

OPTIMIZACIÓN DE PÓRTICOS CON ACCIONES SÍSMICAS: DIFERENTES ESTRATEGIAS NUMÉRICAS UTILIZANDO REDES NEURONALES

Oscar Möller^a, Ricardo O. Foschi^b, Laura M. Quiroz^a y Marcelo Rubinstein^a

^a*Instituto de Mecánica Aplicada y Estructuras (IMAE), Universidad Nacional de Rosario,
Riobamba y Berutti, 2000 Rosario, Argentina, moller@fceia.unr.edu.ar*

^b*Civil Engineering Department, University of British Columbia, 6250 Applied Sciences Lane,
Vancouver, B.C., Canada, V6T 1Z4, rowfa1@civil.ubc.ca*

Palabras clave: Optimización, Redes neuronales, Incertidumbres, Diseño estructural.

Resumen. La optimización de estructuras, dentro del marco de la ingeniería sísmica basada en el desempeño, consiste en encontrar valores a parámetros de diseño que minimicen una función objetivo, el costo total en este trabajo, sujeto a restricciones de confiabilidad en cada nivel de desempeño. La tarea computacional importante es el análisis dinámico no lineal de la estructura para diferentes combinaciones de las variables, y estos resultados discretos son aproximados por redes neuronales. La estimación de la confiabilidad se realiza por simulación directa de Monte Carlo utilizando las redes neuronales como “sustituto” de la respuesta estructural. El proceso de optimización se realiza con un algoritmo de búsqueda que no calcula gradientes, con dos estrategias: (a) Confiabilidades intermedias estimadas por simulación de Monte Carlo en cada paso del proceso de optimización; (b) Confiabilidades intermedias calculadas con redes neuronales entrenadas previamente para relacionar los índices de confiabilidad con los parámetros de diseño. Se aplica a la optimización de dimensiones de vigas y columnas y cuantías de armadura de pórticos, donde el objetivo es el mínimo costo total, incluyendo el costo de construcción y el costo de reparación por daños después de un terremoto. Se muestra la eficiencia del procedimiento, el acuerdo entre las dos estrategias, y las ventajas de cada una de ellas.

1 INTRODUCCIÓN

El problema de optimización consiste en encontrar valores a ciertos parámetros de diseño que minimicen una función objetivo, por ejemplo el costo total en una estructura, y que satisfagan restricciones impuestas al problema.

Para el caso de estructuras con acciones dinámicas aleatorias, por ejemplo acción de terremotos, es necesario considerar las incertidumbres presentes tanto en la demanda como en la capacidad del sistema. Se requiere el uso de métodos probabilísticos para evaluar la probabilidad de “falla” o de excedencia anual en cada nivel de desempeño considerado, dentro del marco del diseño sísmico basado en el desempeño (SEAOC Vision 2000, 1995; FEMA 273, 1997).

La formulación de los estados límites en cada nivel de desempeño requiere el cálculo de valores máximos de respuestas de la estructura en la duración del evento sísmico, las cuales están asociadas a comportamiento estructural fuertemente no lineal. Luego, es necesario recurrir al análisis dinámico no lineal paso a paso, con una importante demanda computacional que hace impracticable la estimación de la confiabilidad por simulación directa de Monte Carlo.

No es posible establecer una relación explícita entre las variables de entrada (datos) y las respuestas dinámicas, pero se pueden calcular resultados discretos para combinaciones específicas de las variables aleatorias y parámetros de diseño intervinientes. Estos resultados discretos se representan luego por una superficie de respuesta o red neuronal apropiadamente ajustada, que se utiliza como “sustituto” de la verdadera respuesta (Hurtado, 2004).

Diferentes tipos de sustitutos se han utilizado, desde funciones analíticas como superficies cuadráticas globales (Möller, 2001; Möller y Foschi, 2003), interpolación local (Foschi, Li y Zhang, 2002), y recientemente redes neuronales (Zhang, 2003; Zhang y Foschi, 2004; Möller et al., 2006 a, b, 2007). En general es difícil seguir los detalles de la respuesta para diferentes datos de las variables con una función analítica simple y global. El uso de interpolación local permite una mejor representación, pero a mayor costo computacional. Las redes neuronales, entrenadas con una base de datos discretos, conducen a una mejor representación, más flexible y adaptable.

El esfuerzo computacional es ahora desplazado desde la evaluación de la confiabilidad, vía simulación, a los cálculos determinísticos de la base de datos para combinaciones de las variables elegidas convenientemente.

Los problemas de optimización pueden clasificarse de acuerdo a la forma de la función a minimizar (o maximizar) y sus restricciones, de acuerdo a la presencia o no de estas últimas, según su dimensionalidad y según el número de funciones objetivo. Existen variados métodos para resolver estos problemas y pueden clasificarse en principio como métodos analíticos, métodos numéricos y otros métodos que incluyen métodos gráficos, experimentales y estudio de casos. En la Figura 1 se muestra una clasificación de los métodos más representativos (Pérez López, 2005).

En la optimización estocástica de estructuras la función objetivo no es explícita ni continua ni derivable, luego es necesario utilizar un método capaz de resolver esos casos, ya que los métodos clásicos de optimización matemática basados en el uso de gradientes, como la técnica del descenso más empinado, los métodos de Newton, quasi-Newton o los métodos del gradiente conjugado, son ineficientes. Dentro de los métodos heurísticos probabilísticos se encuentran los algoritmos evolutivos inspirados en la genética y evolución de las especies (principios de selección natural), y aquellos que buscan una solución mejorada a partir de una

inicial perturbando aleatoriamente los parámetros a optimizar.

En este trabajo se utiliza un algoritmo que realiza una búsqueda aleatoria sin cálculo de gradientes, con el objetivo de encontrar valores a parámetros de diseño que minimicen el costo total, considerando el costo inicial de construcción y el costo de posibles reparaciones o reemplazo luego de la ocurrencia de un terremoto, sujeto a satisfacer restricciones de probabilidad de falla (ó índice de confiabilidad) tolerable en cada nivel de desempeño.

Se analiza comparativamente la eficiencia de diferentes estrategias numéricas para llevar a cabo este proceso. Por un lado, para cada combinación de los parámetros de diseño, la evaluación de los índices de confiabilidad, para analizar si cumple con los valores tolerables, se realiza por simulación de Montecarlo utilizando las redes neuronales que representan la respuesta estructural. Por otro lado, en un paso intermedio se generan redes neuronales para representar los índices de confiabilidad en función de los parámetros de diseño, y con estas redes neuronales se lleva adelante el proceso de optimización.

Estas técnicas se aplican al diseño óptimo de pórticos de hormigón armado sismorresistentes considerando tres niveles de desempeño: operacional, seguridad de vidas y límite de colapso.

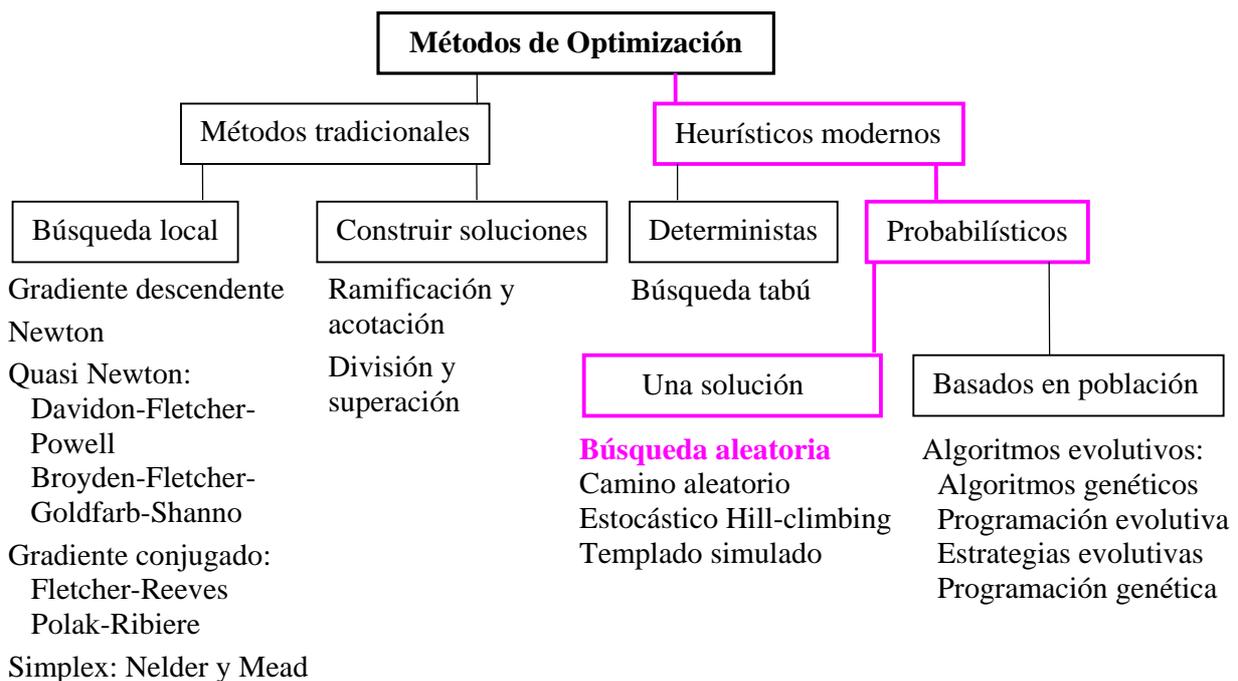


Figura 1: Clasificación de métodos de optimización

2 RESPUESTA DINÁMICA NO LINEAL Y REPRESENTACIÓN CON REDES NEURONALES

2.1 Modelo para análisis dinámico no lineal

El modelo estructural utilizado ya ha sido descrito en otros trabajos (Möller, 2001).

