

OPTIMIZACIÓN DE PÓRTICOS SISMORRESISTENTES UTILIZANDO REDES NEURONALES Y ALGORITMO SIN CÁLCULO DE GRADIENTES

Oscar Möller^a, Ricardo O. Foschi^b, Marcelo Rubinstein^a y Laura M. Quiroz^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 claves: Ingeniería Sísmica, Optimización, Análisis no lineal, Redes neuronales, Algoritmo libre de gradientes.

Resumen. Se presenta un proceso de optimización de estructuras sismorresistentes que consiste en encontrar valores a ciertos parámetros de diseño, tal que la estructura satisfaga probabilidades de excedencia anual admitidas, o índices de confiabilidad, y que minimice alguna función objetivo como el peso total o el costo final. La tarea computacional importante es el análisis dinámico no lineal de la estructura para obtener los parámetros de respuesta de interés, teniendo en cuenta las variables aleatorias, y para un conjunto de acelerogramas que puedan ocurrir en el sitio. La evaluación de la confiabilidad se realiza por simulación directa de Monte Carlo en forma eficiente por la aproximación de la respuesta estructural con un “sustituto”, en este trabajo redes neuronales que poseen las mejores características de flexibilidad y adaptabilidad. El proceso de optimización se realiza con un algoritmo de búsqueda que no utiliza cálculo de gradientes. Los ejemplos presentados muestran la potencialidad y ventajas de estas técnicas numéricas.

Abstract. An optimization process of earthquake-resistant structures is presented, which means to meet values of a set of design parameters that satisfy prescribed probabilities of annual exceedance or reliability indices, and to minimize an objective function like the total weight or cost. The major computational effort is the structural non linear dynamic analysis to obtain the response parameters, taking into account the uncertainties, for a set of earthquake records likely to occur at a site. The reliability evaluation is done by direct simulation of Monte Carlo, efficiently due to the approximation of the structural response by a “substitute”, in this work neural networks that show more flexible and efficient representation. The optimization process is carried out by a search algorithm, gradient free. The presented examples show the power and advantages of these numerical techniques.

1 INTRODUCCIÓN

Dentro del marco del diseño sísmico basado en el desempeño (SEAOC Vision 2000, 1995; FEMA 273, 1997), se consideran las incertidumbres presentes en la demanda sísmica y en la capacidad estructural. El tratamiento de dichas incertidumbres requiere el uso de métodos probabilísticos evaluando la probabilidad de “falla” o excedencia anual en cada nivel de desempeño y compararla con valores tolerables.

La optimización consiste en encontrar valores a ciertos parámetros de diseño, tal que la estructura satisfaga probabilidades de excedencia anual admitidas, o índices de confiabilidad, y que minimice alguna función objetivo como el peso total o el costo final.

El comportamiento estructural es dinámico y fuertemente no lineal, y su respuesta debe ser encontrada mediante análisis numérico, por ejemplo por elementos finitos, para la duración del terremoto. No es posible establecer una relación explícita entre las variables básicas intervinientes y la respuesta dinámica, y los resultados pueden ser obtenidos solamente de forma discreta, dando valores específicos a las variables estructurales y un registro sísmico particular.

Luego, la evaluación de la confiabilidad debe ser realizada por simulación, por ejemplo Monte Carlo, en el cual en cada simulación se debe encontrar la historia de la respuesta dinámica no lineal, con el método de elementos finitos, y esto consume un gran tiempo de computación. Además, es conveniente usar el método de Monte Carlo básico o “crudo”, porque es general, no necesita asumir la forma de la superficie de falla ni requiere la ubicación de puntos de diseño o anclaje, ni necesita de transformaciones de variables. Pero se requieren 10^6 a 10^7 simulaciones para obtener una aceptable confianza en probabilidades de falla de 10^{-2} a 10^{-4} .

La eficiencia del proceso es mejorada significativamente si los resultados discretos se representan por una función, superficie de respuesta, la cual luego es utilizada como “sustituto” (Hurtado, 2004) de la verdadera respuesta. Entonces, en cada simulación el cálculo se realiza con el “sustituto” que prácticamente no consume tiempo de computación.

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, Foschi, Rubinstein y Quiroz, 2006 a, b).

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, conduce 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 estratégicamente.

Para el proceso de optimización, entre las estructuras que cumplen con los índices de confiabilidad objetivo, se busca aquella que tenga el mínimo volumen o mínimo costo. El algoritmo numérico implementado en este trabajo no hace uso de gradientes, como es usual en los algoritmos de minimización, evitándose problemas numéricos como encontrar mínimos locales, o inconvenientes propios del proceso de simulación donde la respuesta estructural es también una variable aleatoria.

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.

2 RESPUESTA DINÁMICA NO LINEAL Y REPRESENTACIÓN CON REDES NEURONALES

2.1 Modelo para análisis dinámico no lineal

El pórtico se discretiza con elementos de barra (Möller, 2001), con los cuales se alcanza un buen balance entre precisión y simplicidad.

