

Redes neuronales artificiales para representar la atenuación de la intensidad sísmica¹

**Artificial neural networks to represent the attenuation
of seismic intensity²**

**Redes neuronais artificiais para representar a atenuação
da intensidade sísmica³**

Eddy Herrera-Daza⁴

Alfonso Mariano Ramos-Cañón⁵

Julio Alberto García-Leal⁶

SICI: 0123-2126(201307)17:2<277:RNAAIS>2.0.TX;2-T

¹ Fecha de recepción: 28 de septiembre de 2012. Fecha de aceptación: 1 de abril de 2013. Este artículo se deriva del proyecto de investigación *Incorporación de la incertidumbre de datos históricos utilizando modelos bioinspirados en el estudio de la atenuación de la intensidad sísmica*, registro 004757, desarrollado por el Grupo de Investigación de Riesgos en Sistemas Naturales y Antrópicos, de la Pontificia Universidad Javeriana, Bogotá, Colombia, financiado por la Pontificia Universidad Javeriana y el Banco Santander S. A.

² Received: September 28, 2012. Accepted: April 1, 2013 This Article is a result of the research project entitled "*Incorporación de la incertidumbre de datos históricos utilizando modelos bioinspirados en el estudio de la atenuación de la intensidad sísmica*" (Incorporation of the uncertainty in historical data using bio-inspired models in the study of the attenuation of seismic intensity), registration 004757, developed by the Research Group of Risks in Natural Systems and Anthropoc of Pontificia Universidad Javeriana, Bogota, Colombia, funded by Pontificia Universidad Javeriana and Banco Santander S. A.

³ Data de recebimento: 28 de setembro de 2012. Data de aceitação: 1 de abril de 2013. Este artigo é derivado do projeto de pesquisa *Incorporação da incerteza de dados históricos utilizando modelos bioinspirados no estudo da atenuação da intensidade sísmica*, registro 004757, desenvolvido pelo *Grupo de Investigación Riesgos en Sistemas Naturales y Antrópicos* (Grupo de Pesquisa Riscos em Sistemas Naturais e Antrópicos) da Pontificia Universidade Javeriana, Bogotá, Colômbia, financiado pela Pontificia Universidade Javeriana e o Banco Santander S. A.

⁴ Licenciada en Matemáticas de la Universidad Distrital de Colombia. Estudiante de magíster en Estadística de la Universidad Nacional de Colombia. Estudiante del Doctorado en Ingeniería de la Pontificia Universidad Javeriana, Profesora del Departamento de Matemáticas de la Pontificia Universidad Javeriana Bogotá, Colombia. Correo electrónico: eherrera@javeriana.edu.co.

⁵ Ingeniero civil de la Pontificia Universidad Javeriana. Magíster en Geotecnia de la Universidad Nacional de Colombia. PhD en Ingeniería de la Universidad de los Andes. Profesor asociado del Instituto Geofísico de la Pontificia Universidad Javeriana, Bogotá Colombia. Correo electrónico: a-ramos@javeriana.edu.co.

⁶ Ingeniero de automatización de la Universidad de la Salle. Especialista en Telemática de la Universidad de los Andes. Estudiante de la Maestría en Hidrosistemas de la Pontificia Universidad Javeriana Bogotá, Colombia. Correo electrónico: julio-garcia@javeriana.edu.co.

Resumen

El estudio de atenuación de la intensidad sísmica desempeña un papel importante en los análisis de amenaza que incluyan eventos históricos. El mapeo de la atenuación de la intensidad generalmente se realiza por medio de regresiones de la intensidad en función de la distancia. Hoy existen distintas formas para estudiar las características de un evento sísmico por medios instrumentales; sin embargo, los expertos enfrentan el problema del carácter cualitativo de las fuentes de información y el mapeo de la relación entre intensidad, magnitud y distancia para la generación de escenarios de riesgo con base en información histórica. Este trabajo presenta la alternativa de mapear dicha relación por medio de las redes neuronales artificiales (RNA). Como resultado, se propone un procedimiento que fue validado por medio del mapeo de las intensidades de 68 sismos ocurridos en el norte de Suramérica, entre 1766 y 2004. Se encontró que las RNA presentan ventajas respecto a los modelos convencionales de regresión: a. preservan de mejor manera el primer momento estadístico, b. reflejan un error de aproximación menor y c. la varianza explicada por las RNA se comporta mejor que los modelos de regresión estadística.

Palabras clave

Intensidad sísmica, redes neuronales artificiales, atenuación sísmica.

Abstract

The study of seismic intensity attenuation plays an important role in the analysis of menace that includes historical events. Mapping the intensity attenuation is usually done by regressing the intensity versus distance. Nowadays there are different ways to examine the characteristics of a seismic event using instrumental means, however, the experts face the problem of qualitative nature of the sources of information and the mapping of the relationship between intensity, magnitude and distance for the generation of risk scenarios based on historical information. This paper presents an alternative to map this relationship through artificial neural networks (ANN). As a result, we propose a procedure that was validated through the mapping of the intensities of 68 earthquakes that occurred northern South America, between 1766 and 2004. We found that ANNs present advantages with respect to the conventional models of regression: a. they preserve in a better way the first statistical moment, b. they reflect a minor approximation error and c. the variance explained by the ANN is better than the one from the models of statistical regression.