Consiste en elementos de barra con comportamiento no lineal, que considera la contribución de los diferentes mecanismos que contribuyen al comportamiento histerético de las regiones críticas de miembros de hormigón armado. La Figura 2 muestra un elemento de rigidez EI y EA , entre nodos i, j , con rigidez reducida en los extremos asociada a factores p_i, p_j . Estos factores y la longitud de la zona de rigidez reducida por comportamiento no lineal son calculados en cada paso usando la relación momento-curvatura también mostrada en la Figura 2 para esfuerzo normal constante.

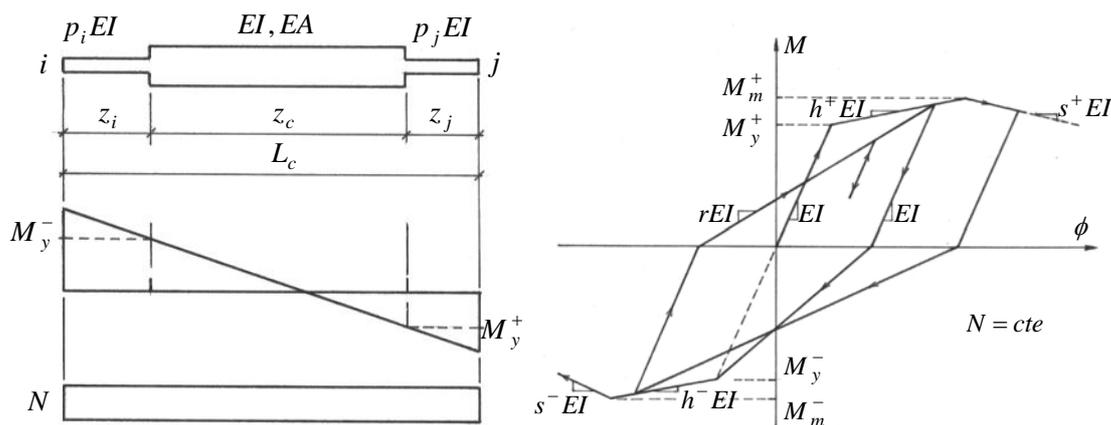


Figura 2: Elemento de barra no lineal

El modelo considera una matriz de masa consistente y amortiguamiento viscoso proporcional a la masa y rigidez inicial. El sistema de ecuaciones no lineales de la estructura es formulado en un esquema incremental lagrangiano actualizado. Se resuelve con integración directa paso a paso en el tiempo con el método de Newmark, e iteraciones de Newton-Raphson para ajustar el equilibrio entre acciones externas y fuerzas internas de los elementos.

Los resultados del análisis son usados para obtener los parámetros de respuesta incluidos en la definición de los estados límites para cada nivel de performance especificado.

2.2 Aproximación de la respuesta con redes neuronales

Dentro de los “sustitutos” de la respuesta estructural, las redes neuronales (Hurtado, 2004) entrenadas a partir de una base de datos discretos, son las que presentan mejores condiciones de adaptabilidad y flexibilidad. La expresión genérica es

$$R(\mathbf{X}) \cong F(\mathbf{X}) = h \left(\sum_{k=0}^J W_{kj} h \left(\sum_{i=0}^N W_{ji} X_i \right) \right) \quad (1)$$

donde $R(\mathbf{X})$ es el “verdadero” valor de la respuesta obtenido con análisis dinámico no lineal para las variables X_i , $F(\mathbf{X})$ la aproximación con red neuronal, $h(t)$ es una función no lineal de transferencia, W_{kj} y W_{ji} son factores de peso.

La arquitectura de la red es representada esquemáticamente en la Figura 3, mostrando una capa de entrada con N neuronas conectadas a J neuronas de una capa intermedia. La información que recibe cada neurona j está formada por la contribución de cada una de las neuronas i de la capa de entrada, con valores X_i y los pesos W_{ji} . Esa información es procesada con la función de transferencia h , usualmente una sigmoide, y el resultado es transmitido a la capa siguiente, de salida, utilizando los pesos W_{kj} . La información que así llega a las neuronas

de la capa de salida son procesadas nuevamente con la función h para producir los resultados finales en las neuronas K .

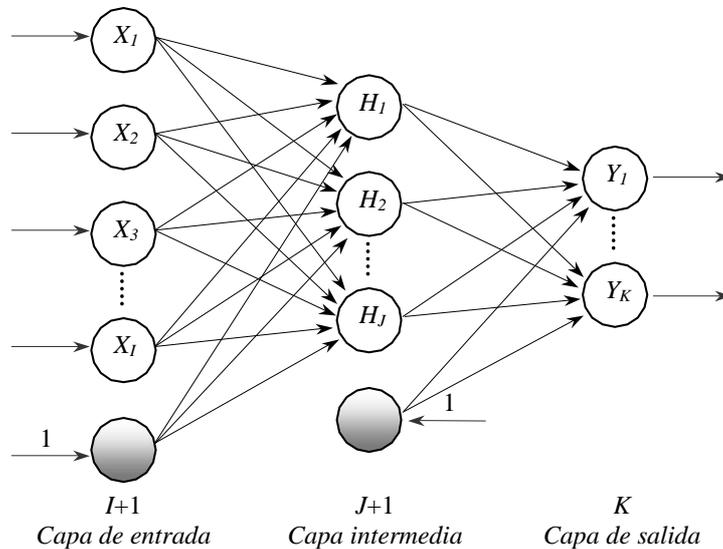


Figura 3: Red neuronal multicapa

En este trabajo se utilizan redes neuronales con una capa intermedia y con una sola neurona en la capa de salida ($Y = F(\mathbf{X})$). El número de neuronas en la capa intermedia puede variar desde una a un máximo controlado por el número de variables de entrada y el número de datos. Dada esa información el número óptimo de neuronas es calculado durante el entrenamiento.

El proceso de entrenamiento consiste en encontrar los pesos W que minimicen el error total entre las predicciones de la red y los resultados del análisis dinámico no lineal para diferentes combinaciones de las variables de entrada X_i . El conjunto de datos y resultados completos es dividido en un conjunto para entrenamiento y otro usado para validación. El error total es la suma de los calculados sobre el conjunto de entrenamiento y el de validación. Este error total es calculado para redes neuronales con diferente número de neuronas en la capa intermedia, eligiendo finalmente la de menor error total.

2.3 Base de datos discreta: rango para variables estructurales y movimiento del suelo

En la Figura 4 se muestra un pórtico plano sismorresistente genérico, utilizado para el cálculo de las respuestas discretas. Las variables y los límites considerados son: número de pisos $NP = 3$ a 10 , número de vanos $NV = 1$ a 4 , luz de los vanos $XL = 300$ a 600 cm todos iguales, masa por unidad de longitud en cada piso $m = 2.15 \times 10^{-4}$ a 4×10^{-4} KN s^2/cm^2 , resistencia característica del hormigón $f'_c = 20$ a 40 MPa , ancho de la sección de vigas $b_v = 15$ a 30 cm, altura de la sección de vigas $h_v = 40$ a 70 cm, ancho de la sección de columnas $b_c = 20$ a 40 cm, altura de la sección de columnas $h_c = 40$ a 100 cm.

Las cuantías de armadura, que cumplen con los requerimientos reglamentarios, tienen los siguientes límites: vigas en el tramo $\rho_{str} = \sqrt{f'_c} / (4 f_y)$ a $(f'_c + 10) / (6 f_y)$, en el apoyo $\rho'_{sap} = \sqrt{f'_c} / (4 f_y)$ a $(f'_c + 10) / (6 f_y)$, y en columnas $\rho_s = 0.008$ a 0.04286 . La presión de confinamiento normalizada es $f_r / f'_{c0} = 0.0$ a 0.15 . Además, las cuantías de armadura deben proveer una resistencia adecuada para las cargas gravitacionales sobre las vigas.