Para representar los diferentes mecanismos que contribuyen al comportamiento histerético de las regiones críticas de miembros de hormigón armado, el elemento se descompone en varios subelementos conectados en serie: (i) *Subelemento elastoplástico*: representa el comportamiento elástico de la barra y la respuesta no lineal de las regiones extremas, con longitud variable dependiendo de la historia de carga; (ii) *Subelemento conexión*: caracteriza la rotación concentrada que se produce en la interfaz barra-nudo por deterioro del anclaje y deslizamiento de armaduras ancladas en el nudo; (iii) *Subelemento corte*: describe la distorsión por corte en las regiones críticas de la barra y el deslizamiento por corte en la interfaz barra-nudo. Extremos rígidos consideran nodos de dimensiones no despreciables.

En este trabajo se utiliza solamente el subelemento elastoplástico, el cual se representa en la fig.1.




Figura 1: Subelemento elastoplástico – Relación momento curvatura

Las hipótesis fundamentales son: (a) El estado de toda la zona plástica, durante carga, descarga o recarga, es controlado por el estado de la sección extrema. (b) La rigidez de la zona plástica se representa por una rigidez promedio efectiva pEI , la cual depende de la sección extrema. Estas hipótesis significan que sólo hay que seguir la historia momento-curvatura de las dos secciones extremas del elemento.

Se 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 las Teorías de aprendizaje estadístico (Hurtado, 2004), las redes neuronales artificiales son dispositivos computacionales compuestos por unidades de procesamiento, “neuronas”, interconectadas. Cada unidad recibe información, realiza cálculos simples y el resultado es pasado a la capa de neuronas siguiente. La red en conjunto tiene la habilidad de responder frente a estímulos de entrada y producir las respuestas correspondientes. 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, $F(\mathbf{X})$ la aproximación con red neuronal, $h(t)$ es una función no lineal llamada sigmoide, w_k son factores de peso y X_i las variables del problema.

Las principales características son: (i) Adaptable: los parámetros de las funciones son determinados por los puntos utilizados en la optimización de la red; (ii) Flexible: la región activa de cada función base $h_i(t)$ es limitada, de manera que valores de X alejados de su zona de influencia no producen resultados de significación. Así los errores en algún punto no se difunden; (iii) Capacidad para aprender de la experiencia y ejemplos: la red se entrena a partir de un conjunto de datos y resultados conocidos del análisis completo del sistema.

En la fig.2 se muestra un esquema de la arquitectura de la “red neuronal multicapa” implementada. En este trabajo se utiliza una sola capa intermedia y una capa de salida con una única neurona, es decir que cada red sólo se utiliza para obtener un único resultado a partir de la información de entrada. El número de neuronas de la capa de entrada resulta de la cantidad de variables de entrada más una neurona.

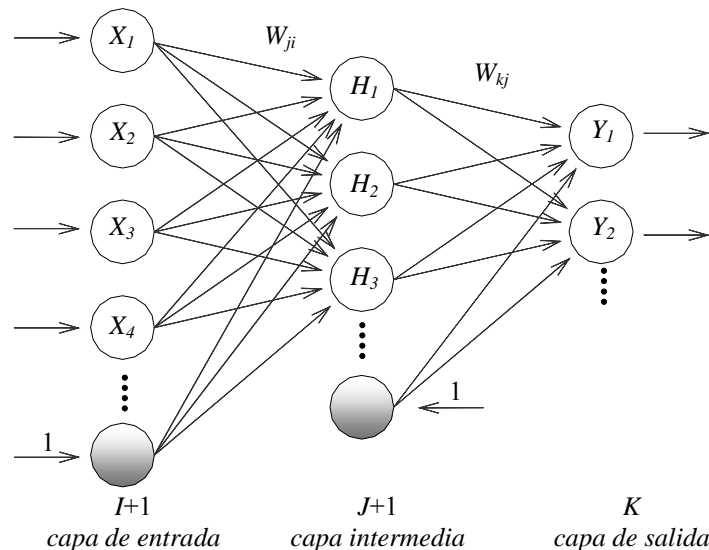


Figura 2: Red neuronal multicapa

La transferencia de información de neuronas de capas adyacentes se realiza a través de unos coeficientes de peso w y de una función de transferencia $h(t)$. Si en la fig.2 se considera que el número de neuronas en la capa de entrada, oculta y de salida son $I+1$, $J+1$ y K respectivamente; y que X_i^p es el p -ésimo dato de la i -ésima neurona de la capa de entrada, I_j^p

el p -ésimo dato de la j -ésima neurona de la capa oculta, H_j^p el p -ésimo resultado de la j -ésima neurona de la capa oculta, I_k^p el p -ésimo dato de la k -ésima neurona de la capa de salida, e Y_k^p el p -ésimo resultado de la k -ésima neurona de la capa de salida, luego resultan las siguientes expresiones:

$$I_j^p = \sum_i^I w_{ji} X_i^p + w_{j0} \quad H_j^p = h(I_j^p) \quad (2)$$

$$I_k^p = \sum_j^J w_{kj} H_j^p + w_{k0} \quad Y_k^p = h(I_k^p) \quad (3)$$

donde w_{ji} son los factores de peso que conectan la i -ésima neurona de la capa de entrada con la j -ésima neurona de la capa oculta, w_{kj} son los factores de peso que conectan las neuronas j -ésima con la k -ésima y $h(\cdot)$ es la función de transferencia dada por:

$$h(x) = \frac{1.0}{(1 + \exp(-x))} \quad (4)$$

Para completar la arquitectura de la red debe determinarse el número óptimo de neuronas de la capa intermedia. En general una red con pocas neuronas en la capa oculta no logra capturar las relaciones entre los datos y los resultados, mientras que una con muchas neuronas tiende a no poder generalizar para datos distintos a los del entrenamiento.

El número máximo de neuronas, está en función del número de variables de entrada $NINT$ y del número de conjunto de datos $NDAT$

$$NEUMAX = \frac{0.8 NDAT - 1}{NINT + 2} \quad (5)$$

El proceso para encontrar el número óptimo de neuronas de la capa intermedia consiste en evaluar el error generalizado para diferente cantidad de neuronas desde 1 a $NEUMAX$, y adoptar la de menor error. El error generalizado (total), se minimiza utilizando un algoritmo iterativo de retropropagación de errores. Es un método de gradiente descendente en el cual los factores de peso w se van optimizando iterativamente (aprendizaje) en forma proporcional a la diferencia entre los valores objetivos T_k y las predicciones de la red Y_k .

Este error generalizado se calcula con

$$E = \frac{1}{2} \sum_p \sum_k (Y_k^p(w) - T_k^p)^2 \quad (6)$$

La red es entonces entrenada presentándole una base de datos y resultados disponibles, optimizando los factores de peso w_{ji} , w_{kj} utilizando el mismo algoritmo de retropropagación de errores.

$$w_{ji}(g+1) = w_{ji}(g) + \Delta w_{ji}(g) \quad \text{con} \quad \Delta w(g) = -\eta \nabla E(g) + \alpha \Delta w(g-1) \quad (7)$$

donde g es el número de la iteración, η la tasa de entrenamiento que depende del problema; si es demasiado alta la red podrá no converger al resultado para algunas muestras, si es demasiado baja la convergencia será muy lenta, y α es el denominado momento. En este trabajo se utilizó $\eta = 0.01$ y $\alpha = 0.05$.

Luego de ser entrenada, la red puede ser usada para realizar predicciones de $R(\mathbf{X})$.

2.3 Pórticos analizados

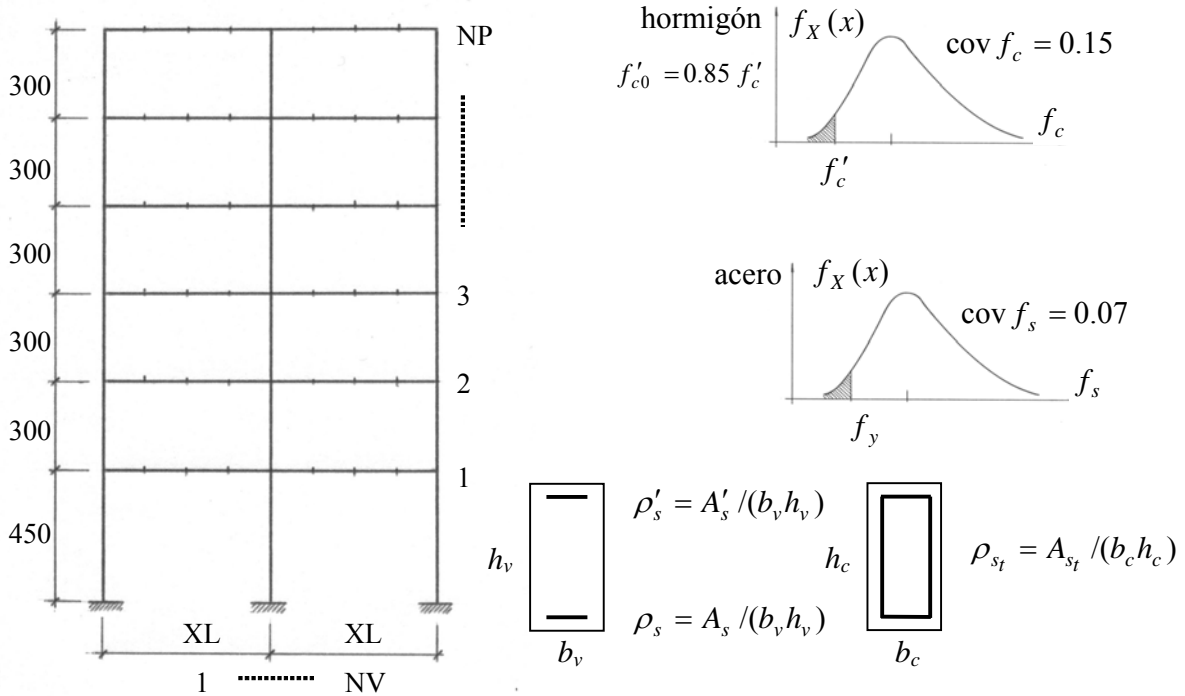


Figura 3: Variables de los pórticos analizados

En la fig.3 se muestra un pórtico plano sismorresistente genérico, donde 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 . De acuerdo al número de pisos las dimensiones de vigas y columnas se reducen con la altura, 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 de pisos

