Accessed: Jun. 04, 2026. [Online]. Available: https://books.google.com/books/about/Dynamics_of_Structures.html?id=TcxyAAAACAAJ
- [14] O. Avci, O. Abdeljaber, S. Kiranyaz, M. Hussein, M. Gabbouj, and D. J. Inman, “A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications,” *Mech. Syst. Signal Process.*, vol. 147, p. 107077, Jan. 2021, doi: 10.1016/J.YMSSP.2020.107077.
- [15] C. R. Farrar and K. Worden, “An introduction to structural health monitoring,” *Philos. Trans. A Math. Phys. Eng. Sci.*, vol. 365, no. 1851, pp. 303–315, Feb. 2007, doi: 10.1098/RSTA.2006.1928.
- [16] X. Yao, “Evolving artificial neural networks,” *Proceedings of the IEEE*, vol. 87, no. 9, pp. 1423–1447, 1999, doi: 10.1109/5.784219.
- [17] M. Nikoo, F. Torabian Moghadam, and Ł. Sadowski, “Prediction of concrete compressive strength by evolutionary artificial neural networks,” *Advances in Materials Science and Engineering*, vol. 2015, 2015, doi: 10.1155/2015/849126.
- [18] E. Momeni, D. J. Armaghani, S. A. Fatemi, and R. Nazir, “Prediction of bearing capacity of

- thin-walled foundation: a simulation approach,” *Engineering with Computers* 2017 34:2, vol. 34, no. 2, pp. 319–327, Nov. 2017, doi: 10.1007/S00366-017-0542-X.
- [19] A. Kaveh, “Applications of Artificial Neural Networks and Machine Learning in Civil Engineering,” *Studies in Computational Intelligence*, vol. 1168, pp. 1–474, 2024, doi: 10.1007/978-3-031-66051-1/SAVE-RESEARCH.
- [20] R. Zhang, Z. Chen, S. Chen, J. Zheng, O. Büyüköztürk, and H. Sun, “Deep long short-term memory networks for nonlinear structural seismic response prediction,” *Comput. Struct.*, vol. 220, pp. 55–68, Aug. 2019, doi: 10.1016/j.compstruc.2019.05.006.
- [21] R. Zhang, Y. Liu, and H. Sun, “Physics-guided convolutional neural network (PhyCNN) for data-driven seismic response modeling,” *Eng. Struct.*, vol. 215, p. 110704, Jul. 2020, doi: 10.1016/J.ENGSTRUCT.2020.110704.
- [22] S. Sadeghi Eshkevari, M. Takáč, S. N. Pakzad, and M. Jahani, “DynNet: Physics-based neural architecture design for nonlinear structural response modeling and prediction,” *Eng. Struct.*, vol. 229, p. 111582, Feb. 2021, doi: 10.1016/J.ENGSTRUCT.2020.111582.
- [23] S. Teng, G. Chen, Z. Yan, L. Cheng, and D. Bassir, “Vibration-based structural damage detection using 1-D convolutional neural network and transfer learning,” *Struct. Health Monit.*, vol. 22, no. 4, pp. 2888–2909, Jul. 2023, doi: 10.1177/14759217221137931.
- [24] M. Raissi, P. Perdikaris, and G. E. Karniadakis, “Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations,” *J. Comput. Phys.*, vol. 378, pp. 686–707, Feb. 2019, doi: 10.1016/J.JCP.2018.10.045.
- [25] G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang, and L. Yang, “Physics-informed machine learning,” *Nature Reviews Physics*, vol. 3, no. 6, pp. 422–440, Jun. 2021, doi: 10.1038/S42254-021-00314-5.
- [26] X. Li, H. Bolandi, T. Salem, N. Lajnef, and V. N. Boddeti, “NeuralSI: Structural Parameter Identification in Nonlinear Dynamical Systems,” *Lecture Notes in Computer Science*, vol. 13807 LNCS, pp. 332–348, 2023, doi: 10.1007/978-3-031-25082-8_22.
- [27] R. Wang *et al.*, “Structural damage identification by using physics-guided residual neural networks,” *Eng. Struct.*, vol. 318, p. 118703, Nov. 2024, doi:

- 10.1016/J.ENGSTRUCT.2024.118703.
- [28] E. Zitzler, K. Deb, and L. Thiele, “Comparison of multiobjective evolutionary algorithms: empirical results,” *Evol. Comput.*, vol. 8, no. 2, pp. 173–195, 2000, doi: 10.1162/106365600568202.
- [29] Y. Shi and R. Eberhart, “Modified particle swarm optimizer,” *Proceedings of the IEEE Conference on Evolutionary Computation, ICEC*, pp. 69–73, 1998, doi: 10.1109/ICEC.1998.699146.
- [30] R. Pintelon and J. Schoukens, “System identification [electronic resource]: a frequency domain approach / Rik Pintelon, Johan Schoukens,” 2012, Accessed: Jun. 05, 2026. [Online]. Available: <http://ezproxy.lib.ed.ac.uk/login?url=https://search.ebscohost.com/login.aspx?direct=true&db=cat00234a&AN=edinb.2243779&site=eds-live>
- [31] A. Rodríguez-Torres, J. Morales-Valdez, and W. Yu, “Parametric identification of a magnetorheological damper based on Genetic Algorithm,” in *2021 18th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE)*, 2021, pp. 1–5. doi: 10.1109/CCE53527.2021.9633028.
- [32] A. Rodríguez-Torres, M. López-Pacheco, J. Morales-Valdez, W. Yu, and J. G. Díaz-Rodríguez, “Robust Force Estimation for Magnetorheological Damper Based on Complex Value Convolutional Neural Network,” *J. Comput. Nonlinear Dyn.*, no. 12, pp. 559–580, 2022, doi: 10.1115/1.4055731.
- [33] M. Abdul Aziz, S. M. Mohtasim, and R. Ahammed, “State-of-the-art recent developments of large magnetorheological (MR) dampers: a review: MA Aziz et al.,” *Korea-Australia Rheology Journal*, vol. 34, no. 2, pp. 105–136, 2022.
- [34] L. Károly, O. Stan, and L. Miclea, “Seismic Model Parameter Optimization for Building Structures,” *Sensors 2020, Vol. 20, Page 1980*, vol. 20, no. 7, p. 1980, Apr. 2020, doi: 10.3390/S20071980.
- [35] S. Mukherjee and I. Barua, “Graph Neural Network Assisted Genetic Algorithm for Structural Dynamic Response and Parameter Optimization,” Oct. 2026, Accessed: Jun. 03, 2026. [Online]. Available: <https://arxiv.org/pdf/2510.22839>

- [36] O. Abdeljaber, O. Avci, S. Kiranyaz, M. Gabbouj, and D. J. Inman, “Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks,” *J. Sound Vib.*, vol. 388, pp. 154–170, Feb. 2017, doi: 10.1016/J.JSV.2016.10.043.
- [37] A. Ayyad, D. Suarez, J. Koeln, D. Boroyevich, and J. E. Machado, “Multirotors From Takeoff to Real-Time Full Identification Using the Modified Relay Feedback Test and Deep Neural Networks,” *IEEE Transactions on Control Systems Technology*, pp. 1561–1577, 2022, doi: 10.1109/TCST.2021.3114265.
- [38] J. Morales-Valdez, L. Alvarez-Icaza, and J. A. Escobar, “Damage localization in a building structure during seismic excitation,” *Shock and Vibration*, vol. 2020, no. 1, p. 8859527, 2020.
- [39] L. J. Oliva-Gonzalez, J. Morales-Valdez, A. Rodríguez-Torres, and R. Martínez-Guerra, “Algebraic PI observer for velocity and displacement in civil structures from acceleration measurement,” *Mech. Syst. Signal Process.*, vol. 208, p. 111017, Feb. 2024, doi: 10.1016/J.YMSSP.2023.111017.
- [40] P. Li, S. Yan, J. Zhang, M. Q. Feng, D. Feng, and S. Li, “A quantitative comparison study for structural flexibility identification using Accelerometric and computer vision-based vibration data,” *J. Sound Vib.*, vol. 576, p. 118288, Apr. 2024, doi: 10.1016/J.JSV.2024.118288.
- [41] T. Liu and H. Meidani, “Physics-Informed Neural Networks for System Identification of Structural Systems with a Multiphysics Damping Model,” *J. Eng. Mech.*, vol. 149, no. 10, Oct. 2023, doi: 10.1061/JENMDT.EMENG-7060.
- [42] D. Y. Yun, B. K. Oh, K. Park, and H. S. Park, “LSTM-Based Approach for Stable Identification of Modal Damping Ratio in Building Structures,” *Struct. Control Health Monit.*, vol. 2024, 2024, doi: 10.1155/2024/6645626.
- [43] M. M. A. Rivera *et al.*, “Modelo nacional de amenaza sísmica para Colombia,” *Libros del Servicio Geológico Colombiano*, Aug. 2020, doi: 10.32685/9789585279469.
- [44] Asociación Colombiana de Ingeniería Sísmica (AIS), *Reglamento Colombiano de Construcción Sismo Resistente NSR-10*. Colombia, 2010.
- [45] J. N. Yang and S. Lin, “Identification of Parametric Variations of Structures Based on Least

