

## Comparación de desempeño de las redes neuronales artificiales RBF y MLP para modelar el ruido en un área urbana

José D. Martínez-Morales\*, José M. Romo-Orozco\*\*, Elvia R. Palacios-Hernández\*\*\*

\*Unidad Académica Multidisciplinaria Zona Media, Universidad Autónoma de San Luis Potosí, 79617, México  
(Tel: 487-8725099; e-mail: daniel.martinez@uaslp.mx)

\*\*Unidad Académica Multidisciplinaria Zona Media, Universidad Autónoma de San Luis Potosí, 79617, México  
(Tel: 487-8725099; e-mail: jmromo@uaslp.mx)

\*\*\*Facultad de Ciencias, Universidad Autónoma de San Luis Potosí, 78290, México  
(Tel: 444-8262491; e-mail: epalacios@fciencias.uaslp.mx)

**Resumen:** En este trabajo, se presenta el modelado del nivel de ruido en una zona urbana. Los modelos son basados en dos tipos de redes neuronales artificiales (RNA), la red de base radial (RBF) y la red perceptron multicapa (MLP). Para llevar a cabo el entrenamiento de las RNA, se ha medido el nivel de ruido  $L_{Aeq}$  en diferentes puntos de una zona urbana mediante un sonómetro. Para realizar la selección de los datos de entrenamiento y prueba de las RNA se utiliza una técnica de *bootstrapping*. Mientras que el número de neuronas en la capa oculta se determina a partir de porcentaje de error medio absoluto (MAPE) y el coeficiente de correlación  $R^2$ . De acuerdo a los resultados obtenidos en este trabajo, la red MLP es capaz de predecir el nivel de presión sonora con un coeficiente de correlación  $R^2 = 0.99883$ , menor al obtenido mediante la red neuronal RBF con  $R^2 = 0.99904$ .

**Palabras clave:** Nivel de ruido  $L_{Aeq}$ , Redes neuronales artificiales, bootstrapping, radial function, MAPE.

### 1. INTRODUCCIÓN

En la actualidad la exposición de comunidades al ruido ambiental es una preocupación mundial, sin embargo, muchas ciudades están todavía expuestas a niveles de ruido que son perturbadores para las actividades humanas cotidianas, ya que el ruido urbano es un factor que contribuye al estrés y este impacta de manera negativa en el bienestar del ser humano (Vernez 2009, Öhrström et al. 2006). El ruido se encuentra entre los contaminantes más invasivos que se presentan en las áreas urbanas, esto debido a que su origen se vincula a tareas realizadas de manera ordinaria. La movilidad, así como las actividades productivas y lúdicas se encuentran entre las principales fuentes de sonidos indeseados que las personas perciben. Por la importancia que pueden tener algunas actividades para el funcionamiento y desarrollo de las ciudades, antes de establecer estrategias tendientes a controlar el ruido aéreo es indispensable elaborar un diagnóstico de las condiciones acústicas que se experimentan en la zona de interés (Jennings et al. 2013). Una forma es modelando dichas condiciones a través de un modelo computacional en base a las características urbanas de la zona a estudiar.

Los niveles diurnos de ruido superiores a 70 dB originan situaciones altamente molestas, sin embargo, un nivel por encima de 60 dB produce afectaciones a un elevado porcentaje de la población en México. La Organización Mundial de la Salud (OMS) ha sugerido un valor de ruido de 55 dB como límite superior deseable al aire libre. Por su parte, la reciente modificación a la Norma Oficial Mexicana NOM-081-SEMARNAT-1994, publicada en México en el

Diario Oficial de la Federación en diciembre del 2013, señala nuevos límites máximos permisibles de emisión de ruido, estos nuevos niveles se muestran en la tabla 1.

**Tabla 1. Niveles máximos permisibles de ruido en México.**

Zona	Horario	Límite máximo permisible en dB
Residencial (exteriores)	6:00 – 22:00	55
Industriales y comerciales	6:00 - 22:00	68
Escuelas (áreas exteriores de juego)	Durante el juego	55
Ceremonias, festivales y eventos de entretenimiento	4 horas	100