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 con dimensiones de vigas y columnas

Las cuantías de armadura, que respetan los límites reglamentarios, son: 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 . 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.

$$\phi (M_{tramo} + M_{apoyo}) \geq \frac{q_u XL^2}{8} \quad (8)$$

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 $a_s = 25$ 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_s y f_g , ó se adoptan valores constantes.

Empleando 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) considerando la aleatoriedad en la secuencia de ángulos de fase para generar el acelerograma, y en los parámetros de la relación momento-curvatura de las secciones de las barras.

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 .

Para cada uno de estos parámetros de respuesta R_i , de cada una de las 900 combinaciones, se calculan los valores medios y desvíos standard para $N = 5$ con:

$$\bar{R}_i = \frac{1}{N} \sum_{k=1}^N R_{ki} \quad \sigma_{R_i} = \sqrt{\frac{1}{N-1} \sum_{k=1}^N (R_{ki} - \bar{R}_i)^2} \quad (9)$$

Así, para cada parámetro de respuesta, dos bases de 900 datos son ensamblados, representando un estimador del valor medio y desvío standard de una respuesta particular sobre el conjunto de acelerogramas usados. Estas dos bases de datos son usadas para entrenar las correspondientes redes neuronales.

2.4 Entrenamiento de las redes neuronales

Siguiendo el procedimiento descrito en el punto 2.2, se entrenaron las redes neuronales que representan los valores medios y los desvíos standard de los parámetros de respuesta R_i . En la fig.4 se presentan los resultados del entrenamiento correspondientes a la distorsión de piso máxima $DISTM$. Como se observa en la figura, una buena representación es obtenida.

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 standard que para el valor medio. Esa dispersión puede cuantificarse con el desvío standard del error relativo, que es un coeficiente de variación promedio, dado por:

$$\sigma_{\varepsilon_r} = \sqrt{\frac{1}{N_E - 1} \sum_{k=1}^{N_E} \left(\frac{Y_k - T_k}{T_k} \right)^2} \quad (10)$$

donde Y_k es el valor calculado con la red, T_k es el valor obtenido con momento-curvatura y $N_E = 900$, el número de combinaciones de los datos de entrada de la red.

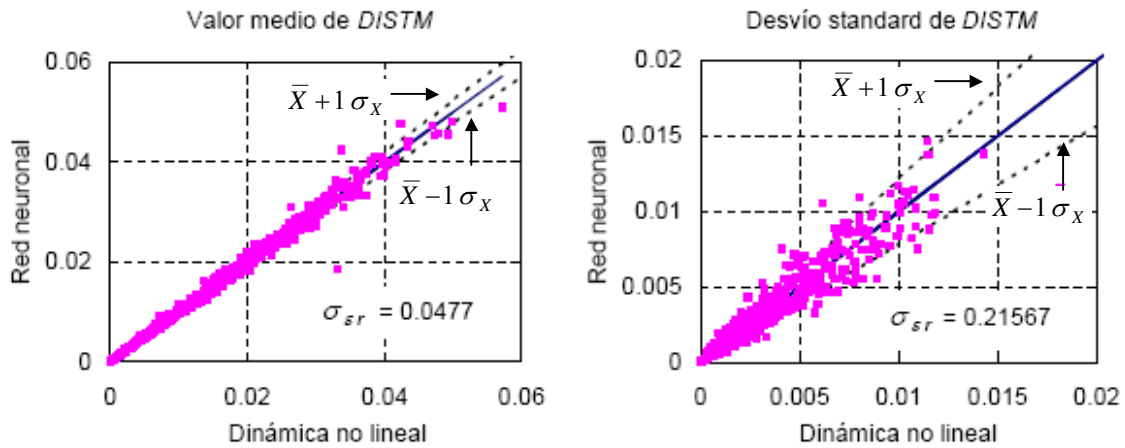


Figura 4: Resultados para \overline{DISTM} y σ_{DISTM}

Como se observa en la fig.4 los resultados Y_k se distribuyen sin preferencias hacia un lado y otro de T_k , de forma tal que puede adoptarse una distribución normal. Luego resulta:

$$\overline{R}_i = \overline{Y}_i (1. + \sigma_{\varepsilon_r} X_N) \quad \sigma_{R_i} = \sigma_{Y_i} (1. + \sigma_{\varepsilon_r} X_N) \quad (13)$$

donde $\overline{Y}_i, \sigma_{Y_i}$ son el valor medio y desvío standard del parámetro i calculado con la red neuronal correspondiente, σ_{ε_r} el desvío standard del error relativo (10), y X_N una variable aleatoria con distribución normal standard (0,1).