Keywords

Seismic intensity, artificial neural networks, seismic attenuation.

Resumo

O estudo de atenuação da intensidade sísmica desempenha papel importante na análise de ameaças que incluem eventos históricos. O mapeamento da atenuação da intensidade geralmente realiza-se por meio de regressões da intensidade em função da distância. Hoje existem diferentes formas para estudar as características de um evento sísmico por meios instrumentais; contudo, os peritos enfrentam o problema do caráter qualitativo das fontes de informação e o mapeamento do relacionamento entre intensidade, magnitude e distância para a geração de cenários de risco com base na informação histórica. Este trabalho apresenta uma alternativa para fazer mapeamento de tal relação por meio das redes neuronais artificiais (RNA). Como resultado, propõe-se procedimento avaliado por meio do mapeamento das intensidades de sessenta e oito sismos acontecidos no norte de Sul-américa, entre 1766 e 2004. Encontrou-se que as RNA demonstraram vantagens no que diz respeito dos modelos convencionais de regressão: a. Melhor preservação do primeiro momento estatístico, b. Refletem um menor erro de aproximação e c. A variância explicada pelas RNA tem melhor desempenho do que os modelos de regressão estatística.

Palavras-chave

Intensidade sísmica, redes neuronais artificiais, atenuação sísmica.

1. Introducción

Las redes neuronales artificiales (RNA) constituyen una herramienta útil que ha sido aplicada a diversos campos del conocimiento. Existen diferentes ejemplos de la aplicación de las RNA en ingeniería y en geociencias particularmente para mapear relaciones altamente no lineales (Penumadu y Zhao, 1999; Chang y Whan, 2002). Precisamente, el propósito de las RNA es proporcionar una parametrización cuando se tiene un mapeo no lineal entre entradas y salidas (Bishop, 1995), como el que se da en ingeniería sísmica entre la atenuación de la energía liberada en un terremoto con la distancia al foco o al epicentro. Para mapear dicha atenuación, típicamente se han desarrollado ecuaciones a partir del análisis estadístico multivariado de parámetros representativos de la energía (aceleración, velocidad, intensidad) con la distancia. Como ejemplo de este tipo de aproximación, Prieto *et al.* (2011a) desarrolló ecuaciones de atenuación de la intensidad en función del radio equivalente para una base de datos de intensidades macrosísmicas recopilada del norte de Suramérica.

Autores como Günaydin y Günaydin (2008), Arjun y Kumar (2009) y Derras y Beckkouche (2011) han usado herramientas alternativas basadas en la inteligencia artificial, como las RNA, para mapear la disminución de la aceleración pico del suelo con la distancia.

Siguiendo esta misma línea de trabajo, en el presente artículo se propone un procedimiento alternativo de tratamiento de la base de datos de intensidades macrosísmicas generada por Prieto *et al.* (2011 b, c). En el conocimiento de los autores, no se tiene registro en la literatura del uso de redes neuronales para el mapeo de la atenuación de la intensidad macrosísmica. Por lo anterior, el objetivo de este trabajo es presentar la mejor RNA que sea capaz de mapear el comportamiento de la atenuación de intensidad sísmica con la distancia, usando la base de datos de información sísmica originalmente generada por Prieto *et al.* (2011 b, c) para el norte de Suramérica.

El contenido del artículo es el siguiente: en la sección 2 se presentan los aspectos generales de la atenuación sísmica; en la sección 3 se muestran los elementos

matemáticos relacionados con una RNA; la sección 4 presenta la descripción de la base de datos de intensidades usadas en el presente trabajo; en la sección 5 se presentan los modelos de análisis de variables de entrada y de salida que fueron mapeadas a través de las redes neuronales; la sección 6 muestra los resultados obtenidos; finalmente, la sección 7 expone la comparación de las RNA con los modelos convencionales de atenuación de la intensidad y se recalcan algunas de las principales conclusiones obtenidas en el trabajo.

2. Atenuación sísmica

Aunque hoy en día existen distintas formas para estudiar las características de un evento sísmico por medios instrumentales, la intensidad sigue siendo un parámetro significativo, especialmente para los sismos históricos. Dado que la intensidad es una medida no instrumental, existen diversas fuentes de incertidumbre en los modelos relacionados con ella. Por lo anterior, en la literatura científica se encuentran varios esfuerzos para mejorar los modelos de atenuación de la intensidad (Sauter, 1989).

Se han desarrollado diferentes estudios de atenuación de la intensidad sísmica en diferentes regiones del mundo: en el noroccidente de Europa (Ambraseys, 1985), la zona de Cascadia (Bakun *et al.*, 2002), India (Ambraseys y Douglas, 2004) e Italia (Gasperini, 2001; Pasolini *et al.*, 2008). En estos casos, el mapeo de la atenuación de la intensidad se realiza a través de regresiones estadísticas de la intensidad o de niveles de diferencia de intensidad en función de la distancia.

