

Atenuación de la intensidad a través de un algoritmo bioinspirado.

Intensity attenuation through a bioinspired algorithm

Alfonso Mariano Ramos Cañón*
Eddy Herrera Daza**
Julio Alberto García Leal***

Resumen

El estudio de atenuación de la intensidad sísmica juega un papel importante en los análisis de amenaza que incluyan eventos históricos. El mapeo de la atenuación de la intensidad generalmente se realiza a través de regresiones de la intensidad en función de la distancia. Este trabajo presenta una forma alternativa de mapear esta relación través del uso de las Redes Neuronales Artificiales RNAs. Como resultado se propone un procedimiento novedoso que fue validado a través del mapeo de las intensidades para el caso de 68 sismos ocurridos en la parte norte de Suramérica en el periodo comprendido entre 1766 a 2004. Se encuentra que las RNAs presentan varias ventajas con 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 RNAs 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 threat involving historical events. Mapping the intensity attenuation is usually done through regressions of intensity versus distance. This paper presents an alternative way to map this relationship through the use of Artificial Neural Networks RNAs. As a result we propose a novel method was validated by mapping of the intensities for the case of 68 earthquakes occurred in the northern part of South America in the period 1766-2004. RNAs are found to have several advantages over conventional regression models: a. Best preserved of the first statistical moment, b. Reflect a lower approximation error and c. The variance explained by the RNAs performs better than statistical regression models.

Keywords: Seismic intensity, artificial neural networks, seismic attenuation

* Profesor Asociado. Instituto Geofísico, Pontificia Universidad Javeriana, Bogotá, Colombia. a-ramos@javeriana.edu.co.

** Profesora Departamento de Matemáticas, Pontificia Universidad Javeriana. Bogotá, Colombia. eherrera@javeriana.edu.co

*** MSc Hidrosistemas, Pontificia Universidad Javeriana, Bogotá, Colombia. julio-garcia@javeriana.edu.co

I. INTRODUCCIÓN

El presente trabajo es un resumen del artículo publicado por [1]. Las redes neuronales artificiales (RNAs) constituyen una herramienta útil que ha sido aplicada a diversos campos del conocimiento. Desde la década de los ochentas, las herramientas basadas en sistemas inteligentes han adquirido gran popularidad dentro de la práctica de la ingeniería. Uno de los papeles importantes de las RNAs es proporcionar una parametrización cuando se tiene un mapeo no lineal entre entradas y salidas [2] como el dado en ingeniería sísmica, entre la atenuación de la energía liberada en un terremoto con la distancia al foco. 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, [3] 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.

En [4,5,6] han usado herramientas alternativas basadas en la inteligencia artificial para mapear la disminución de la aceleración pico del suelo con la distancia.

Siguiendo esta misma línea de trabajo, en el presente trabajo se propone un procedimiento alternativo de tratamiento de la base de datos de intensidades macrosísmicas generada por [7 y 8].

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 haciendo uso de la base de datos de información sísmica originalmente generada por [7 y 8] para la parte norte de Suramérica.

II. ATENUACIÓN SISMICA

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, se encuentran en la literatura científica varios esfuerzos para mejorar los modelos de atenuación de la intensidad [9].

Se han desarrollado varios estudios de atenuación de la intensidad sísmica en diferentes regiones del mundo: la zona de Cascadia [10], India [11] e Italia [12,13]). En los casos anteriormente mencionados, 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 la parte norte de Suramérica, [14] y [3] 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, debida a que este es un medio para incorporar las sollicitaciones de las fuentes de los terremotos. Adicionalmente, el estudio de la atenuación de la intensidad es importante en la evaluación de la amenaza probabilística sísmica, por lo que resalta la necesidad de encontrar formas alternativas que mapeen mejor dicha relación.