3 EVALUACIÓN DE LA CONFIABILIDAD

3.1 Variables aleatorias

Se estudia la optimización de algunas variables para pórticos de 6 pisos y 3 vanos solicitados por la sismicidad de la ciudad de Mendoza, Argentina.

Los datos numéricos de todas las variables consideradas se presentan en la tabla 2, donde el signo ? corresponde a los parámetros de diseño a optimizar que se detallarán en las aplicaciones.

3.2 Funciones de falla

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

$$G(\mathbf{X}) = RLIM - R(\mathbf{X}) \quad (14)$$

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 $X_i, i = 1, N$.

Variable	\bar{X}	σ_X	Tipo	Variable	\bar{X}	σ_X	Tipo
$X(1) = NP$	6	0	Normal	$X(12) = \rho_s$?	$0.10 \bar{X}$	Lognormal
$X(2) = NV$	3	0	Normal	$X(13) = f_r / f'_{c0}$	0.10	0.01	Normal
$X(3) = XL$	450 cm	22.5 cm	Normal	$X(14) = a_G$	$X(14) = X(16) [1.0+X(17)]$		
$X(4) = m$	3×10^{-4}	3×10^{-5}	Normal	$X(15) = f_g$	2.50 Hz	0.375 Hz	Normal
$X(5) = f'_c$	30 MPa	3 MPa	Lognormal	$X(16) = \bar{a}_G$	94 cm/s ²	130cm/s ²	Lognormal
$X(6) = b_v$	20 cm	1 cm	Normal	$X(17) = \sigma_{\bar{a}_G}$	0	0.25	Normal
$X(7) = h_v$? cm	$0.05 \bar{X}$	Normal	$X(18) = X(N-3)$	0	1	Normal
$X(8) = b_c$	30 cm	1.5 cm	Normal	$X(19) = X(N-2)$	0	1	Normal
$X(9) = h_c$? cm	$0.05 \bar{X}$	Normal	$X(20) = X(N-1)$	0	1	Normal
$X(10) = \rho_{s,tr}$?	$0.10 \bar{X}$	Lognormal	$X(21) = X(N)$	0	1	Normal
$X(11) = \rho'_{s,ap}$?	$0.10 \bar{X}$	Lognormal				

Tabla 2: Datos de las variables aleatorias

La incertidumbre en RLIM se tiene en cuenta con un coeficiente de variación COVRL, resultando

$$RLIM = \overline{RLIM} (1 + COVRL X(N-1)) \quad (15)$$

A partir de \bar{R}_i, σ_{R_i} dado por (13), y considerando una distribución lognormal para la respuesta estructural, se obtiene

$$R(\mathbf{X}) = \frac{\bar{R}(\mathbf{X})}{\sqrt{1 + \left(\frac{\sigma_R(\mathbf{X})}{\bar{R}(\mathbf{X})}\right)^2}} \exp \left[X(N) \sqrt{\ln \left(1 + \left(\frac{\sigma_R(\mathbf{X})}{\bar{R}(\mathbf{X})}\right)^2 \right)} \right] \quad (16)$$

con

$$\bar{R}(\mathbf{X}) = \bar{Y}(\mathbf{X}) (1 + \sigma_{\varepsilon_R} X(N-3))$$

$$\sigma_R(\mathbf{X}) = \sigma_Y(\mathbf{X}) (1 + \sigma_{\varepsilon_\sigma} X(N-2))$$

Se requiere calcular los índices de confiabilidad para probabilidades de excedencia anual en los niveles de desempeño operacional, seguridad de vidas y colapso. Los estados límites considerados en cada nivel de desempeño son:

Operacional

- Comportamiento elástico $G_{11}(\mathbf{X}) = u_y (1 + 0.10 X(N-1)) - u_{\max}(\mathbf{X}) \quad (17)$

- Distorsión de piso $G_{12}(\mathbf{X}) = 0.005 (1 + 0.10 X(N-1)) - DISTM(\mathbf{X}) \quad (18)$

Seguridad de vidas

- Distorsión de piso $G_{21}(\mathbf{X}) = 0.015 (1 + 0.10 X(N-1)) - DISTM(\mathbf{X}) \quad (19)$

- Índice daño local máximo $G_{22}(\mathbf{X}) = 0.60 (1 + 0.10 X(N-1)) - DILOM(\mathbf{X}) \quad (20)$

$$\text{- Índice de daño global} \quad G_{23}(\mathbf{X}) = 0.40 (1. + 0.10 X(N - 1)) - DIG(\mathbf{X}) \quad (21)$$

Límite de colapso

$$\text{- Distorsión de piso} \quad G_{31}(\mathbf{X}) = 0.025 (1. + 0.10 X(N - 1)) - DISTM(\mathbf{X}) \quad (22)$$

$$\text{- Índice daño local máximo} \quad G_{32}(\mathbf{X}) = 1.00 (1. + 0.10 X(N - 1)) - DILOM(\mathbf{X}) \quad (23)$$

$$\text{- Índice de daño global} \quad G_{33}(\mathbf{X}) = 0.80 (1. + 0.10 X(N - 1)) - DIG(\mathbf{X}) \quad (24)$$

En G_{11} , u_y es el desplazamiento de fluencia del pórtico estimado con una expresión dada por Priestley (1998), debajo del cual la estructura permanece elástica.