Para Colombia y el norte de Suramérica, Gómez y Salcedo (2002) y Prieto *et al.* (2011a) han propuesto ecuaciones de atenuación de la intensidad macrosísmica. Este tipo de ecuaciones son de suma importancia para la construcción de infraestructura civil en países con un régimen sísmico alto y poca información instrumental, debido a que este es un medio para asignar daño a infraestructura por las sollicitaciones de las fuentes de los terremotos. Adicionalmente, el estudio de la atenuación de la intensidad es importante en la evaluación probabilística de la amenaza sísmica, por lo cual se resalta la necesidad de encontrar formas alternativas que mapeen mejor dicha relación.

2.1. Modelo convencional de atenuación de la intensidad sísmica

Existen distintas maneras de representar la atenuación de la intensidad de un evento sísmico, dichos modelos relacionan la intensidad (I) y/o la diferencia de intensidad ($I - I_0$) en función de la magnitud (M), y la distancia (R) con modelos matemáticos y estadísticos de regresión que consideran como variable continua

la intensidad. En rigor, la intensidad es una variable aleatoria discreta. Prieto *et al.* (2011b) presentan una forma alternativa de tratamiento de la intensidad y la distancia con una función de distribución de probabilidad conjunta discreta-continua. Sin embargo, el modelo matemático más utilizado para mapear la relación entre I , R e I_0 (Muñoz, 1989; Prieto *et al.*, 2011a) es:

$$I - I_0 = a - bR - c \ln R \quad (1)$$

Otros autores presentan un enfoque incluyendo directamente la magnitud en la ecuación de atenuación (Chavez y Castro, 1988; Bakun *et al.*, 2002; Musson, 2005):

$$I = b_0 + b_1 M - b_2 \ln R + e \quad (2)$$

Generalmente, a los parámetros de las ecuaciones 1 y 2 se les trata de dar una explicación física relacionándolas con las condiciones de frontera, la atenuación inelástica y la atenuación geométrica. La ecuación 2 es una representación de carácter multivariado de la atenuación de la intensidad, que corresponde a:

$$Y = b_0 + b_1 X_1 + b_2 X_2 + e \quad (3)$$

Donde e es el vector de errores, el cual se supone que generalmente tiene un comportamiento aleatorio, con media cero, varianza constante σ^2 y distribución normal. Los coeficientes de este modelo tienen su análogo en el modelo de redes neuronales con el vector de pesos W (Bishop, 1995).

Adicionalmente, se tiene que la métrica de desempeño para el modelo de regresión es la desviación estándar σ tipo 1 definida como:

$$\sigma = \left(\frac{\sum (error^2)}{n-1} \right)^{1/2} \quad (4)$$

Donde n es el número de observaciones y $error$ es la diferencia entre los puntos observados y los estimados por el modelo. Los modelos de regresión estadística que se utilizarán en el presente trabajo como línea base de comparación con los modelos de las RNA son aquellos propuestos por Prieto *et al.* (2011a) y Villacis *et al.* (1994), que están relacionados con dos tipos de eventos llamados de

subducción y eventos superficiales, los cuales se presentan a continuación. De Prieto *et al.* (2011^a):

$$I - I_o = 2,0971 - 0,0012708R - 2,1778 \log_{10} R; s = 1,29 \text{ Sismos superficiales} \quad (5)$$

$$I - I_o = 2,7188 - 0,0094801R - 1,7026 \log_{10} R; s = 0,67 \text{ Sismos de subducción} \quad (6)$$

De Villacis *et al.* (1994):

$$I = 1,55M - 3,72 \log_{10} R + 1,97; \sigma = 1,39 \text{ Sismos superficiales} \quad (7)$$

$$I = 1,70M - 4,82 \log_{10} R + 3,97; \sigma = 1,64 \text{ Sismos de subducción} \quad (8)$$

La base de datos que usó Prieto *et al.* (2011a) es la misma que se usó para el desarrollo de este trabajo.

3. El modelo de una red neuronal (RNA)

Según Haykin (1994), una *red neuronal* es un procesador masivamente paralelo distribuido que tiene una facilidad natural para el almacenamiento de los conocimientos adquiridos de la experiencia, el cual es similar al cerebro en dos aspectos: el conocimiento obtenido por la red a través de un proceso de aprendizaje y las conexiones entre las neuronas conocidas como pesos sinápticos que sirven para almacenar conocimiento.

Una RNA está formada por unos nodos de entrada $\mathbf{X} = (x_1, \dots, x_N)$ y unos nodos de salida $\mathbf{Y} = (y_1, \dots, y_c)$ que representan el estimador y la estimación, respectivamente. En el medio de estas entradas y salidas se encuentran los nodos ocultos dispuestos en capas. El número de nodos ocultos y capas generalmente se determinan de manera empírica con el objetivo de optimizar el rendimiento de la red. Cada conexión entre los nodos en una capa en particular con la capa superior se puede representar a través de un peso dado por w_{ij} , que indica la importancia de la conexión entre los nodos i -ésimo y j -ésimo.