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). En la literatura se han reportado modelos matemáticos y estadísticos de regresión de ajuste de datos. En forma general, el modelo matemático que ha sido usado para mapear la relación entre I , R e I_0 tiene la siguiente estructura [3,15]

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

Otros autores presentan un enfoque incluyendo directamente la magnitud en la ecuación de atenuación [10,16]

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

Generalmente, a los parámetros de la ecuación 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 la forma general:

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

Donde e es el vector de errores, el cual se supone generalmente que 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. Adicionalmente se tiene que la métrica de desempeño para el modelo de regresión es la desviación estándar σ tipo I definida como:

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

[3]:

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

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

[17]:

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

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

La base de datos que usó [3] para derivar los modelos de regresión estadística de las ecuaciones 5 y 6 es la misma que se usó para el desarrollo del presente trabajo.

III. EL MODELO DE UNA RED NEURONAL (RNA)

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 [18].

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.

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 con 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 $y_j = f(\mathbf{X} \cdot \mathbf{W}_j - b_j)$. Este

proceso se repite para todos los nodos y luego para

cada capa. La red puede entonces utilizarse para

hacer mapeos basados en los valores de entrada. En

nuestra aplicación se utilizaron tres algoritmos para

el entrenamiento: *Gradiente Conjugado*, *Back-Propagation* y *Levenberg-Marquard*, 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

cerca 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 $E(\mathbf{W})$:

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

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.

IV. ÁREA DE ESTUDIO Y DATOS DE TRABAJO

El mapa del área de estudio y el epicentro de 68 sismos ocurridos en la parte norte de Suramérica en el periodo comprendido entre 1766 a 2004 se

encuentra disponible en el suplemento electrónico de la publicación realizada por [7].

De la base de datos generada por [7] 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, sismos superficiales. 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. En la Tabla 1 se presenta una descripción general de la base de datos.

Tabla 1. Variables utilizadas e intervalos desagregados en sismos superficiales y de subducción.[1]

Variables	Rango	Evento	
		Superficial	Subducción
Magnitud (M)	Max	7,8	6,9
	Min	4,2	5,4
Intensidad (I)	Max	11	9
	Min	1	3
Distancia (R), Km	Max	631,3	354,8
	Min	3,2	24,3
Intensidad epicentral (I_o)	Max	11	9
	Min	5	5
Diferencia entre intensidades ($I-I_o$)	Max	0	0
	Min	-9	-4

V. SELECCIÓN DE LOS MODELOS

Teniendo en cuenta las relaciones funcionales entre magnitud (M), distancia (R), intensidad (I), intensidad epicentral (I_o) y diferencia de intensidad ($I-I_o$), se plantean tres modelos a través de RNAs (Tabla 2).

Tabla 2. Variables de entrada y salida de los modelos. [1]

Modelos	Variables Entrada		Variables de Salida	
	I	Magnitud (M)	Intensidad (I)	Distancia (R)
II	Magnitud (M)	Distancia (R)	Intensidad (I)	
III	Magnitud (M)		Intensidad epicentral (I_o)	

VI. RESULTADOS

A. Topología de la red

Para enfrentar el problema de mapeo de la intensidad sísmica, se utilizará un criterio heurístico basado en la intuición y la experimentación para seleccionar la mejor topología de la RNA [19 y 20].

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 [21]. 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 las Tablas 3 a la 5 se presentan los resultados obtenidos de la selección de las RNAs para los tres modelos en términos del grado de correlación **R**.

La selección del mejor modelo de red se debió a dos factores principalmente. Por un lado está el rendimiento en la etapa de entrenamiento analizado a través de la rapidez de respuesta en la etapa de formación y por otro lado las métricas de desempeño tanto en la etapa de formación del modelo de red como en la etapa de validación a través de la función de error.

Analizando los aspectos anteriormente mencionados, el modelo de RNAs seleccionado corresponde con el algoritmo *Levenberg-Marquardt* [22 y 23].

Tabla 3. Resultados del Modelo I para sismos superficiales y subducción. Entrada (intensidad y magnitud), salida (distancia e intensidad epicentral).