Debido a que el oído responde a una amplia gama de presiones sonoras y a que no lo hace de manera lineal, para representarla se adopta una escala logarítmica, llamada nivel de presión sonora (NPS o  $L_d$ ). Esta escala se expresa en valores relativos a un valor de referencia que corresponde al umbral de audición, a partir del cual todos los sonidos audibles son positivos. La unidad de medición es el decibelio (dB), que equivale a la menor variación sonora capaz de ser

percibida por el oído humano medio; con el dB se reduce el manejo de valores de presión sonora de 0 a 135 dB, donde 0 dB representa una presión igual al umbral de audición y 135 dB el umbral aproximado de dolor. El nivel de presión sonora de dos sonidos distintos puede ser el mismo, pero uno de ellos puede considerarse más alto si está concentrado en región de frecuencias en donde el oído es más sensible. Para adaptar el nivel de presión sonora (dB) a la sensibilidad del oído humano se aplican correcciones (reducción o aumento de nivel) y se obtienen niveles ponderados. La ponderación más utilizada, ya que refleja mejor la respuesta del oído para niveles habituales de ruido, es la curva de ponderación A, obteniendo a partir de ella niveles ponderados A.

La mayoría de los sonidos varían con el tiempo pudiendo fluctuar en una escala muy pequeña (a una cierta distancia de una autopista) o en una escala muy amplia (cerca de un aeropuerto). La descripción de estas variaciones se realiza mediante una única unidad llamada nivel equivalente continuo de presión acústica  $L_{Aeq}$  en dB, la descripción de todos los diferentes ruidos se basa en la hipótesis que a dosis de ruido iguales (la energía acústica se multiplica por el tiempo de exposición) resultan efectos sonoros iguales. Existen unidades suplementarias para describir sonidos que presentan fluctuaciones muy rápidas o para aquellos que resultan poco corrientes, como son el nivel máximo de presión acústica  $L_{max}$ , y los niveles de ruido estadísticos  $L_n$  (nivel de exceso en % del tiempo).

El objetivo de este estudio es desarrollar un modelo para estimar el nivel de presión sonora, bajo la hipótesis de que las variables de posición en el plano del área urbana, así como el ancho de la vía ( $A_v$ ) y la altura de la edificación ( $A_e$ ) en el punto de medición tiene influencia en el nivel de sonido equivalente  $L_{Aeq}$ . Los modelos son desarrollados mediante el uso de RNA perceptron multicapa (MLP) y redes de funciones de base radial (RBF).

Las RNA están siendo utilizadas ampliamente para la predicción de variables ambientales (Torija et al. 2012a, Torija et al. 2012b, Dolores et al. 2013, Kumar et al. 2014, Sharma et al. 2012), debido a su baja sensibilidad a datos con ruido y a que su desempeño es bueno aún cuando se consideran conjuntos de datos pequeños para el aprendizaje de las RNA. Más aún, las RNA pueden ser empleadas para generar datos que puedan ser incorporados a un sistema de información geográfica (GIS, geographical system information) mejorando la visualización e interpretación de datos en mapas de ruido (Souza et al. 2011). Torija et al. (2012a) usaron el espectro en frecuencias del nivel de sonido como dato de entrada para desarrollar un modelo de tráfico mediante regresión lineal múltiple y redes neuronales MLP. En su estudio las bandas de frecuencia de 50-400 Hz y 1-2.5kHz son entradas a diferentes configuraciones de redes neuronales MLP para estimar el tráfico carretero, encontrando coeficientes de correlación  $R^2$  en el rango de 0.82 a 0.85. Torija et al. (2012b) predicen el nivel de presión sonora equivalente ( $L_{Aeq}$ ) y su composición espectral de un ambiente sonoro urbano, basado en un modelo de RNA *backpropagation*, considerando 14 parámetros de entrada y 6 salidas de la RNA. En su estudio examinan diferentes configuraciones de RNA para las cuales encuentran coeficientes de correlación  $R^2$  en el rango de 0.88 a 0.90 para

la predicción del nivel de presión sonora  $L_{Aeq}$ . Kumar et al. (2014), utilizaron RNA *backpropagation* entrenadas mediante el algoritmo Levenberg-Marquardt (L-M) para la predicción del percentil 10 ( $L_{10}$ ) del nivel sonoro, así como el nivel equivalente de presión sonora ( $L_{Aeq}$ ) mediante tres variables de entrada de la RNA. En su estudio encontraron que la arquitectura de la RNA (3, 8, 2) es óptima con coeficientes de correlación  $R^2 = 0.8160$  y  $R^2 = 0.8524$  para  $L_{10}$  y  $L_{Aeq}$  respectivamente para datos de prueba de la RNA. El presente estudio se efectúa sobre la parte central de la ciudad de Rioverde, San Luis Potosí (México). En la Fig. 1 se muestra el área urbanizada de interés para predecir el nivel de presión sonora equivalente, esta área corresponde al polígono delimitado por las calles Guerrero (norte), Aldama (sur), Galeana (este) y Juárez (oeste); el área de estudio presenta una alta concentración de tránsito vehicular y de actividades comerciales que ocasionan niveles de presión sonora por encima de los máximos permisibles, lo que sugiere la necesidad de ampliar y actualizar la información para detectar las áreas de especial sensibilidad y regular el funcionamiento de algunas actividades que en el contexto son fuentes de ruido excesivo.