Para cada nodo en una capa particular, los valores de entrada de nodo de la capa anterior se multiplican por el peso de las conexiones entre los nodos, y a continuación, todas las conexiones diferentes se suman para producir el valor en el nodo. Las salidas del nodo j y_j se obtienen calculando el valor de la función f de activación, la cual representa la respuesta de un nodo a la señal total que recibe respecto al producto interior del vector \mathbf{X} y el vector \mathbf{W}_j de pesos, menos

el valor umbral b_j . Lo anterior se puede describir mediante la siguiente expresión $y_j = f(\mathbf{X} \cdot \mathbf{W}_j - b_j)$.

En nuestra aplicación se utilizaron tres algoritmos para el entrenamiento: *gradiente conjugado*, *Back-Propagation* y *Levenberg-Marquardt*, que se basan en el principio de obtener el mínimo error posible $E(\mathbf{W})$. En forma general, para que la RNA genere un vector de salida $\mathbf{Y} = (y_1, \dots, y_c)$ que sea lo más cercano posible al vector objetivo $\mathbf{T} = (t_1, \dots, t_c)$, el cual comúnmente se denomina *target*, se debe determinar la matriz de pesos óptima \mathbf{W}^* en la fase de entrenamiento, con una medida objetivo de desempeño dada por la función de error:

$$E(\mathbf{W}) = \frac{1}{N} \sum_{n=1}^{n=N} \frac{1}{2} \sum_{k=1}^{k=c} \{y_k(x^n; \mathbf{W}) - t_k^n\}^2 \quad (9)$$

Donde t_k es una componente de la salida deseada \mathbf{T} , y_k corresponde a la salida de RNA, c es el número de nodos de salida y N es el número de patrones de entrenamiento.

4. Área de estudio y datos de trabajo

El norte de Suramérica se caracteriza, tectónicamente hablando, por la compleja interacción de las placas de Nazca, Suramericana y Caribe. Esta interacción hace que sea una zona altamente propensa a la generación de sismos. El mapa del área de estudio y el epicentro de 68 sismos ocurridos en el norte de Suramérica en el periodo comprendido entre 1766 y 2004 se encuentra disponible en el suplemento electrónico de la publicación realizada por Prieto *et al.* (2011b).

De la base de datos generada por Prieto *et al.* (2011b) se tomaron dos subgrupos de datos. Un subgrupo está compuesto por los sismos corticales superficiales con profundidad estimada menor a 40 kilómetros en Colombia y en el occidente de Venezuela. El otro subgrupo comprende sismos de subducción en la región del océano Pacífico asociados con la interacción entre las placas de Nazca y la Suramericana en Colombia. Los mapas de isosistas reportados en Prieto *et al.* (2011b) provienen de sismos desde 1766 a 2004. Los epicentros de los eventos son de Colombia, el occidente de Venezuela, la costa Pacífica de Ecuador y Perú. La gran mayoría de los mapas recolectados en dicho estudio fueron originalmente dibujados en la escala de Mercalli modificada (MMI). Alrededor del 13% de los datos originales fueron representados en otras escalas, como R-F (Rossi-Forel), MCS (Mercalli-Cancani-Sieberg), MSK (Medvedev, Sponheuer, Karnik) y EMS-92 (Escala Macrosísmica Europea). En Prieto *et al.* (2011b) homologan

las isosistas a la de Mercalli modificada; también, reportan 296 isosistas con su respectivo radio equivalente.

Teniendo en cuenta las relaciones funcionales entre magnitud (M), distancia (R), intensidad (I), intensidad epicentral (I_0) y diferencia de intensidad ($I-I_0$), se plantean tres modelos a través de RNA (tabla 1).

Tabla 1. Variables de entrada y salida de los modelos

Modelos	Variables de entrada		Variables de salida	
I	Magnitud (M)	Intensidad (I)	Distancia (R)	Intensidad epicentral (I_0)
II	Magnitud (M)	Distancia (R)	Intensidad (I)	
III	Magnitud (M)		Intensidad epicentral (I_0)	

Fuente: presentación propia de los autores.

Los modelos I y II representan la atenuación de la energía sísmica con la distancia. Un evento sísmico genera una magnitud y diferentes valores de intensidades que van disminuyendo con la distancia (atenuación). El mayor valor de la intensidad se presenta en el epicentro. En la superficie, la magnitud se ve reflejada en la intensidad epicentral I_0 . El modelo III representa la relación entre la energía liberada en el foco y la parte de dicha energía que se observa en la superficie (intensidad epicentral I_0). Dentro del subgrupo de sismos superficiales se tienen 60 eventos y 222 datos de entrada asociados con igual número de isosistas y radios equivalentes. En el subgrupo de los sismos de subducción se tienen 8 eventos y 30 datos de entrada.