Modelo I				
Capas Ocultas (2)	Algoritmo de entrenamiento Levenberg-Marquardt			
Tipo de Eventos	R : Entrenamiento	R: Prueba	R: Entrenamiento	R: Prueba
Superficial	0,86804	0,8616	0,64015	0,49446
Subducción	0,91214	0,99252	0,94714	0,9802

Tabla 4. Resultados del Modelo II para sismos superficiales y subducción. Entrada (magnitud y radio), salida (intensidad).

Modelo II		
Capas Ocultas (2)	Algoritmo de entrenamiento Levenberg-Marquardt	
Tipo de Eventos	R : Entrenamiento	R: Prueba
Superficial	0,77204	0,75821
Subducción	0,89714	0,9643

Tabla 5. Resultados del Modelo III para sismos superficial y subducción. Entrada (magnitud), salida (intensidad epicentral).

Modelo III		
Capas Ocultas Superficial (4), Subducción (2)	Algoritmo de entrenamiento Levenberg-Marquardt	
Tipo de Eventos	R : Entrenamiento	R: Prueba
Superficial	0,66775	0,77047
Subducción	0,96492	0,97321

Las Figuras 1 y 2 representan el grado de correlación **R** entre los datos observados y los calculados en el entrenamiento y la prueba con las RNA para el modelo I para sismos superficiales y sismos de subducción.

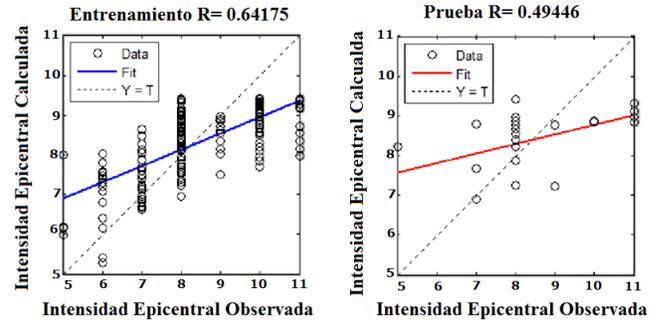
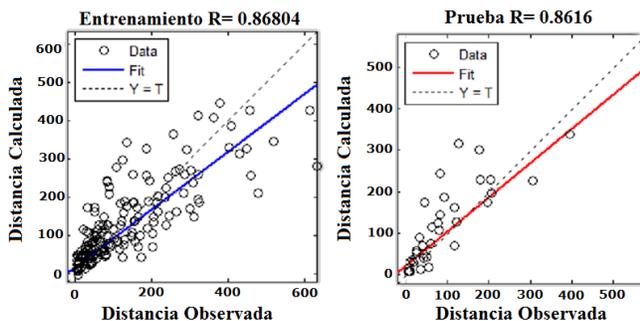


Figura 1. Modelo I. Entrada (magnitud e intensidad). Salidas (distancia e intensidad epicentral) para sismos superficiales. Fuente: [1].

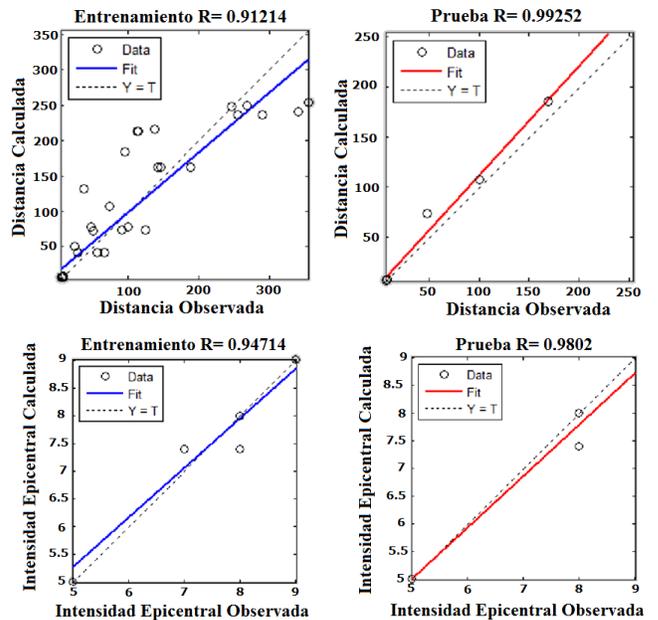


Figura 2. Modelo I. Entrada (magnitud e intensidad). Salidas (distancia e intensidad epicentral) para sismos subducción. Fuente: [1].