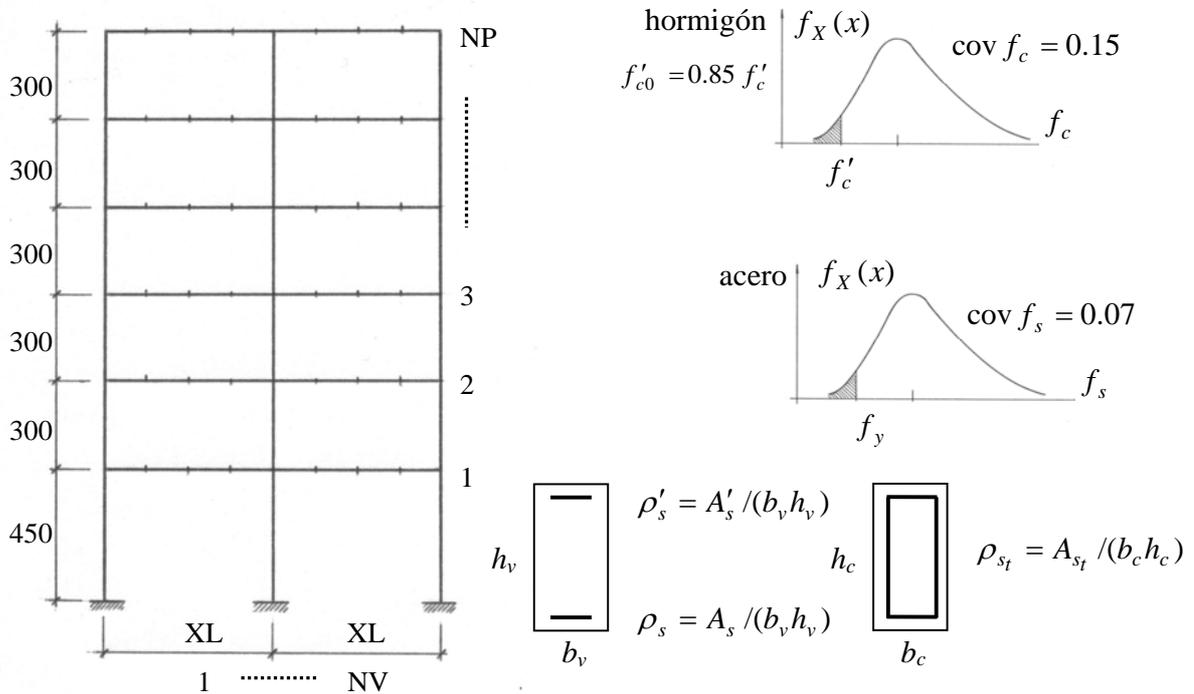


Figura 4: Variables de los pórticos analizados

Las dimensiones de vigas y columnas se reducen con la altura en función del número de pisos, como se indica en la Tabla 1.

NP	G1	G2	G3
3	2	1	
4	2	2	
5	3	2	
6	3	3	
7	3	2	2
8	3	3	2
9	3	3	3
10	4	3	3

Dimensiones en cada grupo
 G1: b_v, h_v b_c, h_c
 G2: $b_v, 0.8h_v$ $b_c, 0.8h_c$
 G3: $b_v, 0.6h_v$ $b_c, 0.6h_c$

Tabla 1: Número de pisos para cada grupo de dimensiones de vigas y columnas

Para la acción sísmica se considera la sismicidad de la ciudad de Mendoza, Argentina. Las variables y sus límites son la aceleración pico del suelo $a_G = 25$ a 1200 cm/s^2 , y la frecuencia central del filtro del suelo $f_g = 2.0$ a 3.0 HZ . Otras variables para la generación de los acelerogramas son funciones de a_G y f_g , ó se adoptan valores constantes.

Dentro de estos rangos y aplicando la técnica de diseño de experimentos (Zhang, 2003) se generan 900 combinaciones de las variables. Para cada una de ellas se obtienen 5 subcombinaciones (j) correspondiendo a diferentes registros sísmicos y considerando la aleatoriedad en los parámetros de la relación momento-curvatura de las secciones de las barras.

Para cada subcombinación se genera un acelerograma (Möller et al., 2008) siguiendo el procedimiento de Shinozuka (1967), teniendo en cuenta la no estacionariedad por una función de modulación, y escalando el acelerograma resultante a una deseada aceleración pico.

Cada subcombinación es resuelta con el modelo para análisis dinámico no lineal descrito en el punto 2.1, obteniéndose el desplazamiento máximo en el último piso u_{max} , la distorsión de piso máxima $DISTM$, el índice de daño de Park y Ang (1985) local máximo $DILOM$, y el índice de daño global DIG . Los cálculos de $DILOM$ y DIG son descriptos en Möller et al. (2008).

Así, para cada uno de estos parámetros de respuesta R_i , en cada una de las 900 combinaciones, se calculan los valores medios y desvíos estándar, para $N = 5$ casos correspondientes a las sub-combinaciones sobre los registros sísmicos y propiedades de histéresis, con:

$$\bar{R}_i = \frac{1}{N} \sum_{k=1}^N R_{k_i} \quad \sigma_{R_i} = \sqrt{\frac{1}{N-1} \sum_{k=1}^N (R_{k_i} - \bar{R}_i)^2} \quad (2)$$

Con estos resultados se ensamblan dos bases de 900 datos para cada parámetro de respuesta, que son usadas para entrenar dos redes neuronales: una para el valor medio y otra para el desvío estándar de la respuesta sobre las variables en las sub-combinaciones.

2.4 Resultados del entrenamiento de redes neuronales

Se entrenaron las redes neuronales para cada parámetro de respuesta estructural R_i , utilizando las bases de datos de las estadísticas de la respuesta. Como ejemplo, en la Figura 5 se muestra la aproximación alcanzada para $DISTM$ entre los resultados del análisis dinámico no lineal y las predicciones obtenidas con las redes neuronales. Como se observa en la figura, una buena representación es obtenida.

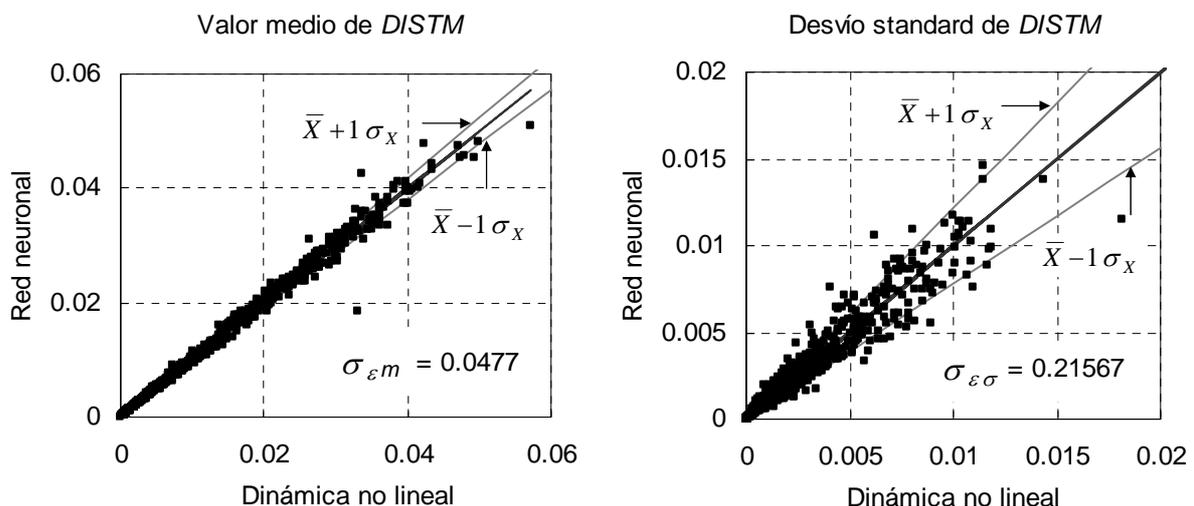


Figura 5: Resultados del entrenamiento de redes neuronales para \bar{DISTM} y σ_{DISTM}

Si la aproximación fuera perfecta, todos los puntos deberían estar sobre la línea a 45° . Se observa una dispersión alrededor de esta línea, más para el desvío estándar que para el valor medio, la que puede cuantificarse con el desvío estándar del error relativo, que es un coeficiente de variación promedio, dado por:

$$\sigma_{\varepsilon_r} = \sqrt{\frac{1}{N_E - 1} \sum_{k=1}^{N_E} \left(\frac{T_k - Y_k}{Y_k} \right)^2} \quad (3)$$

donde Y_k es el valor calculado con la red neuronal, T_k es el valor obtenido con análisis dinámico no lineal y $N_E = 900$, el número de combinaciones en la base de datos.