3.3 Probabilidad de falla

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

$$Pf = P[G(\mathbf{X}) \leq 0] \quad (25)$$

utilizando el método de simulación de Monte Carlo standard con 10^6 a 10^7 simulaciones según el caso, para todos los “modos de falla” simultáneamente como sistema en serie.

Este análisis se facilita significativamente utilizando las correspondientes redes neuronales entrenadas para el cálculo de los parámetros de respuesta estructural $R(\mathbf{X})$ en cada simulación.

Considerando la ocurrencia de terremotos como un proceso de Poisson, con frecuencia media $\nu = 0.20$ para la ciudad de Mendoza, para magnitudes de interés $M \geq 5$, se calcula la probabilidad de falla anual como:

$$Pf_{anual} = 1. - \exp[-\nu t_L Pf_E] \rightarrow \beta_{anual} \cong -\Phi^{-1}(Pf_{anual}) \quad (26)$$

donde Pf_E es la probabilidad de falla si ocurre un evento sísmico y $t_L = 1$ año. Pf_E y Pf_{anual} pueden ser expresados en términos de sus correspondientes índices de confiabilidad β .

4 PROCESO DE OPTIMIZACIÓN

4.1 El problema

El problema de optimización puede ser establecido de la siguiente manera

- Dado un sistema con N variables aleatorias, X_i ($i = 1, N$), y M requerimientos de desempeño o estados límites $G_j(X_i)$, ($j = 1, M$), que deben cumplir con probabilidades de excedencia anual prescripta, o con índices de confiabilidad β_j .
- Determinar el correspondiente conjunto de parámetros de diseño d_k ($k = 1, L$) que satisfagan los requerimientos de confiabilidad y que también minimicen una función objetivo $F(d_k)$, por ejemplo el costo total del sistema.

Los parámetros de diseño pueden ser definidos como valores medios y/o desvíos standard de algunas de las variables aleatorias X_i .

4.2 La solución

En la solución a este problema de optimización se pueden emplear una gran variedad de algoritmos. En este trabajo se utiliza un algoritmo que no necesita calcular gradientes, el cual se describe a continuación.

- 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 un círculo de búsqueda alrededor del punto de anclaje inicial. Nuevamente se evalúa la confiabilidad, 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.
- 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.
- g) Dependiendo de la naturaleza del problema, el ciclo completo se puede repetir varias veces, y finalmente la combinación óptima de parámetros de diseño es el que corresponde al mínimo de los mínimos de cada ciclo.

Este proceso evita el cálculo de gradientes, por lo tanto evita muchos problemas numéricos, y su eficiencia es incrementada por el uso de redes neuronales en el cálculo de los índices de confiabilidad para cada combinación analizada. Este proceso se ilustra en la fig.5.

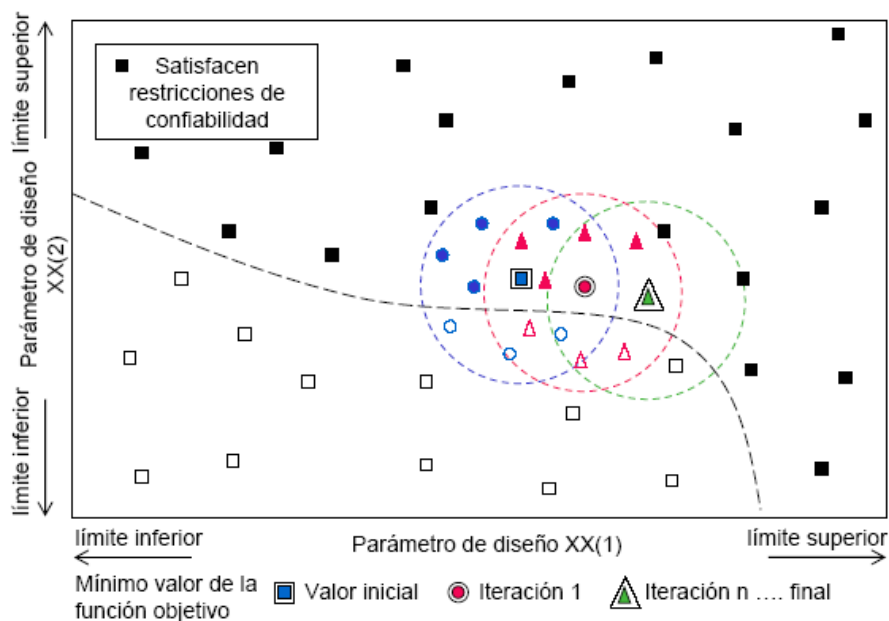


Figura 5: Proceso de optimización

5 APLICACIONES

5.1 Optimización de dimensiones de vigas y columnas

Este primer ejemplo trata de la optimización de las alturas de vigas h_v y columnas h_c , para el pórtico considerado y cuyos datos generales de las variables están dados en la tabla 2.