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 que 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.

VII. VALIDACIÓN DEL MODELO DE REDES NEURONALES

Utilizando los resultados de la RNA en cada modelo (I, II y II) se mapeó la relación de atenuación para

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

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

[17]

$$I = 1.55M - 3.72 \log_{10} R + 1.97; \sigma = 1.39 \text{ Sismos superficiales} \quad (7)$$

$$I = 1.70M - 4.82 \log_{10} R + 3.97; \sigma = 1.64 \text{ Sismos de subducción} \quad (8)$$

El comportamiento de la atenuación de la intensidad para las ecuaciones de regresión y los resultados del modelo de RNAs se puede observar en la Figura 3 para dos magnitudes. Adicionalmente se presenta los

puntos observados de la base de datos con fines indicativos.

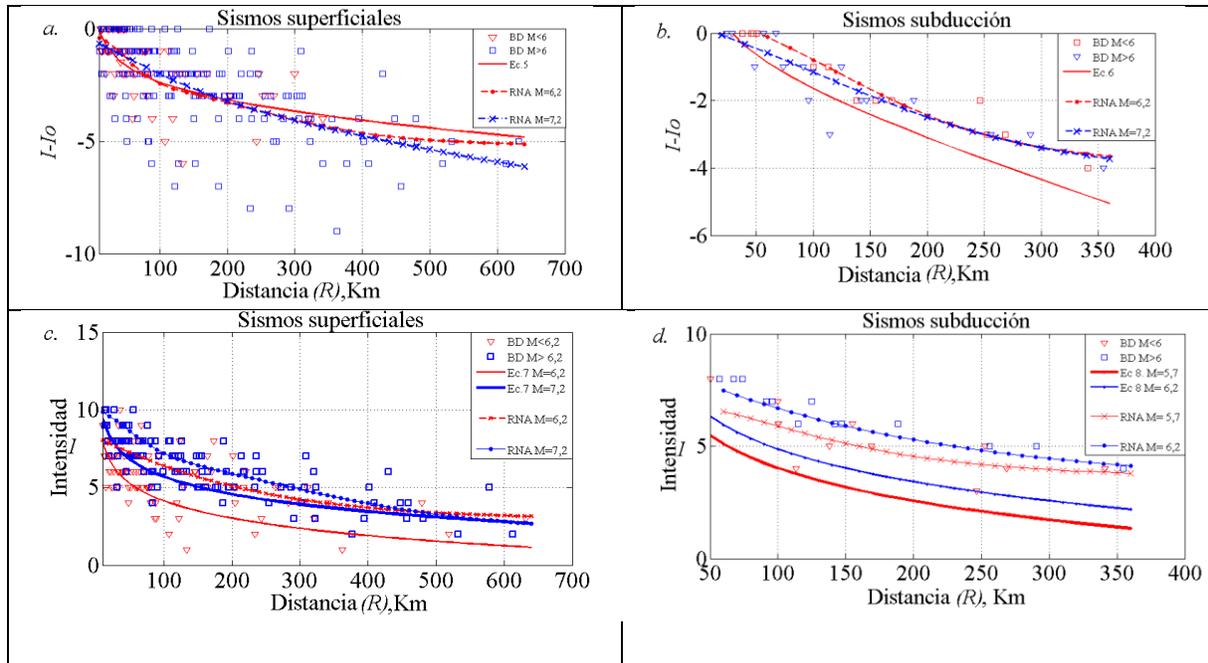


Figura 3. Comparación de la atenuación de la intensidad con la ecuación de atenuación y con el modelo de RNA. a. Diferencia de intensidad ($I - I_o$), RNA para modelo I y ecuación 5 para sismos superficiales. b. Diferencia de intensidad ($I - I_o$), RNA para modelo I y ecuación 6 para sismos de subducción. c. Intensidad, RNA para modelo II y ecuación 7. d. Intensidad, RNA para modelo II y ecuación 8.