Fig. 1. Zona urbana de interés en la predicción del nivel de presión sonora.

### 1.1 Medición del nivel de presión sonora $L_{Aeq}$ .

Convencionalmente, para registrar los niveles de ruido aéreo en áreas urbanas, se recurre a los sonómetros. En este caso se utilizó un equipo integrador-promediador modelo 2250, con micrófono modelo 4189, de la marca Brüel & Kjaer. Las mediciones se realizaron en 38 puntos de la zona central de la ciudad entre los meses de marzo y julio del año 2009, entre las 8:00 am y las 19:00 pm de días laborales. Cabe mencionar que cada una de las mediciones realizadas en este horario se repitió en tres ocasiones, esto con el fin de evitar incertidumbre en la medición. Las mediciones de presión sonora realizadas mediante sonómetro, se efectuaron con apego a la norma ISO 1996-2:2007, que indica que el sonómetro debe estar colocado a una altura de 1.5 m y alejado 2 m de la superficie vertical más cercana. El nivel de sonido fue adquirido de manera simultánea con el ancho de la vía y la altura de la edificación. En la Fig. 2 se muestra una fotografía del sonómetro empleado para este trabajo.



Fig. 2. Sonómetro para la medición del nivel de ruido  $L_{Aeq}$ .

Los conjuntos de datos adquiridos para desarrollar los modelos consisten de 38 datos, mostrados en las Figs. 3 y 4 como variables de entrada y salida a las RNA respectivamente.




Fig. 3. Conjuntos de datos de entrada de las RNA para el entrenamiento y prueba. (a) posición  $x$  (b) posición  $y$  (c) ancho de la vía  $A_v$ , (d) Altura de la edificación  $A_e$ .




Fig. 4. Conjunto de datos de salida de las RNA para su entrenamiento y prueba.

Los datos disponibles para desarrollar los modelos se dividen en los conjuntos de entrenamiento y prueba de las RNA. El conjunto de entrenamiento consiste de 20 datos de entrada y salida, mientras que el conjunto de prueba consiste de los restantes 18 datos de las variables de entrada y salida de las RNA.

## 2. MODELO DEL RUIDO EN ZONA URBANA

### 2.1 Red neuronal de funciones de base radial (RBF)

La red RBF es una red neuronal con neuronas artificiales organizadas en por lo menos 3 capas. Una capa de entrada, una capa oculta y una capa de salida (Simpson, 1990). El algoritmo de entrenamiento de la red RBF se basa en el gradiente y minimiza una función de error cuadrática del error entre los valores reales del sonido y los predichos por la red. Las conexiones de la RNA (pesos  $w_{ij}$ ) se ajustan hasta que un valor preestablecido de error se alcance. Los datos de entrada o referencia del modelo son las posiciones  $P_x$  y  $P_y$  en el plano de la zona urbana, así como el ancho de la vía y la altura de la edificación en el punto de medición, estas variables influyen el nivel de ruido debido a la dispersión del ruido que se presenta en espacios más abiertos. Como variable de salida del modelo se tiene el nivel de ruido. La red neuronal de base radial está basada en la suma de productos, cuya función de activación es de base radial (función de validez) descrita por la siguiente ecuación

$$\phi(x, c) = \exp\left(\frac{-\|x - c\|^2}{2\sigma^2}\right), \quad (1)$$

donde  $x$  son las entradas de la red,  $c$  son los centros de las funciones radiales y  $\sigma$  son los anchos de las mismas. En la Fig. 5 se muestra la estructura de la red neuronal empleada para modelar el nivel de ruido. La salida de la RNA con  $Q$  neuronas en la capa oculta está dada por:

$$\hat{y} = \sum_{i=1}^Q w_i \phi_i(x, c_i), \quad (2)$$

donde  $w_i$  denota el  $i$ -ésimo peso de entrenamiento.