Los datos particulares se presentan en la tabla 3.

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
$X(10) = \rho_{s,tr}$	0.008	0.0008	Lognormal
$X(11) = \rho'_{s,ap}$	0.012	0.0012	Lognormal
$X(12) = \rho_s$	0.020	0.0020	Lognormal

Tabla 3: Datos de las variables para la aplicación 1

La función objetivo a minimizar es el valor medio del volumen del pórtico, de acuerdo a la siguiente expresión

$$\begin{aligned}
 Vol &= V_{vigas} + V_{columnas} \\
 F(X_i) &= [\bar{X}(1) \bar{X}(2) \bar{X}(3) \bar{X}(6) \bar{X}(7) 0.9 + \\
 &\quad + (150 + 270 \bar{X}(1)) (1 + \bar{X}(2)) \bar{X}(8) \bar{X}(9)] 10^{-6} m^3 \\
 F(d_k) &= [145800 \cdot \bar{X}(7) + 212400 \cdot \bar{X}(9)] 10^{-6} m^3
 \end{aligned} \tag{27}$$

La probabilidad de excedencia anual Pf_{anual} en cada nivel de desempeño se especifica en la tabla 4. Luego utilizando la ec.(26) se obtienen las probabilidades de falla si ocurre un evento sísmico Pf_E y los correspondientes índices de confiabilidad β_E .

Nivel de desempeño	Pf_{anual}	β_{anual}	Pf_E	β_E
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

Los resultados obtenidos, luego de aplicar el proceso de optimización descrito, se resumen en la tabla 5. Se realizaron 3 ciclos completos, observándose que los resultados son casi coincidentes tanto en los valores óptimos de los parámetros de diseño como en el volumen mínimo, eligiéndose los correspondientes al ciclo 3. En todos los casos los índices de confiabilidad están dentro del 3% de los valores objetivos.

Ciclo	h_v (cm)	h_c (cm)	Vol (m^3)	β_1	β_2	β_3
1	55.1	51.8	19.109	1.310	2.259	2.658
2	56.5	50.7	19.054	1.315	2.257	2.649
3	56.4	50.9	19.030	1.315	2.258	2.651

Tabla 5: Valores óptimos para la aplicación 1

5.2 Optimización de cuantías de armaduras longitudinales

Este segundo ejemplo trata de la optimización de las cuantías de armaduras longitudinales de vigas y columnas del pórtico considerado y cuyos datos generales de las variables están dadas en la tabla 2.

Los datos particulares se presentan en la tabla 6.

Variable	\bar{X}	σ_X	Tipo
$X(7) = h_v$	55 cm	2.75	Normal
$X(9) = h_c$	60 cm	3.00	Normal
$X(10) = \rho_{s,tr} = d_1$?	0.10 \bar{X}	Lognormal
$X(11) = \rho'_{s,ap} = d_2$?	0.10 \bar{X}	Lognormal
$X(12) = \rho_s = d_3$?	0.10 \bar{X}	Lognormal

Tabla 6: Datos de las variables para la aplicación 2

La función objetivo a minimizar es el peso de la armadura longitudinal del pórtico, de acuerdo a la siguiente expresión

$$\begin{aligned}
 P &= [V_{vigas} (\rho_{s,tr} + 0.6 \rho'_{s,ap}) + V_{columnas} \rho_s] 7.85 \cdot 10^{-5} \text{ KN} \\
 F(X_i) &= [\bar{X}(1) \bar{X}(2) \bar{X}(3) \bar{X}(6) \bar{X}(7) 0.9 (\bar{X}(10) + 0.6 \bar{X}(11)) + \\
 &\quad + (150 + 270 \bar{X}(1)) (1 + \bar{X}(2)) \bar{X}(8) \bar{X}(9) \bar{X}(12)] 10^{-6} 7.85 \cdot 10^{-5} \text{ KN} \\
 F(d_k) &= [8.019 (\bar{X}(10) + 0.6 \bar{X}(11)) + 12.744 \bar{X}(12)] 7.85 \cdot 10^{-5} \text{ KN}
 \end{aligned} \tag{28}$$

Se utilizan las mismas probabilidades de excedencia anual $P_{f_{anual}}$ en cada nivel de desempeño que para la aplicación 1, ver tabla 4.

En este caso los parámetros de diseño tienen restricciones entre ellos. Las cuantías de armadura deben proveer una resistencia adecuada para las cargas gravitacionales sobre las vigas de acuerdo con ec.(8), y además para garantizar una ductilidad mínima en las secciones de vigas se debe cumplir

$$\begin{aligned}
 0.5 \rho'_{s,ap} &\leq \rho_{s,tr} \leq 2 \rho'_{s,ap} \\
 0.5 \bar{X}(11) &\leq \bar{X}(10) \leq 2 \bar{X}(11)
 \end{aligned} \tag{29}$$

Los resultados obtenidos, luego de aplicar el proceso de optimización descrito, se resumen en la tabla 7. Se realizaron 3 ciclos completos, observándose que los resultados son

casi coincidentes tanto en los valores óptimos de los parámetros de diseño como en el peso mínimo, eligiéndose los correspondientes al ciclo 1. En todos los casos los índices de confiabilidad están dentro del 3% de los valores objetivos, y los parámetros de diseño cumplen con las restricciones establecidas entre ellos.