- Squares Estimation and Adaptive Tracking Technique,” *J. Eng. Mech.*, vol. 131, no. 3, pp. 290–298, Mar. 2005, doi: 10.1061/(ASCE)0733-9399(2005)131:3(290).
- [46] B. Mavkov, M. Forgione, and D. Piga, “Integrated Neural Networks for Nonlinear Continuous-Time System Identification,” *IEEE Control Syst. Lett.*, vol. 4, no. 4, pp. 851–856, 2020, doi: 10.1109/LCSYS.2020.2994806.
- [47] M. Al-Laham, S. Abdullah, M. A. Al-Ma’aitah, M. A. Al-Betar, S. Kassaymeh, and A. Azzazi, “Parameter Identification of a Multilayer Perceptron Neural Network using an Optimized Salp Swarm Algorithm,” *International Journal of Advanced Computer Science and Applications*, vol. 14, no. 6, pp. 1221–1232, Jun. 2023, doi: 10.14569/IJACSA.2023.01406130.
- [48] Y. Jin, “Surrogate-assisted evolutionary computation: Recent advances and future challenges,” *Swarm Evol. Comput.*, vol. 1, no. 2, pp. 61–70, Jun. 2011, doi: 10.1016/J.SWEVO.2011.05.001.
- [49] A. I. F. Al-Adly and P. Kripakaran, “Physics-informed neural networks for structural health monitoring: a case study for Kirchhoff–Love plates,” *Data-Centric Engineering*, vol. 5, no. 4, Mar. 2024, doi: 10.1017/DCE.2024.4.
- [50] R. de O. Teloli *et al.*, “A physics-informed neural networks framework for model parameter identification of beam-like structures,” *Mech. Syst. Signal Process.*, vol. 224, p. 112189, Feb. 2025, doi: 10.1016/J.YMSSP.2024.112189.
- [51] J. Derrac, S. García, D. Molina, and F. Herrera, “A practical tutorial on the use of nonparametric statistical tests as a methodology for comparing evolutionary and swarm intelligence algorithms,” *Swarm Evol. Comput.*, vol. 1, no. 1, pp. 3–18, Mar. 2011, doi: 10.1016/J.SWEVO.2011.02.002.
- [52] B. Efron and R. J. Tibshirani, “An Introduction to the Bootstrap,” *An Introduction to the Bootstrap*, May 1994, doi: 10.1201/9780429246593/INTRODUCTION-BOOTSTRAP-BRADLEY-EFRON-TIBSHIRANI.
- [53] E. Zitzler, L. Thiele, M. Laumanns, C. M. Fonseca, and V. G. Da Fonseca, “Performance assessment of multiobjective optimizers: An analysis and review,” *IEEE Transactions on Evolutionary Computation*, vol. 7, no. 2, pp. 117–132, Apr. 2003, doi:

10.1109/TEVC.2003.810758.

- [54] C. Zhang, A. A. Mousavi, S. F. Masri, G. Gholipour, K. Yan, and X. Li, “Vibration feature extraction using signal processing techniques for structural health monitoring: A review,” *Mech. Syst. Signal Process.*, vol. 177, p. 109175, Sep. 2022, doi: 10.1016/J.YMSSP.2022.109175.
- [55] A. Rodríguez-Torres, J. Morales-Valdez, and W. Yu, “Alternative tuning method for proportional-derived gains for active vibration control in a building structure,” *Transactions of the Institute of Measurement and Control*, 2021, doi: 10.1177/01423312211021052;JOURNAL:JOURNAL:TIMA;WEBSITE:WEBSITE:SAGE;WGROUPE:STRING:PUBLICATION.
- [56] A. Rodríguez-Torres, J. Morales-Valdez, and W. Yu, “Active Vibration Control for Building Structures based on H_∞ Synthesis Problem,” in *2020 17th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE)*, 2020, pp. 1–6.
- [57] A. Rodríguez-Torres, J. Morales-Valdez, and W. Yu, “Semi-active vibration control via a magnetorheological damper and active disturbance rejection control,” *Transactions of the Institute of Measurement and Control*, p. 01423312241276074, 2024.