5. Resultados

5.1. Topología de la red

Para enfrentar el problema de representación de la intensidad sísmica se utilizó un criterio heurístico basado en la intuición y la experimentación para seleccionar la mejor topología de la RNA (Sietsma y Dow, 1991; Tabares y Hernández, 2008). El diseño corresponde a una arquitectura con una o dos neuronas de entrada (magnitud y/o intensidad y/o distancia), y una o dos neuronas de salida (distancia y/o intensidad epicentral, intensidad). Ambas entradas y salidas corresponden a los modelos I, II y III. El número de capas ocultas varía en cada modelo. El número de neuronas en estas capas fue elegido por el modelador de forma heurística, debido a que no existe una regla o método que determine

el número de neuronas para un problema de RNA (León y Galván, 2003). En todas las pruebas de validación realizadas, los pesos se inicializarán aleatoriamente una sola vez. Se utilizaron los algoritmos de entrenamiento referenciados con un máximo de 57 iteraciones y un error final en la aproximación de 0,03.

En la tabla 2 se presentan los resultados obtenidos de la selección de las RNA para los tres modelos en términos del grado de correlación R . Particularmente, en la etapa de validación se buscó el modelo que no presentó grandes diferencias en el error, tanto en la etapa de formación como en la etapa de validación, que haría pensar que los datos en la validación corresponden a otra población (Masters, 1993). Analizando los aspectos anteriormente mencionados, el modelo de RNA seleccionado corresponde con el algoritmo Levenberg-Marquardt (Kipli, 2012; Lourakis, 2005).

Tabla 2. Resultados del modelo I-III

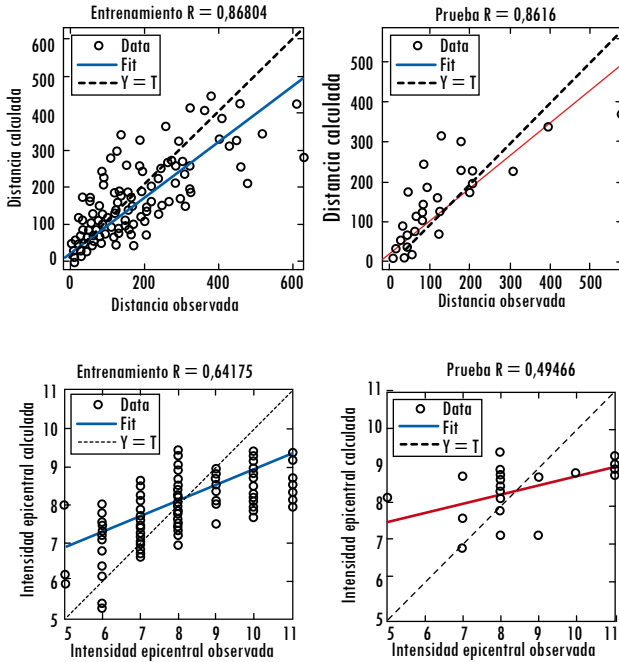
Modelo	Modelo I		Modelo II		Modelo III	
Capas	Superficial (2) Subducción (2)		Superficial (2) Subducción (2)		Superficial (4) Subducción (2)	
Eventos	R: Entreno	R: Prueba	R: Entreno	R: Prueba	R: Entreno	R: Prueba
Superficial	0,869	0,862	0,772	0,758	0,668	0,770
Subducción	0,912	0,993	0,897	0,964	0,965	0,973

Fuente: presentación propia de los autores.

A manera de ilustración de la capacidad de representación de las RNA, se presentan solo los resultados del modelo I. En la figura 1 se ilustra el grado de correlación R entre los datos observados y los calculados en el entrenamiento y la prueba con las RNA.

Se observa que el grado de correlación R es mayor para los eventos de subducción que para los sismos superficiales. Esto se puede deber a dos aspectos: 1. la base de datos tiene menor cantidad de datos para los sismos de subducción, por lo cual la RNA se ajusta más fácilmente; 2. los eventos asignados a subducción se catalogan más fácilmente por su ubicación geográfica. La categoría de sismos superficiales puede ser ambigua, y dado el carácter histórico de los sismos de la base de datos, tiene una variabilidad intrínseca que se ve reflejada en una dispersión mayor.

Figura 1. Modelo I



Fuente: presentación propia de los autores.

5.2. Validación del modelo de redes neuronales


Utilizando los resultados de la RNA en cada modelo (I, II y III), se representó la relación de atenuación para los sismos superficiales y de subducción. Esta aproximación se contrastó con los modelos de regresión estadística presentados por Prieto *et al.* (2011a) y por Villacis *et al.* (1994) dados en las ecuaciones (5), (6), (7) y (8).

El comportamiento de la atenuación de la intensidad para las ecuaciones de regresión y los resultados del modelo de RNA se pueden observar en la figura 2 para dos magnitudes. Adicionalmente, se presentan los puntos observados de la base de datos con fines indicativos.

Una de las ventajas que presenta la atenuación de la intensidad con RNA es que las curvas de atenuación no son paralelas entre sí para diferentes magnitudes. Esta característica de representación de las RNA permite observar procesos emergentes de la propagación de ondas por medios heterogéneos (la corteza terrestre y el subsuelo superficial). Es bien conocido que la tasa de atenuación de la energía sísmica no es la misma para diferentes tamaños de fuentes, por

lo que el uso de un método alternativo que permita capturar particularidades en la propagación de la energía sobrepasa el alcance de las ecuaciones de atenuación convencionales. A manera de ejemplo, se observa en la figura 2 (c y d) que para distancias bajas la atenuación tiene un comportamiento de disminución proporcional para las dos magnitudes; sin embargo, para distancias mayores se observa mayor atenuación para los sismos de mayor magnitud. Este comportamiento se evidencia en los datos observados y son convenientemente reflejados en la curva de atenuación.