La ec.(3) puede ser usada para cuantificar las dispersiones σ_{ε_m} y $\sigma_{\varepsilon\sigma}$ asociadas con las redes neuronales para *DISTM*. Análisis similares se realizan para los otros parámetros de respuesta.

Haciendo uso de la ec.(3), el valor medio y el desvío estándar \bar{R}_i , σ_{R_i} de cada respuesta i , pueden ser representados como distribuciones Normales alrededor de los valores calculados con las redes neuronales

$$\bar{R}_i = \bar{Y}_i (1 + \sigma_{\varepsilon_m} X_{N1}) \quad \sigma_{R_i} = \sigma_{Y_i} (1 + \sigma_{\varepsilon\sigma} X_{N2}) \quad (4)$$

donde \bar{Y}_i , σ_{Y_i} son el valor medio y desvío estándar del parámetro i calculado con la red neuronal correspondiente, y X_{N1} , X_{N2} son variables Normales estándar.

3 ESTIMACIÓN DE LA CONFIABILIDAD

3.1 Niveles de desempeño, funciones de estado límite y variables aleatorias

La expresión genérica de la función de falla $G(\mathbf{X})$, o función de estado límite en cada nivel de desempeño a analizar, es

$$G(\mathbf{X}) = RLIM - R(\mathbf{X}) \quad (5)$$

donde $RLIM$ es el valor límite del parámetro de respuesta y $R(\mathbf{X})$ es la respuesta de la estructura en función del conjunto de variables aleatorias \mathbf{X} .

Las funciones de estados límites considerados para los niveles de desempeño operacional, seguridad de vidas y límite de colapso, se describen en las ecs.(6) a (13). En ellas, los números entre paréntesis indican el valor medio y su coeficiente de variación: $(RLIM, COVRL)$. En G_{11} , \bar{u}_y es el desplazamiento de fluencia medio del pórtico, debajo del cual la estructura permanece elástica, y estimado con una expresión dada por Priestley (1998).

Operacional

- Comportamiento elástico $G_{11}(\mathbf{X}) = (\bar{u}_y, 0.10) - u_{\max}(\mathbf{X}) \quad (6)$

- Distorsión de piso $G_{12}(\mathbf{X}) = (0.005, 0.10) - DISTM(\mathbf{X}) \quad (7)$

Seguridad de vidas

- Distorsión de piso $G_{21}(\mathbf{X}) = (0.015, 0.10) - DISTM(\mathbf{X}) \quad (8)$

- Índice daño local máximo $G_{22}(\mathbf{X}) = (0.60, 0.10) - DILOM(\mathbf{X}) \quad (9)$

- Índice de daño global $G_{23}(\mathbf{X}) = (0.40, 0.10) - DIG(\mathbf{X}) \quad (10)$

Límite de colapso

- Distorsión de piso $G_{31}(\mathbf{X}) = (0.025, 0.10) - DISTM(\mathbf{X}) \quad (11)$

$$\text{- Índice daño local máximo} \quad G_{32}(\mathbf{X}) = (1.00, 0.10) - DILOM(\mathbf{X}) \quad (12)$$

$$\text{- Índice de daño global} \quad G_{33}(\mathbf{X}) = (0.80, 0.10) - DIG(\mathbf{X}) \quad (13)$$

Cada función de respuesta $R(\mathbf{X})$ es además desarrollada para representar la variabilidad sobre las sub-combinaciones. Para el desplazamiento máximo en el último piso $u_{max}(\mathbf{X})$ y distorsión de piso máxima $DISTM(\mathbf{X})$, la variabilidad es representada por una distribución lognormal

$$R(\mathbf{X}) = \frac{\bar{R}(\mathbf{X})}{\sqrt{1. + \left(\frac{\sigma_R(\mathbf{X})}{\bar{R}(\mathbf{X})}\right)^2}} \exp\left[R_{N1} \sqrt{\ln\left(1. + \left(\frac{\sigma_R(\mathbf{X})}{\bar{R}(\mathbf{X})}\right)^2\right)}\right] \quad (14)$$

donde R_{N1} es una variable Normal estándar y el valor medio $\bar{R}(\mathbf{X})$ y desvío estándar $\sigma_R(\mathbf{X})$ son calculados utilizando la ec.(4) a partir de las correspondientes representaciones con redes neuronales.

La variabilidad para el índice de daño local máximo $DILOM(\mathbf{X})$, y para el índice de daño global $DIG(\mathbf{X})$, que están limitados entre 0 y 1, son representados por distribuciones Beta con esos mismos límites y los correspondientes valores medios $\bar{R}(\mathbf{X})$ y desvíos estándar $\sigma_R(\mathbf{X})$. Para calcular valores de $R(\mathbf{X})$ con la distribución Beta, se introduce una variable aleatoria R_{N2} uniformemente distribuida entre 0 y 1.

Se considera la incertidumbre en el valor límite $RLIM$ con distribución lognormal para el desplazamiento máximo y la distorsión de piso, requiriendo la introducción de una variable aleatoria adicional R_{N3} similar a la ec.(14). Para el índice de daño local máximo y el índice de daño global se asume distribución Beta, con una variable aleatoria adicional R_{N4} uniforme entre 0 y 1.

El pórtico estudiado tiene 6 pisos y 3 vanos, con alturas de entrepisos mostradas en la Figura 3, con la sismicidad correspondiente a la ciudad de Mendoza. Los tipos de distribución y estadística de todas las variables consideradas se presentan en la Tabla 2, donde el signo ? corresponde a los parámetros de diseño a optimizar, que son los valores medios de la altura de las secciones de vigas y columnas, y las cuantías de armadura longitudinal.

3.2 Probabilidad de falla

Para cada nivel de desempeño considerado, se calcula la probabilidad de falla Pf con:

$$Pf = P[G(\mathbf{X}) \leq 0] \quad (15)$$

utilizando el método de simulación de Monte Carlo estándar, incluyendo simultáneamente todas las funciones de estado límite en cada nivel de desempeño, de acuerdo con las ecs.(6) a (13), como sistema en serie. El número de simulaciones varía de 10^6 a 10^7 , trabajo que se facilita significativamente por el uso de redes neuronales que representan los parámetros de respuesta estructural $R(\mathbf{X})$.

La probabilidad de falla así calculada está condicionada a la ocurrencia de un terremoto. La probabilidad de falla anual se puede obtener considerando la ocurrencia de terremotos como un proceso de Poisson. Para la ciudad de Mendoza, terremotos de magnitudes $M \geq 5$ tienen una frecuencia media $\nu = 0.20$, luego la probabilidad de falla anual Pf_{anual} se puede estimar como:

$$Pf_{anual} = 1. - \exp[-\nu t_L Pf] \rightarrow \beta_{anual} \cong -\Phi^{-1}(Pf_{anual}) \quad (16)$$

donde $t_L = 1$ año. Pf_{anual} puede ser expresada por el índice de confiabilidad β_{anual} , como se indica en la ec.(16), usando la Distribución Normal estándar Φ .

Variable	\bar{X}	σ_X	Tipo	Variable	\bar{X}	σ_X	Tipo
$X(1) = NP$	6	0	Normal	$X(13) = f_r / f'_{c0}$	0.10	0.01	Normal
$X(2) = NV$	3	0	Normal	$X(14) = a_G$	$X(14) = X(16) [1.0+X(17)]$		
$X(3) = XL$	400 cm	20.0 cm	Normal	$X(15) = f_g$	2.50 Hz	0.375 Hz	Normal
$X(4) = m$	2.5×10^{-4}	2.5×10^{-5}	Normal	$X(16) = \bar{a}_G$	94 cm/s ²	130cm/s ²	Lognormal
$X(5) = f'_c$	30 MPa	3 MPa	Lognormal	$X(17) = \sigma_{\bar{a}_G}$	0	0.25	Normal
$X(6) = b_v$	20 cm	1 cm	Normal	$X(18) = R_{N4} (*)$	0	1	Uniforme
$X(7) = h_v$? cm	0.05 \bar{X}	Normal	$X(19) = R_{N3}$	0	1	Normal
$X(8) = b_c$	30 cm	1.5 cm	Normal	$X(20) = X_{N1}$	0	1	Normal
$X(9) = h_c$? cm	0.05 \bar{X}	Normal	$X(21) = X_{N2}$	0	1	Normal
$X(10) = \rho_{s,tr}$?	0.10 \bar{X}	Lognormal	$X(22) = R_{N2} (*)$	0	1	Uniforme
$X(11) = \rho'_{s,ap}$?	0.10 \bar{X}	Lognormal	$X(23) = R_{N1}$	0	1	Normal
$X(12) = \rho_s$?	0.10 \bar{X}	Lognormal	(*) Límites para distribución uniforme			

Tabla 2: Estadísticas de las variables aleatorias

3.3 Representación de los índices de confiabilidad por redes neuronales

Para hacer más eficiente el proceso de optimización, dentro del marco del diseño basado en el desempeño, a ser descrito en las siguientes secciones, se construye una base de datos para los índices de confiabilidad $\beta_1, \beta_2, \beta_3$ correspondientes a los tres niveles de desempeño. Así, para diferentes combinaciones de los parámetros de diseño, mostrados en la Tabla 3, se calculan los índices de confiabilidad como se discutió en los apartados anteriores, y luego se utilizan para entrenar las tres redes neuronales asociadas. Los datos de entrada para dichas redes son, justamente, los parámetros de diseño.