### 2.2 Red neuronal perceptron multicapa (MLP)

La red neuronal MLP utilizada en este trabajo consiste en una capa de entrada, una capa oculta con  $Q$  neuronas y una capa de salida, la activación de la  $i$ -ésima neurona oculta,  $i=1,2,\dots,Q$ , viene dada por

$$u_i = \sum_{j=1}^p w_{ij} x_j + \theta_i, \quad (3)$$

donde  $w_{ij}$  es el peso que conecta la  $j$ -ésima unidad de entrada a la  $i$ -ésima neurona oculta,  $\theta_i$  es el  $i$ -ésimo umbral y  $x_j$  es la  $j$ -ésima variable de entrada con  $j = 1, 2, \dots, p$ . La salida de la  $i$ -ésima neurona oculta se define como

$$y_i = \phi_i(u_i) = \phi_i \left( \sum_{j=1}^p w_{ij} x_j + \theta_i \right), \quad (4)$$

donde  $\phi(\cdot)$  es la función de activación. Por lo tanto, los valores de salida de la red están dados por

$$y_{pred} = \phi \left( \sum_{i=1}^Q m_i y_i + b \right), \quad (5)$$

donde  $m_i$  es el peso que conecta la  $i$ -ésima neurona oculta a la neurona de salida, y  $b$  es el umbral de la neurona de salida. La función de activación utilizada para esta red neuronal es *log-sigmoide*, por lo tanto, la salida de esta red se calcula como sigue

$$y_{pred} = \frac{1}{1 + \exp^{-\sum_{i=1}^Q m_i y_i + b}}. \quad (6)$$

En la Fig. 6 se muestra la estructura de la red MLP empleada en este trabajo.

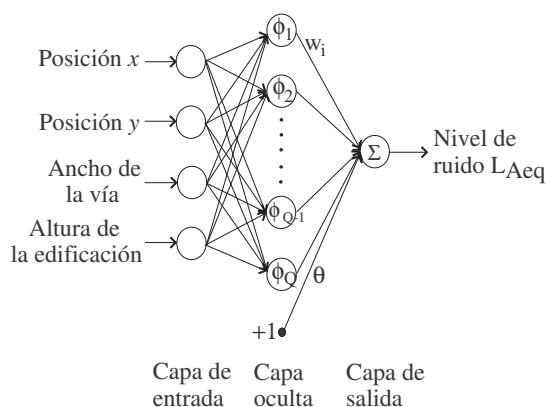


Fig. 5. Estructura del modelo neuronal RBF para el nivel de ruido.




Fig. 6. Estructura del modelo neuronal MLP para el nivel de ruido.

### 3. DESEMPEÑO DE LOS MODELOS BASADOS EN RNA

Con el fin de seleccionar el número de neuronas ocultas de las RNA, una técnica de *bootstrapping* introducida por Efron et al. (1993), se utiliza para evaluar la exactitud de los modelos RNA. Supongamos que tenemos el conjunto de datos de entrenamiento  $Z = (z_1, z_2, \dots, z_n)$ , donde  $z_i = (x_i, y_i)$  es un par de entrada-salida. Los conjuntos de datos  $Z^{*b}$  se extraen aleatoriamente del conjunto  $Z$ . Cada muestra *bootstrap* es del mismo tamaño, esto se hace  $B$  veces. Entonces, el modelo se ajusta a cada una de las muestras *bootstrap* y se examina el comportamiento de los ajustes en las  $B$  repeticiones. El total de los conjuntos de datos adquiridos para cada variable de entrada y salida son divididos en conjuntos de entrenamiento y prueba, 20 conjuntos son elegidos para el entrenamiento de los modelos, mientras que los restantes 18 conjuntos de datos se utilizan como datos de prueba de los modelos. Si  $f^{*b}(x_i)$  es el valor predicho para la entrada  $x_i$ , del modelo ajustado para la  $b$ -ésima muestra *bootstrapped*, la estimación del error de predicción del modelo se puede obtener mediante

$$Err_{boot} = \frac{1}{BH} \sum_{b=1}^B \sum_{i=1}^H (y_i - f^{*b}(x))^2, \quad (7)$$

donde  $B = 10$  es el número de muestras *bootstrap* y  $H = 20$  son los conjuntos de datos de entrenamiento. El parámetro  $Err_{boot}$  estimado a partir de las muestras *bootstrap*, caracteriza la precisión del modelo y se puede utilizar para comparar el rendimiento de diferentes modelos con diferente número de neuronas en la capa oculta, con el fin de seleccionar la mejor red neuronal.