Ciclo	$\rho_{s,tr}$	$\rho'_{s,ap}$	ρ_s	P (KN)	β_1	β_2	β_3
1	0.005765	0.01132	0.01100	18.91	1.328	2.258	2.628
2	0.006630	0.01053	0.01098	19.13	1.323	2.256	2.636
3	0.006190	0.01079	0.01079	19.14	1.326	2.258	2.634

Tabla 7: Valores óptimos para la aplicación 2

5.3 Optimización de dimensiones de vigas y columnas, y de cuantías de armaduras

En este último ejemplo se optimizan las dimensiones de los elementos del pórtico y las armaduras, con el objetivo de obtener el costo mínimo.

Los datos generales están en la tabla 2, y los particulares para este ejemplo en la tabla 8

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 8: Datos de las variables para la aplicación 3

La función objetivo a minimizar es el costo directo del pórtico, considerando para el hormigón $CUH = 900 \text{ \$/m}^3$ y para el acero $CUA = 2.50 \text{ \$/Kg}$

$$C = [V_{vigas} + V_{columnas}] CUH + [P_{arm. vigas} + P_{arm. colum}] CUA$$

$$F(d_k) = [0.1458 \bar{X}(7) + 0.2124 \bar{X}(9)] CUH + \quad (30)$$

$$+ [0.1458 \bar{X}(7) (\bar{X}(10) + 0.6 \bar{X}(11)) + 0.2124 \bar{X}(9) \bar{X}(12)] 7850 CUA$$

Se utilizan las mismas probabilidades de excedencia anual $P_{f_{anual}}$ en cada nivel de desempeño que para la aplicación 1, ver tabla 4.

Las cuantías de armaduras de vigas tienen restricciones iguales a las consideradas para la aplicación 2, ver ecs.(8) y (29).

Los resultados obtenidos, luego de aplicar el proceso de optimización descripto, se resumen en la tabla 9. Se realizaron también 3 ciclos completos, observándose que los resultados son bastante similares tanto en los valores óptimos de los parámetros de diseño como en el costo mínimo, eligiéndose los correspondientes al ciclo 1. En todos los casos los

índices de confiabilidad están dentro del 3% de los valores objetivos, y los parámetros de diseño cumplen con las restricciones establecidas entre ellos.

Ciclo	h_v (cm)	h_c (cm)	$\rho_{s,tr}$	$\rho'_{s,ap}$	ρ_s	C (\$)	β_1	β_2	β_3
1	56.79	51.36	0.00614	0.00943	0.0188	23288	1.312	2.257	2.655
2	54.84	47.62	0.00733	0.01170	0.0264	23790	1.302	2.259	2.669
3	59.05	53.74	0.00924	0.01310	0.0165	24642	1.328	2.257	2.620

Tabla 9: Valores óptimos para la aplicación 3

6 CONCLUSIONES

- En el marco de la ingeniería sísmica basada en el desempeño, las incertidumbres presentes en demandas y capacidades hacen necesaria la evaluación de probabilidades de falla, o de excedencia anual, en varios niveles de desempeño, las que deben estar acotadas a valores admitidos.
- La evaluación de la confiabilidad bajo acciones sísmicas requiere la utilización de análisis dinámico no lineal. Luego la respuesta estructural no tiene forma explícita, y la evaluación es posible realizarla si se aproxima la función de respuesta. Para ello 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 con resultados determinísticos, utilizando análisis dinámico no lineal aplicando el método de los elementos finitos. Con estas bases de datos se entrenan redes neuronales para el valor medio y el desvío standard de cada parámetro de respuesta estructural, sobre un conjunto de acelerogramas.
- Luego el cálculo de la probabilidad de falla, para los distintos estados límites en cada nivel de desempeño, se realiza utilizando el método de simulación directa de Monte Carlo, con un pequeño costo computacional.
- 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 utiliza un algoritmo de búsqueda sin cálculo de gradiente, el cual ha mostrado un eficiente comportamiento para los ejemplos estudiados.
- Se presentan tres ejemplos de optimización de pórticos sismorresistentes bajo la acción sísmica de la ciudad de Mendoza, considerando varios niveles de desempeño y varios estados límites en cada nivel. Se definen los valores admitidos de índice de confiabilidad en cada nivel, y la función objetivo a minimizar en cada caso. Se muestra que el proceso es posible realizarlo de forma eficiente por el uso de redes neuronales como sustituto de la respuesta dinámica no lineal, y el algoritmo de optimización que evita el cálculo de gradientes.

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., 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.
- 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.
- 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.
- 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 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.