La ventaja de esta aproximación es que, durante el proceso de optimización, la evaluación de la confiabilidad, en cada paso, puede ser realizada utilizando las redes neuronales en lugar de las simulaciones de Monte Carlo.

La Figura 6 muestra la comparación entre los índices de confiabilidad calculados con las redes neuronales entrenadas y con el proceso de simulación de Monte Carlo, para cada nivel de desempeño. Se observa una pequeña dispersión que puede ser tenida en cuenta de la misma forma descrita para las redes neuronales de las respuestas estructurales. La Figura 6 muestra también, para cada caso, el desvío estándar del error relativo del entrenamiento.

Variable	\bar{X}	σ_X	Tipo
$X(7) = h_v = d_1$? cm	$0.05 \bar{X}$	Normal
$X(9) = h_c = d_2$? cm	$0.05 \bar{X}$	Normal
$X(10) = \rho_{s,tr} = d_3$?	$0.10 \bar{X}$	Lognormal
$X(11) = \rho'_{s,ap} = d_4$?	$0.10 \bar{X}$	Lognormal
$X(12) = \rho_s = d_5$?	$0.10 \bar{X}$	Lognormal

Tabla 3: Parámetros de diseño

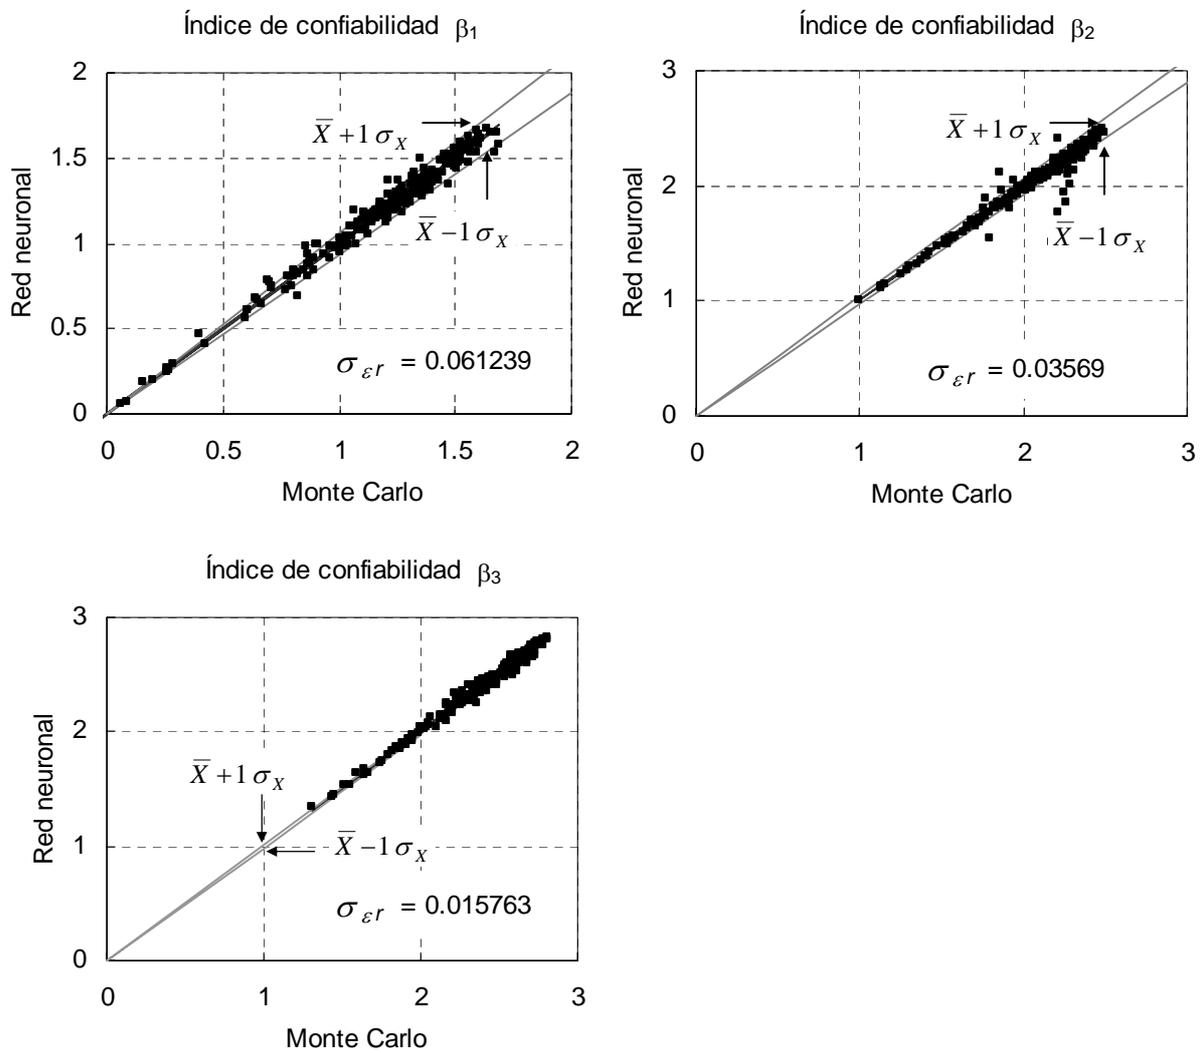


Figura 6: Redes neuronales entrenadas para los índices de confiabilidad

4 PROCESO DE OPTIMIZACIÓN

4.1 El problema

El problema de optimización se define de la siguiente manera: dada una función objetivo $F(\mathbf{d})$, siendo \mathbf{d} el vector de los parámetros de diseño, se pretende encontrar los valores óptimos de \mathbf{d} que hagan mínima la función objetivo F , sujeto a la restricción de cumplir con valores mínimos de los índices de confiabilidad β_i ($i = 1, M$) para cada uno de los M niveles de desempeño.

En este trabajo la función objetivo es el costo total de la estructura, incluyendo el costo inicial de construcción más el costo de reparación por daños, o reemplazo, después de la ocurrencia de un terremoto.

Los parámetros de diseño pueden ser definidos como los valores medios ó los desvíos estándar de algunas de las variables aleatorias del problema. En este caso, los parámetros de diseño son los valores medios de las alturas de las secciones de vigas y columnas h_v , h_c , y las cuantías de armadura longitudinal $\rho_{s,tr}$, $\rho'_{s,ap}$, ρ_s , ver la Tabla 3.

4.2 Estrategias de optimización

La solución al problema de optimización puede ser obtenida por una gran variedad de algoritmos. En este trabajo se utiliza un algoritmo que no necesita calcular gradientes, el cual se describe a continuación con dos estrategias numéricas.

▪ Variante 1

- a) Se elige aleatoriamente un conjunto de combinaciones para los parámetros de diseño, dentro de sus límites especificados.
- b) Para cada combinación se evalúa la confiabilidad, utilizando simulación de Monte Carlo y redes neuronales como sustituto de la respuesta estructural.
- c) Para aquellas combinaciones de los parámetros de diseño que satisfacen las restricciones de confiabilidad, se evalúa la función objetivo y se selecciona el caso que resulta con menor valor como “punto de anclaje inicial”.
- d) Un nuevo conjunto de combinaciones se eligen aleatoriamente en una hiperesfera de búsqueda alrededor del punto de anclaje inicial. Nuevamente se evalúa la confiabilidad utilizando simulación de Monte Carlo, y para aquellos casos que satisfacen las restricciones de confiabilidad se evalúa la función objetivo, eligiéndose el caso de menor valor como nuevo punto de anclaje.
- e) Este proceso se repite iterativamente hasta que no se encuentre ningún punto dentro del radio de búsqueda que, satisfaciendo las restricciones de confiabilidad, tenga un menor valor de la función objetivo que el correspondiente al punto de anclaje. Esa combinación, la del punto de anclaje, se elige como una aproximación del mínimo.
- f) Todo el proceso es repetido desde el principio con otra selección aleatoria de combinaciones de valores de los parámetros de diseño, encontrándose, en general, otro punto con mínimo valor de la función objetivo. Podría ser el caso de un problema que acepte varios mínimos. Si hay solamente un mínimo, entonces las diferencias entre los mínimos de cada ciclo serán pequeñas, dentro de las tolerancias numéricas. Finalmente la combinación óptima de parámetros de diseño es la que corresponde al mínimo de los mínimos de cada ciclo.