Figura 2. Comparación de la atenuación de la intensidad con la ecuación de atenuación y con el modelo de RNA. (a) Diferencia de intensidad ($I - I_0$), RNA para modelo I y ecuación 5 para sismos superficiales. (b) Diferencia de intensidad ($I - I_0$), RNA para modelo I y ecuación 6 para sismos de subducción. (c) Intensidad, RNA para modelo II y ecuación 7. (d) Intensidad, RNA para modelo II y ecuación 8



Fuente: presentación propia de los autores.

Con el objeto de comparar el desempeño de las ecuaciones convencionales de atenuación (ecuaciones 5, 6, 7 y 8) con las generadas a través de RNA en este trabajo, se procedió a calcular la desviación estándar y la raíz de los errores cuadráticos medios (RECM) de la base de datos (tabla 3). La desviación estándar da cuenta de la dispersión de los datos respecto al valor medio, y el RECM

representa la dispersión de los datos respecto al modelo (ecuación de regresión o RNA) que pretende mapear los datos observados.

Tabla 3. Resultados de comparación modelos

Superficial	Estadístico	Observado $I-I_o$	Ecuación 5	RNA Modelo I
	Desviación estándar	1,91	1,52	1,32
	RECM		19,16	14,53
Subducción	Estadístico	Observado $I-I_o$	Ecuación 6	RNA Modelo I
	Desviación estándar	1,25	1,44	1,15
	RECM		2,96	1,89
Superficial	Estadístico	Observado I	Ecuación 7	RNA Modelo II
	Desviación estándar	1,92	1,76	1,37
	RECM		20,23	13,40
Subducción	Estadístico	Observado I	Ecuación 8	RNA Modelo II
	Desviación estándar	1,52	1,85	1,45
	RECM		7,30	1,98

Fuente: presentación propia de los autores.

Se observa que el RECM es menor en todos los casos para las RNA al compararla con las ecuaciones de regresión, por lo que se puede concluir que las RNA son capaces de representar de mejor manera la atenuación de la intensidad. En la tabla 4 se muestran los pesos de la segunda capa.

Tabla 4. Tabla de pesos de la red neuronal, modelos I, II y III

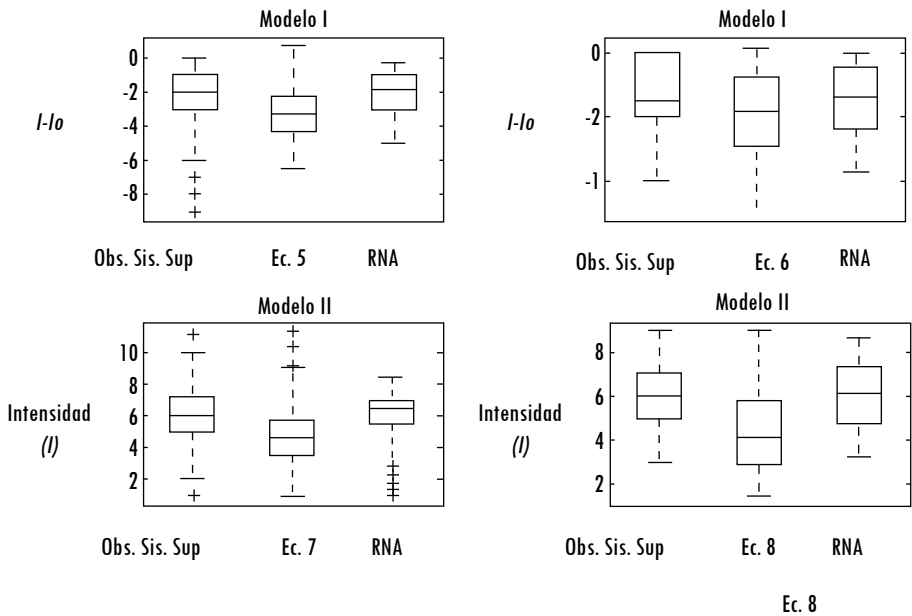
Modelo	Superficial - Subducción			
	Distancia	I_o	Distancia	I_o
I	[-.54; .59; .57 .95; -.24; .27; -.91; -.54; .75; -.08]	[.37; .59; .06; .51; .01; .81; -.75; .7; .65; .53]	[.98; .22; -.50; .04; 0.43; -0.48; -.77; .01; -.56; -.38]	[.75; -.03; -.19; -.75 .85; -.99; -.63; -.35; -.9; -.71]
II	I [-.74; .60; -.39; -.31; .32; -0.922; .54; .38; .85; -0.88]		I [.73; .72; .10; -.09; .7; -.30; -.52; -.90; -.73; .16]	
III	I_o [.74; -.61; .65; .16; -.28; .86; -.79; -.25; -.11; .53]	I_o [-.41; -.59; -.17; .81; -.21; -.03; -.29; .51; -.4; -.10]	I_o [.47; -.37; .15; .5; -.29; -.10; -.93; .46; .24; -.75]	

Fuente: presentación propia de los autores.