Fuente: [1].

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 mapeo de las RNA permite observar procesos emergentes de la propagación de ondas por medio heterogéneos (la corteza terrestre y el subsuelo superficial).

Con el objeto de comparar el desempeño de las ecuaciones convencionales de atenuación (ec 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 6). La desviación estándar da cuenta de la dispersión de los datos con respecto al valor medio y el RECM representa la dispersión de los datos con respecto al modelo (ecuación de regresión o RNA) que pretende mapear los datos observados.

Tabla 6. Resultados de comparación Modelos I

Superficial			
Estadístico	Observado <i>I-Io</i>	Ecuación 5	RNA Modelo I
Desviación estándar	1,91	1,52	1,32
RECM		19,16	14,53
Subducción			
Estadístico	Observado <i>I-Io</i>	Ecuación 6	RNA Modelo I
Desviación estándar	1,25	1,44	1,15
RECM		2,96	1,89
Superficial			
Estadístico	Observado <i>I</i>	Ecuación 7	RNA Modelo II
Desviación estándar	1,92	1,76	1,37
RECM		20,23	13,4
Superficial			
Estadístico	Observado <i>I</i>	Ecuación 8	RNA Modelo II
Desviación estándar	1,52	1,85	1,45
RECM		7,3	1,98

Fuente: [1].

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 RNAs son capaces de mapear de mejor manera la atenuación de la intensidad.

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 (ec. 5, 6, 7 y 8) en contraste con los modelos de RNAs, los resultados se observan en el diagrama de caja de la Figura 4

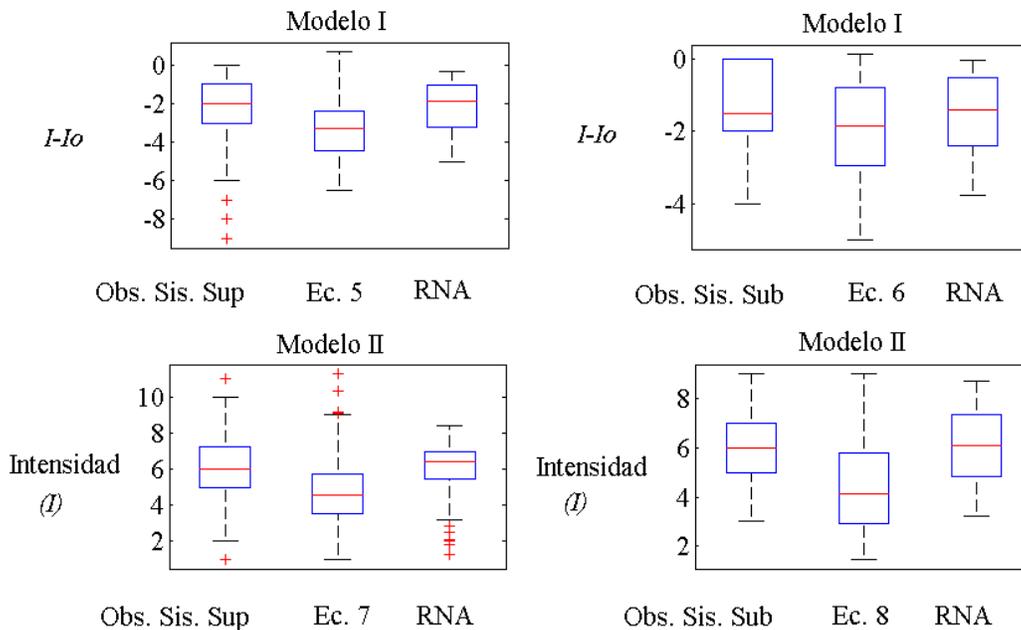


Figura 4. Diagrama de caja de los datos observados, de las ecuaciones de regresión y de las RNA's.
Fuente: [1].