Este simple algoritmo evita problemas numéricos asociados al cálculo de gradientes, y su eficiencia es incrementada por el uso de redes neuronales como sustituto de la respuesta dinámica no lineal en cada simulación de Monte Carlo. El proceso se ilustra esquemáticamente en la Figura 7.

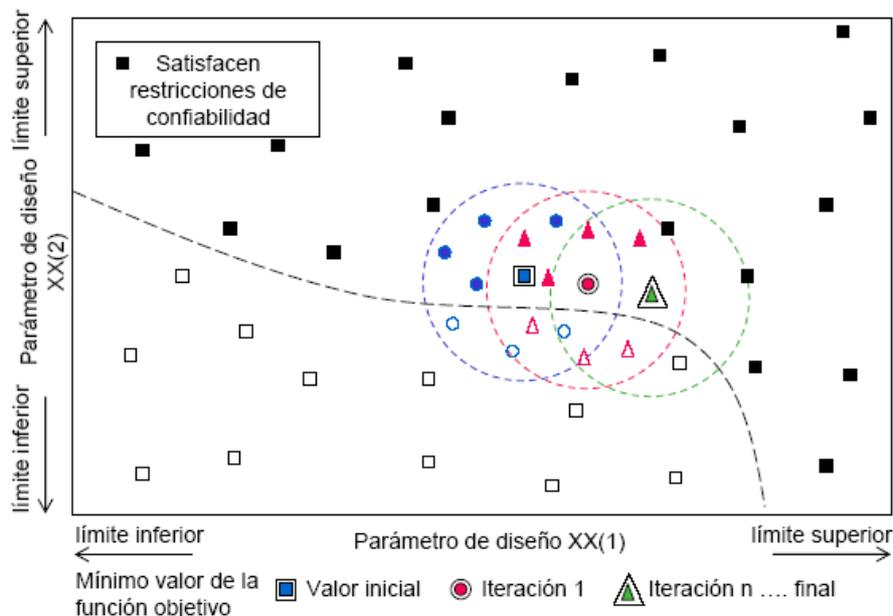


Figura 7: Proceso de optimización

▪ Variante 2

El proceso general de optimización es similar a la variante 1 descrita más arriba, con las siguientes diferencias:

En el paso b) la confiabilidad se evalúa utilizando las redes neuronales entrenadas para los índices de confiabilidad β_1 , β_2 , β_3 , como se describió en el punto 3.3.

En el paso d) también se utilizan las redes neuronales entrenadas para β_1 , β_2 , β_3 , en la evaluación de la confiabilidad de cada combinación seleccionada aleatoriamente dentro de la hipersfera de búsqueda alrededor del punto de anclaje. Similarmente para todo el proceso iterativo.

La demanda computacional podría ser bastante menor en este caso, dependiendo del número de iteraciones necesarias para convergencia en cada ciclo, y del número de ciclos completos realizados. Las simulaciones de Monte Carlo solo hay que realizarlas para construir la base de datos necesaria para entrenar las redes neuronales de los índices de confiabilidad, utilizando siempre en cada simulación las redes neuronales que aproximan la respuesta estructural.

5 EJEMPLO: RESULTADOS NUMÉRICOS

5.1 Parámetros de diseño

Los parámetros de diseño son los indicados en la Tabla 3, donde se observa su vinculación con las variables aleatorias del problema descriptas en la Tabla 2, dentro de los siguientes límites: altura de la sección de vigas $h_v = 40$ a 70 cm, altura de la sección de columnas $h_c = 40$ a 100 cm, cuantía de armadura de vigas en el tramo $\rho_{s,tr} = \sqrt{f'_c} / (4 f_y)$ a $(f'_c + 10) / (6 f_y)$, en el apoyo $\rho'_{s,ap} = \sqrt{f'_c} / (4 f_y)$ a $(f'_c + 10) / (6 f_y)$, y en columnas $\rho_{s,t} = 0.008$ a 0.04286 .

Además, los parámetros de diseño tienen restricciones entre ellos. Las cuantías de armadura deben proveer una resistencia adecuada para las cargas gravitacionales sobre las vigas, y además para garantizar una ductilidad mínima en las secciones de vigas se debe cumplir

$$\begin{aligned} 0.5 \rho'_{s,ap} &\leq \rho_{s,tr} \leq 2 \rho'_{s,ap} \\ 0.5 \bar{X}(11) &\leq \bar{X}(10) \leq 2 \bar{X}(11) \end{aligned} \quad (17)$$

5.2 Restricciones de confiabilidad

La probabilidad de excedencia anual tolerable Pf_{anual} en cada nivel de desempeño se especifica en la Tabla 4. Luego utilizando la ec.(16) se obtienen las probabilidades de falla si ocurre un evento sísmico Pf y los correspondientes índices de confiabilidad β .

Nivel de desempeño	Pf_{anual}	β_{anual}	Pf	β
Operacional	2×10^{-2}	2.054	0.10101	1.276
Seguridad de vidas	2×10^{-3}	2.878	0.10010×10^{-1}	2.326
Límite de colapso	7×10^{-4}	3.195	0.35012×10^{-2}	2.697

Tabla 4: Índices de confiabilidad objetivos

5.3 Función objetivo: costo total

La función objetivo adoptada aquí es el costo total de la estructura, incluyendo el costo inicial de construcción C_0 , más el costo de reparaciones C_1 asociado a diferentes niveles de daño, o reemplazo, después de un terremoto. Para éste último se debe tener en cuenta la probabilidad que un terremoto pueda ocurrir durante la vida útil de la estructura.

$$F(\mathbf{d}) = C_0(\mathbf{d}) + C_1(\mathbf{d}) \quad (18)$$

a) Costo inicial

El precio del hormigón incluye materiales, encofrado y mano de obra para la colocación, se estima en $CUH = 900$ $\$/m^3$. Para el acero, incluyendo material y mano de obra para la colocación, se estima en $CUA = 360$ $\$/KN$.

El volumen de hormigón, en función de las variables aleatorias \mathbf{X} del problema, ó en función de los parámetros de diseño \mathbf{d} , resulta

$$\begin{aligned}
 Vol(\mathbf{X}) &= V_{vigas} + V_{columnas} \\
 &= [\bar{X}(1) \bar{X}(2) \bar{X}(3) \bar{X}(6) \bar{X}(7) 0.9 + \\
 &\quad + (150 + 270 \bar{X}(1)) (1 + \bar{X}(2)) \bar{X}(8) \bar{X}(9)] 10^{-6} m^3 \quad \text{ó} \\
 Vol(\mathbf{d}) &= [145800 \cdot \bar{X}(7) + 212400 \cdot \bar{X}(9)] 10^{-6} m^3
 \end{aligned} \tag{19}$$

El peso de la armadura, incluyendo una cuantía aproximada por estribos, resulta

$$\begin{aligned}
 P(\mathbf{X}) &= [V_{vigas} (\rho_{s,tr} + 0.6 \rho'_{s,ap} + 0.0065) + V_{column} (\rho_s + 0.009)] 78.5 KN \\
 &= [V_{vigas} (\bar{X}(10) + 0.6 \bar{X}(11) + 0.0065) + V_{column} (\bar{X}(12) + 0.009)] 78.5 KN \quad \text{ó} \\
 P(\mathbf{d}) &= [0.1458 X(7) (\bar{X}(10) + 0.6 \bar{X}(11) + 0.0065) + \\
 &\quad + 0.2124 X(9) (\bar{X}(12) + 0.009)] 78.5 KN
 \end{aligned} \tag{20}$$

El costo inicial del pórtico resulta entonces

$$C_0(\mathbf{d}) = Vol(\mathbf{d}) CUH + P(\mathbf{d}) CUA \tag{21}$$

b) Costo por daños

El costo futuro de reparación, a valores actuales, depende del nivel de daño causado por el terremoto, del tiempo en el cual ocurre el terremoto dentro de la vida útil de la estructura, y del interés acumulado desde el momento de la construcción hasta la ocurrencia del daño.