Adicionalmente, en referencia a la dispersión expresada a través de la desviación estándar, esta siempre fue menor en las RNA en comparación con los modelos de regresión. Lo que significa que la varianza explicada por las RNA es más cercana a uno en comparación con el modelo de regresión. La varianza explicada se entiende como la diferencia que hay entre la varianza observada y la varianza del modelo, dividida entre la varianza del observado.

En cuanto a la estructura de dispersión de los datos observados y la que se refleja con los modelos correspondientes a las ecuaciones de regresión (ecuaciones 5, 6, 7 y 8), en contraste con los modelos de RNA, los resultados se observan en el diagrama de caja de la figura 3.

Figura 3. Diagrama de caja de los datos observados, de las ecuaciones y de las RNA




Fuente: presentación propia de los autores.

En la figura 3 se observa que la dispersión medida en términos del rango intercuartil es mayor en los modelos de regresión, particular para el 25% más alto de la población, indicando una sensibilidad de los parámetros de los modelos de regresión a valores extremos. Este comportamiento es contrario a lo que se observa en las RNA. Para el caso del 25% más bajo de la población de estudio, las RNA tratan de conservar la dispersión que presenta la muestra de datos. Finalmente, el mapeo que se obtiene a través de los modelos de regresión estadística muestra siempre un desplazamiento hacia valores inferiores, mientras

que las RNA conservan un porcentaje similar de densidad alrededor del centro de masa respecto a los observados.

En la figura 4 se observa un ejemplo aplicativo de las isosistas originales realizadas por Briceño (2004) sobre el sismo del Quindío en 1999, y los radios equivalentes de estos. El primero, en relación con la información suministrada en la base de datos de Prieto *et al.* (2011 b, c) y el segundo, con la RNA del modelo I.

Figura 4. (a) Isosista original. (b) Radio equivalente de isosista en la base de datos de Prieto *et al.* (c) Radio equivalente de isosistas con RNA del sismo del Quindío del 25 de enero de 1999



Fuente: Briceño, (2004) (izquierda), Prieto *et al.* (2011a) (central) y elaboración propia (derecha).

6. Conclusiones

Es preponderante tener en cuenta que las RNA, como cualquier otro método dirigido por los datos, depende de la cantidad y calidad de datos disponibles para su calibración. Dado lo anterior, aunque son interesantes los resultados absolutos mostrados en términos de atenuación de la intensidad con la distancia, se considera más importante el hecho de exaltar que las RNA son una forma alternativa de representar la relación de los datos de intensidad sísmica con fines de atenuación.

Las RNA son capaces de representar de una mejor manera la atenuación de la intensidad. Esto se evidencia en tres métricas: a. los coeficientes de correlación tanto en el entrenamiento de la red como en la prueba de las RNA (test) estuvieron entre 0,97 y 0,9 (exceptuando el modelo II). b. Se observa que los modelos de RNA muestran un mejor ajuste entre los datos observados (objetivo) y los datos obtenidos por los modelos de RNA. c. Se observa que el RECM es menor en todos los casos para las RNA al compararla con las ecuaciones de regresión.

Las RNA representan mejor la estructura de la dispersión de los datos observados en comparación con las ecuaciones de atenuación convencionales. La estructura de la dispersión de los datos observados representados por el rango intercuartil y sus magnitudes se asemejan más a las generadas por las RNA que la que se observa en las ecuaciones convencionales de atenuación de intensidad.

Referencias

- AMBRASEYS, N. Intensity-Attenuation and Magnitude-Intensity Relationships for Northwest European Earthquakes. *Earthquake Engineering and Structural Dynamics*. 1985, vol. 13, núm. 6, pp. 733-778.
- AMBRASEYS, N. y DOUGLAS, J. Magnitude Calibration of North Indian Earthquakes. *Geophysical Journal International*. 2004, vol. 159, núm. 1, pp. 165-206.
- ARJUN, C. y KUMAR, A. Artificial Neural Network-Based Estimation of Peak Ground Acceleration. *ISET Journal of Earthquake Technology*. 2009, paper núm. 501, vol. 46, núm. 1, pp. 19-28.
- BAKUN, W.; HAUGERUD, R.; HOPPER, M. y LUDWIN, R. The December 1872 Washington State Earthquake. *Bulletin of the Seismological Society of America*. 2002, vol. 92, núm. 8, pp. 3239-325.
- BISHOP, C. *Neural Networks for Pattern Recognition*. Oxford: Oxford University Press, 1995.
- BRICEÑO, L. A. Isosistas del sismo del Quindío (25/01/1999). 2004, Comunicación personal.
- CHANG, L. y WHAN, H. Neural Network Based Models for Generating Artificial Earthquakes and Response Spectra. *Computers & Structures*. 2002, vol. 80, núm. 20-21, pp. 1627-1638.
- CHÁVEZ, M. y CASTRO, R. Attenuation of Modified Mercalli Intensity with Distance in Mexico. *Bulletin of the Seismological Society of America*. 1988, vol. 78, núm. 6, pp. 1875-1884.
- DERRAS, B. y BECKKOCHE, A. Use of the Artificial Neural Networks for Peak Ground Acceleration Estimation. *Lebanese Science Journal*. 2011, vol.12, núm 2, pp. 101-115.
- GASPERINI, P. The Attenuation of Seismic Intensity in Italy: A Bilinear Shape Indicates the Dominance of Deep Phases at Epicentral Distances Longer than 45 km. *Bulletin of the Seismological Society of America*. 2001, vol. 91, pp. 826-841.
- GÓMEZ, A. y SALCEDO, E. *Leyes de Atenuación de la Intensidad Macrosísmica en Colombia*. Primer Simposio Colombiano de Sismología: Avances de la Sismología Colombiana en los últimos 20 Años. Ingeominas. Bogotá. Octubre 2002.
- GÜNAYDIN, K. y GÜNAYDIN, A. Peak Ground Acceleration Prediction by Artificial Neural Networks for Northwestern Turkey. *Mathematical Problems in Engineering*. 2008, ID 919420, pp. 1- 20.
- HAYKIN, S. *Neural Network a Comprehensive Foundation*. México: Prentice-Hall, 1994.
- KIPLI, K.; MUHAMMAD, M.; MASNIAH, SH.; ZAMHARI, N.; LIAS, K. y AWANG, A. Performance of Levenberg - Marquardt Backpropagation for Full Reference Hybrid Image