Se observa en la Figura 4 que la dispersión medida en términos del rango intercuartíl es mayor en los modelos de regresión en los casos evaluados, en 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 RNAs. 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 muestran siempre un desplazamiento hacia valores inferiores, mientras que las RNAs conservan un porcentaje similar de densidad alrededor del centro de masa con respecto a los observados.

VIII. CONCLUSIONES

Las RNA's son capaces de mapear de 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 RNAs (test) estuvieron entre 0,97 y 0,9 (exceptuando el modelo II). b. Se observa que los modelos de RNAs muestran un excelente ajuste entre los datos observados (*target*) y los datos obtenidos por los modelos de RNAs, y c. Se observa que el RECM es menor en todos los casos para las RNA al compararla con las ecuaciones de regresión.

Las RNAs 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 RNAs que la que se observa en las ecuaciones convencionales de atenuación de intensidad.

AGRADECIMIENTOS

Los autores del presente artículo agradecen al Banco Santander S.A. y a la Pontificia Universidad Javeriana por el apoyo económico para el desarrollo del trabajo enmarcado en el proyecto 4757 "Incorporación de la incertidumbre de datos históricos utilizando modelos bio-inspirados en el estudio de la atenuación de la intensidad sísmica"

REFERENCIAS

- [1] HERRERA, E., RAMOS, A. y J. GARCÍA. *Redes neuronales para representar la atenuación de la intensidad sísmica*. Revista Ingeniería y Universidad 2013. Vol 17 No 2 pp 277-292.
- [2] BISHOP, C. *Neural Networks for Pattern Recognition*. Oxford: Oxford University Press, 1995.
- [3] PRIETO, J., FOSHI, R., VENTURA,C., FINN, W. RAMOS, A. PRADA, L.. *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.

[4] GÜNAYDIN, K. y GÜNAYDIN, A. *Peak Ground Acceleration Prediction by Artificial Neural Networks for Northwestern Turkey*. Mathematical Problems in Engineering. 2008, pp. 1- 20.

[5] ARJUN, C. y A. KUMAR. *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.

[6] 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.

[7] PRIETO, J., FOSHI, R., VENTURA,C., FINN, W. RAMOS, A. PRADA, L. *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.

[8] PRIETO, J. VENTURA,C., FINN, W. RAMOS, A. PRADA, L. *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.

[9] SAUTER, F. *Fundamentos de Ingeniería Sísmica: Introducción a la Sismología (I)*. Editorial Tecnológica de Costa Rica. 1989, 1ª ed, 271p.

[10] 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.

[11] 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.

[12] 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.

- [13] PASOLINI, C., GASPERINI, P. ALBARELLO, D., LOLLI, D. DÁRMICO, 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.
- [14] 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.
- [15] MUÑOZ, D. *Conceptos Básicos en Riesgo Sísmico*. Física de la tierra. 1989, núm. 1, pp.199-215.
- [16] MUSSON, R. *Intensity Attenuation in the U.K*. Journal of Seismology. 2005, vol. 9, pp. 73-86.
- [17] 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.
- [18] HAYKIN, S. *Neural Network a Comprehensive Foundation*. Prentice-Hall. 1994, 2^a ed, vol. 4, pp 1-35, México.
- [19] SIETSMA, J. y DOW R. *Creating Artificial Neural Networks that Generalize*. Neural Network. 1991, vol. 4, núm. 1, pp. 67-79.
- [20] 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 Ingeniera Universidad de Antioquia. 2008, núm 46, pp. 110-118.
- [21] LEÓN, P. y GALVAN I. *Redes de Neuronas Artificiales, un Enfoque Práctico*. Pearson, Prentice Hall.2003, Madrid.
- [22] KIPLI, K., MUHAMMAD, M., MASNIAH, N. 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.
- [23] LOURAKIS, M. *Brief Description of the Levenberg-Marquardt Algorithm Implemented by Levmar*. Foundation of Research and Technology. 2005, vol. 4, pp. 1-6.