El índice de daño global DIG es utilizado aquí como un indicador del perjuicio causado en la estructura. Siendo $C_f(DIG)$ el costo función de ese daño que ocurre en el tiempo t , $C_{f0}(DIG)$ el costo llevado al tiempo de construcción $t = 0$, r la tasa de interés, resulta

$$C_{f0}(DIG) = C_f(DIG) \exp(-rt) \tag{22}$$

Considerando el arribo de terremotos como un proceso de Poisson, la probabilidad que ocurra un terremoto en el tiempo t es

$$P(t \leq T_1 \leq t + dt) = f_{T_1}(t) dt = \nu \exp(-\nu t) dt \tag{23}$$

El valor esperado del costo en $t = 0$, condicionado al valor del daño DIG , es

$$C_1 |_{DIG} = \int_0^{\infty} C_{f0}(DIG) f_{T_1}(t) dt = C_f(DIG) \frac{\nu}{r + \nu} \tag{24}$$

Esta relación ha sido desarrollada por Sexsmith (1983). Se supone la siguiente relación entre el nivel de daño DIG y el costo de reparación.

$$\begin{aligned}
 C_f(DIG) &= \alpha C_0 \left(\frac{DIG}{0.60} \right)^b \quad \text{para } DIG \leq 0.60 \\
 C_f(DIG) &= \alpha C_0 \quad \text{para } DIG > 0.60
 \end{aligned} \tag{25}$$

en la cual C_0 es el costo de reemplazo completo de la estructura, con un porcentaje adicional $\alpha = 1.20$ por demolición y limpieza. En la ec.(24) se asume un reemplazo completo cuando DIG excede 0.60. Para daño menor a 0.60 el costo es función del daño a través del exponente b , que en este trabajo se adoptó $b = 1$. Otros costos como seguros, interrupción de servicio, etc., deberían ser tenidos en cuenta pero no fueron considerados en este ejemplo.

Finalmente el costo de reparación por daños resulta

$$C_1(\mathbf{d}) = \int_0^{\infty} C_1 |_{DIG} \cdot f_{DIG}(DIG) \cdot d(DIG) \quad (26)$$

utilizando la función de densidad de probabilidades para el índice de daño DIG . Ésta puede ser obtenida calculando primero la distribución acumulada mediante simulación de Monte Carlo y redes neuronales para la respuesta DIG , ajustando luego una distribución Beta, y finalmente la función de densidad por derivación.

El objetivo es la minimización del costo total esperado $C_0 + C_1$ sujeto a las restricciones de confiabilidad en cada nivel de desempeño.

5.4 Resultados

a) Proceso de optimización utilizando Monte Carlo en el cálculo de la confiabilidad

Los resultados obtenidos para este caso se resumen en la Tabla 5.

Parámetro	Ciclo 1	Ciclo 2	Ciclo 3
$d_1 = \bar{X}(7) = h_v (cm)$	59.18	62.65	59.95
$d_2 = \bar{X}(9) = h_c (cm)$	53.73	58.15	50.13
$d_3 = \bar{X}(10) = \rho_{s,tr}$	0.01117	0.00904	0.01024
$d_4 = \bar{X}(11) = \rho'_{s,ap}$	0.01211	0.01287	0.01145
$d_5 = \bar{X}(12) = \rho_{s,col}$	0.02124	0.01747	0.02624
Costo inicial (\$)	32332	33001	32456
Costo por daños (\$)	4914	4488	4414
Costo total (\$)	37246	37489	36870
β_1 ($\beta_{1T} = 1.276$)	1.4400	1.4710	1.4296
β_2 ($\beta_{2T} = 2.326$)	2.3512	2.3726	2.3508
β_3 ($\beta_{3T} = 2.697$)	2.7027	2.7059	2.7031

Tabla 5: Resultados cuando la confiabilidad se estima por simulación en cada paso de la optimización

En la Tabla 5, β_{1T} , β_{2T} , β_{3T} son los índices de confiabilidad objetivos indicados en la Tabla 4. Se realizaron tres ciclos completos del proceso de optimización, correspondiendo a tres elecciones iniciales diferentes de los parámetros de diseño. Los mínimos de los tres ciclos son muy similares entre ellos, pero con diferentes combinaciones de dimensiones de vigas y columnas, y de cuantías de armadura.

Dentro de las soluciones obtenidas, la solución “óptima”, mínimo de los mínimos de cada ciclo, para este ejemplo corresponde al ciclo 3, con un costo inicial intermedio, pero con el menor costo de reparaciones por daños, mostrando la importancia de considerar este tipo de costos en el análisis.

La optimización, con confiabilidades intermedias estimadas por simulación de Monte

Carlo usando redes neuronales para la respuesta estructural, requirió 225 simulaciones con 500000 muestras cada uno, para todo el proceso iterativo y los tres ciclos.

b) Proceso de optimización utilizando redes neuronales en el cálculo de la confiabilidad

La variante de estimar la confiabilidad, en cada paso del proceso de optimización, con las redes neuronales entrenadas para los índices de confiabilidad, produjo los resultados que se muestran en la Tabla 6.

Parámetro	Ciclo 1	Ciclo 2	Ciclo 3
$d_1 = \bar{X}(7) = h_v \text{ (cm)}$	60.41	59.76	61.23
$d_2 = \bar{X}(9) = h_c \text{ (cm)}$	53.10	53.06	50.71
$d_3 = \bar{X}(10) = \rho_{s,tr}$	0.01226	0.01171	0.00782
$d_4 = \bar{X}(11) = \rho'_{s,ap}$	0.01366	0.01270	0.01310
$d_5 = \bar{X}(12) = \rho_{s,col}$	0.01916	0.01782	0.02447
Costo inicial (\$)	32137	31310	31995
Costo por daños (\$)	3857	4258	3839
Costo total (\$)	35994	35568	35834
$\beta_1 \text{ (} \beta_{1T} = 1.276 \text{)}$	1.4179	1.4062	1.4560
$\beta_2 \text{ (} \beta_{2T} = 2.326 \text{)}$	2.3304	2.3306	2.4050
$\beta_3 \text{ (} \beta_{3T} = 2.697 \text{)}$	2.7098	2.7006	2.7148

Tabla 6: Resultados cuando la confiabilidad se estima con redes neuronales en cada paso de la optimización

Con esta estrategia numérica también se realizaron tres ciclos completos del proceso de optimización, comenzando cada uno de ellos con diferentes combinaciones de los parámetros de diseño. Los resultados del primer y tercer ciclo son similares respectivamente a los obtenidos en la Tabla 5. El caso “óptimo” resulta para el segundo ciclo con una combinación de dimensiones de vigas y columnas muy similar al primer ciclo. El costo inicial para el primer ciclo es mayor debido a mayores cuantías de acero, y resulta también en un costo de reparación menor. El segundo ciclo, que es el óptimo, tiene mayor costo de reparación pero no suficientemente alto como para revertir el ahorro inicial en acero.

Para generar las bases de datos para entrenar las redes neuronales de los índices de confiabilidad, se utilizaron 224 combinaciones de los parámetros de diseño, es decir se realizaron una cantidad de análisis con Monte Carlo similar a la estrategia anterior.

Sin embargo el tiempo de procesamiento de la optimización se reduce sustancialmente lo que permite hacer mayor cantidad de ciclos completos para buscar posibles mínimos locales, y la solución con menor costo final, ver comparación en el apartado c).

Como resultado del procesamiento para diez ciclos completos, el caso correspondiente al costo mínimo se presenta en la Tabla 7. Se obtiene un costo de \$35167 en lugar de \$35568, es decir una diferencia de 1.1%.

De esta forma pueden obtenerse varias combinaciones posibles de los parámetros de

diseño con costos totales similares. La combinación “óptima final” será elegida por el ingeniero teniendo en cuenta otros requerimientos constructivos.

Parámetro	Ciclo “óptimo”	Parámetro	Ciclo “óptimo”
$d_1 = \bar{X}(7) = h_v (cm)$	61.29	Costo inicial (\$)	31399
$d_2 = \bar{X}(9) = h_c (cm)$	51.78	Costo por daños (\$)	3768
$d_3 = \bar{X}(10) = \rho_{s,tr}$	0.00899	Costo total (\$)	35167
$d_4 = \bar{X}(11) = \rho'_{s,ap}$	0.01294	β_1 ($\beta_{1T} = 1.276$)	1.4483
$d_5 = \bar{X}(12) = \rho_{s,col}$	0.02383	β_2 ($\beta_{2T} = 2.326$)	2.3831
		β_3 ($\beta_{3T} = 2.697$)	2.7054

Tabla 7 Resultado óptimo de un conjunto de 10 ciclos

c) Comparación de tiempos de procesamiento

El equipo utilizado para realizar los cálculos numéricos de este trabajo es un PC con un procesador Pentium IV de 3.2GHz. Los tiempos de cálculo fueron los siguientes

a) Optimización utilizando Monte Carlo en el cálculo de la confiabilidad:

3 ciclos completos, donde fueron necesarios 225 evaluaciones: $72hs\ 10min = 4330min$

10 ciclos completos (por extrapolación, no fueron realizados): $4330 \times 10/3 = 14433min$

b) Optimización utilizando redes neuronales para $\beta_1, \beta_2, \beta_3$ en el cálculo de la confiabilidad

3 ciclos completos: base de datos para $\beta_1, \beta_2, \beta_3$, 224 Monte Carlos: 4100min
 entrenamiento de redes neuronales : $3 \times 38.3min = 114.9min$
 proceso de optimización: 6.4min
 Total: $4100 + 114.9 + 6.4 = 4221.3min$

10 ciclos completos: $4100 + 114.9 + 22.6 = 4237.5min$

Se observa que para 3 ciclos los tiempos son similares debido a que para formar la base de datos de $\beta_1, \beta_2, \beta_3$ se utilizaron casi la misma cantidad de simulaciones con Monte Carlo que en el proceso de optimización a). La ventaja de utilizar redes neuronales para el cálculo de los índices de confiabilidad durante el proceso de optimización b), se nota claramente cuando se requieren muchos ciclos completos, porque el incremento de tiempo es mínimo.