- Quality Metrics. *Processing of the International MultiConference of Engineers and Computer Scientist*. 2012, vol.1, pp. 1-4.
- LEÓN, P. y GALVAN, I. *Redes de Neuronas Artificiales, un Enfoque Práctico*. Madrid: Pearson, Prentice Hall, 2003.
- LOURAKIS, M. Brief Description of the Levenberg-Marquardt Algorithm Implemented by Levmar. *Foundation of Research and Technology*. 2005, vol. 4, pp. 1-6.
- MASTERS, T. *Practical Neural Network Recipes in C++*. San Diego, CA.: Academic Press, 1993.
- MUÑOZ, D. *Conceptos Básicos en Riesgo Sísmico. Física de la tierra*. 1989, núm. 1, pp.199-215.
- MUSSON, R. Intensity Attenuation in the U.K. *Journal of Seismology*. 2005, vol. 9, pp. 73-86.
- PASOLINI, C.; GASPERINI, P.; ALBARELLO, D.; LOLLI, D. y D'ARMICO, V. The Attenuation of Seismic Intensity in Italy, Part I: Theoretical and Empirical Background. *Bulletin Seismological Society of America*. 2008, vol. 98, núm. 2, pp. 682-691.
- PENUMADU, D. y ZHAO, R. Triaxial Compression Behavior of Sand and Gravel Using ANN. *International Journal of Computers and Geotechnics*. 1999, vol. 24, núm. 3, pp. 207-230.
- PRIETO, J.; FOSCHI, R.; VENTURA, C.; LIAM, W.; RAMOS, A. y PRADA-SARMIENTO, F. Atenuación y Distribución de Probabilidad de Intensidades Sísmicas para Colombia y el Occidente de Venezuela. *Revista internacional de Desastres Naturales, Accidentes e Infraestructura Civil*. 2011a. vol. 11, núm. 2, pp.183-196.
- PRIETO, J.; FOSCHI, R.; VENTURA, C.; LIAM, W.; RAMOS, A. y PRADA-SARMIENTO, F. Probability Distribution of Intensity Attenuations for Colombia and Western Venezuela. *Bulletin of the Seismological Society of America*. 2011b. vol. 101, núm. 2, pp. 405-505.
- PRIETO, J.; VENTURA, C.; LIAM, W.; RAMOS, A. y PRADA-SARMIENTO, F. Base de Datos de Intensidades Sísmicas para Colombia y el Occidente de Venezuela. *Revista Internacional de Desastres Naturales, Accidentes e Infraestructura*. 2011c. vol. 11, núm. 2, pp. 163-182.
- SAUTER, F. *Fundamentos de Ingeniería Sísmica: Introducción a la Sismología (I)*. Cartago, CR: Editorial Tecnológica de Costa Rica, 1989, 1ª ed, 271p.
- SIETSMA, J. y DOW, R. Creating Artificial Neural Networks that Generalize. *Neural Network*. 1991, vol. 4, núm. 1, pp. 67-79.
- TABARES, H. y HERNÁNDEZ, J. Mapeo Curvas Típicas Demanda de Energía Eléctrica del Sector Residencial, Comercial e Industrial de la Ciudad de Medellín, Usando Redes Neuronales Artificiales y Algoritmos de Interpolación. *Revista Facultad de Ingeniería Universidad de Antioquia*. 2008, núm 46, pp. 110-118.
- VILLACIS, C.; YAMADA, T y KANECO, F. *Attenuation Relations for Ecuador, Appendix II, in the Quito, Ecuador, Earthquake Risk Management Project*. Escuela Politécnica Nacional. Geohazards Interntaional Orstom-Quito and Oyo Corporation. 1994, pp. 162-181.