6 CONCLUSIONES

Del trabajo realizado se desprenden las siguientes conclusiones, así como sugerencias para futuras investigaciones.

- En el marco de la ingeniería sísmica basada en el desempeño, se consideran las incertidumbres presentes en demandas y capacidades para evaluar probabilidades de falla, o de excedencia anual, en varios niveles de desempeño requeridos, las que deben estar acotadas a valores admitidos.

- Para la formulación de los estados límites, los cálculos de la respuesta estructural requiere del análisis dinámico no lineal. No existe una relación explícita entre dichas respuestas y las variables aleatorias intervinientes. Se pueden obtener resultados discretos para diferentes combinaciones de las variables, y esos resultados pueden ser aproximados por una superficie de respuesta o red neuronal. En este trabajo se utilizan redes neuronales porque tienen las mejores características de flexibilidad y adaptabilidad.
- La tarea computacional importante es la construcción de las bases de datos discretos, realizando análisis dinámico no lineal para un número representativo de combinaciones de las variables dentro de sus límites. Para cada combinación de las variables se analiza un conjunto de sub-combinaciones con diferentes acelerogramas, calculándose el valor medio y desvío estándar de cada parámetro de respuesta. Con estas bases de datos se entrenan redes neuronales que son utilizadas para representar las respuestas en forma probabilística.
- La utilización de las redes neuronales como “sustituto” de la respuesta estructural, hace posible el cálculo de la probabilidad de falla utilizando el método de simulación directa de Monte Carlo, con un pequeño costo computacional.
- La confiabilidad asociada a cada nivel de desempeño puede así ser estimada para diferentes combinaciones de los parámetros de diseño, y dichos índices de confiabilidad también pueden ser representados por redes neuronales.
- La optimización consiste en encontrar un conjunto de valores de parámetros de diseño que, satisfaciendo los requerimientos de confiabilidad, minimicen una función objetivo. En este trabajo se muestra la implementación de un algoritmo de optimización basado en una búsqueda sin cálculo de gradientes, el cual ha mostrado un eficiente comportamiento tanto cuando las confiabilidades intermedias son evaluadas por simulación de Monte Carlo, como cuando dichas confiabilidades son obtenidas utilizando redes neuronales.
- Este esquema de optimización se aplicó a pórticos sismorresistentes de varios pisos, donde los parámetros de diseño son las dimensiones de los elementos estructurales y las cuantías de armaduras longitudinales. La función objetivo es el costo total, que incluye el costo inicial de construcción y el costo por daños considerando la probabilidad de ocurrencia de terremotos.
- Los resultados muestran un buen acuerdo entre las dos estrategias numéricas para la evaluación de la confiabilidad en cada paso del proceso de optimización, y que algunas diferencias en los valores de los parámetros de diseño corresponden a muy similares valores del costo total. También los resultados muestran que es importante la consideración de los costos de reparación por daños, y que este costo influye en la solución óptima.
- Este trabajo ha mostrado que redes neuronales son útiles para representar la relación entre respuestas estructurales y las variables aleatorias intervinientes, y entre los índices de confiabilidad y los parámetros de diseño. La primera aplicación hace posible el uso de la simulación de Monte Carlo para estimar confiabilidades o probabilidades de falla, mientras que la segunda mejora la eficiencia del algoritmo de optimización cuando confiabilidades intermedias necesitan ser evaluadas.
- Se debe continuar investigando y mejorando la relación entre niveles de daño y costos de reparación, así como la relación entre parámetros de daño y deformaciones o desplazamientos calculados. Aquí fue utilizado un índice de daño ampliamente conocido, pero se reconoce la necesidad de avanzar sobre la influencia de la historia de desplazamientos y deformaciones sobre el daño acumulado en el tiempo.

REFERENCIAS

- FEMA, "NEHRP Guidelines for the seismic rehabilitation of buildings", Report 273, *Buildings Seismic Safety Council*, 1997.
- Foschi, R., Li, H., Zhang, J., Reliability and performance-based design: a computational approach and applications, *Structural safety*, **24**, 205-218, 2002.
- Hurtado, J., *Structural Reliability – Statistical Learning Perspectives*, Lecture Notes in Applied and Computational Mechanics, Vol.17, Springer Verlag, 2004.
- Möller, O., Metodología para evaluación de la probabilidad de falla de estructuras sismorresistentes y calibración de códigos, *Tesis de Doctorado en Ingeniería*, Universidad Nacional de Rosario, 2001.
- Möller, O., Foschi, R., Reliability evaluation in seismic design: a response surface methodology, *Earthquake Spectra*, **19** (3), 579-603, 2003.
- Möller, O., Foschi, R., Rubinstein, M., and Quiroz, L.. Seismic Structural Reliability Using Different Nonlinear Dynamic Response Surface Approximations, *Structural Safety*, under review, 2008.
- Möller, O., Foschi, R., Rubinstein, M., Quiroz, L., Momento-curvatura de secciones de hormigón armado sismorresistentes utilizando redes neuronales. *Mecánica Computacional* Vol. XXV, 2145-2162, AMCA, 2006.
- Möller, O., Foschi, R., Rubinstein, M., Quiroz, L. Vulnerabilidad sísmica de estructuras: una aproximación probabilística usando redes neuronales, *Memorias XIX Jornadas Argentinas de Ingeniería Estructural*, CD, 050, AIE, 2006.
- Möller, O., Foschi, R., Rubinstein, M., Quiroz, L. Confiabilidad de estructuras sismorresistentes utilizando diferentes aproximaciones de la respuesta dinámica no lineal. *Memorias del Séptimo Encuentro de Investigadores y Profesionales Argentinos de la Construcción VII EIPAC 2007*, CD E08-01, 2007.
- Park, Y.J., Ang, A.H-S, Mechanistic seismic damage model for reinforced concrete. *Journal of Structural Engineering*, ASCE, Vol.111 (ST4), pp.722-739, 1985.
- Pérez López, Jesús R., Contribución a los métodos de optimización basados en procesos naturales y su aplicación a la medida de antenas en campo próximo. URL <http://www.tesisenred.net/TDR-0305107-180847>, 2005.
- Priestley, M.J.N., Brief comments on elastic flexibility of reinforced concrete frames and significance to seismic design, *Bulletin of the New Zealand National Society for Earthquake Engineering*, Vol 3, N° 4, 1998.
- SEAOC Vision 2000 Committee. Performance based seismic engineering of buildings. *Structural Engineers Association of California, Sacramento, California, U.S.A.*, 1995.
- Sexsmith, R.G. Bridge risk assessment and protective design for ship collision, *Proc. Colloquium on Ship Collision with Bridges and Offshore Structures*, International Association for Bridge and Structural Engineering, IABSE, Copenhagen, 1983.
- Shinozuka M, Sato Y. Simulation of nonstationary random processes. *ASCE Journal of Engineering Mechanics*; 93(1): 11-40, 1967.
- Zhang, J., Performance-based seismic design using designed experiments and neural networks, *PhD. Thesis*, Department of Civil Engineering, University of British Columbia, Canada, 2003.
- Zhang, J., Foschi, R.O., Performance-based design and seismic reliability analysis using designed experiment and neural networks, *Probabilistic Engineering Mechanics*, **19**, 259-267, 2004.

AGRADECIMIENTOS

Este trabajo fue realizado con los aportes de los Proyectos de Investigación “Confiabilidad de sistemas estructurales bajo solicitaciones dinámicas” IING 142 (19/I202) de la Universidad Nacional de Rosario, Argentina, y “Neural networks for reliability and performance-based design in earthquake engineering” Natural Science Engineering Research Council: RGPIN 5882-04, University of British Columbia, Vancouver, Canada.