### 4. RESULTADOS

La Fig. 7 muestra  $Err_{boot}$  para diferente número de neuronas ocultas para cada red neuronal.  $Err_{boot}$  es más pequeño para la RNA RBF con arquitectura (4,6,1) para la predicción de  $L_{Aeq}$ .

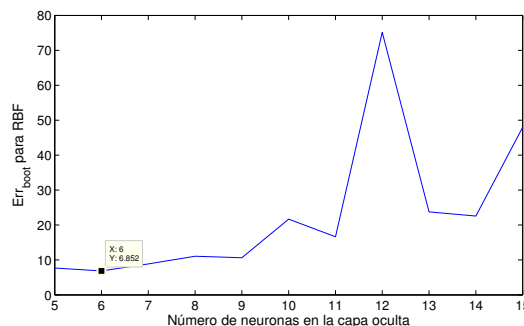


Fig. 7. Desempeño de la RNA RBF para diferente número de neuronas en la capa oculta en términos de  $Err_{boot}$ .

Para la red MLP con arquitectura (4, 6, 1),  $Err_{boot}$  es más pequeño para la predicción de  $L_{Aeq}$ , como se muestra en la Fig. 8.




Fig. 8. Desempeño de la RNA MLP para diferente número de neuronas en la capa oculta en términos de  $Err_{boot}$ .

Con el fin de estimar las cualidades de predicción de los modelos RNA con los valores más bajos de  $Err_{boot}$ , los conjuntos de datos que no se utilizaron para entrenar a las redes se eligen y el coeficiente de correlación  $R^2$  se calcula durante la validación de los modelo como

$$R^2 = 1 - \left( \frac{\sum_{i=1}^T (y_{meas_i} - y_{pred_i})^2}{\sum_{i=1}^T (y_{meas_i})^2} \right), \quad (8)$$

además del porcentaje de error medio absoluto (MAPE) que determina el error sobre todas los datos de prueba definido por

$$MAPE = \frac{1}{T} \left[ \sum_{i=1}^T \left| \frac{y_{meas_i} - y_{pred_i}}{y_{meas_i}} \right| \right] \times 100, \quad (9)$$

donde  $T = 18$  es el número de conjuntos de datos de prueba,  $y_{meas}$  y  $y_{pred}$  son el ruido medido y predicho por la RNA respectivamente. El MAPE es más pequeño con la estructura (4, 6, 1) para la red RBF (2.739). Mientras que el MAPE es de 2.497 para la arquitectura (4, 6, 1) de la red MLP. La correlación entre las emisiones medidas y predichas por las redes RBF y MLP se muestran en las Figs. 9 y 10 respectivamente. Como es visible en estas figuras los valores predichos por cada modelo están muy cerca a los datos experimentales. La Fig. 9 muestra la correlación entre  $L_{Aeq}$  medido y predicho por la red RBF. Para este caso  $R^2 = 0.99904$ . La Fig. 10 muestra la predicción de  $L_{Aeq}$  mediante la red MLP con un coeficiente de correlación  $R^2 = 0.99883$ .

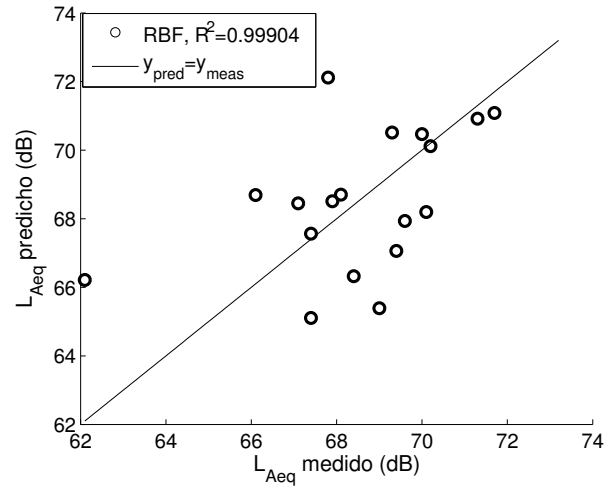


Fig. 9. Coeficiente de correlación  $R^2 = 0.99904$  obtenido mediante la RNA RBF en la predicción de  $L_{Aeq}$ .




Fig. 10. Coeficiente de correlación  $R^2 = 0.99883$  obtenido mediante la RNA MLP en la predicción de  $L_{Aeq}$ .

## 5. CONCLUSIONES

Como contribución, en este trabajo se desarrollan modelos basados en RNA para la predicción del nivel equivalente de presión sonora  $L_{Aeq}$ , mediante las variables de posición en el plano del área urbana, así como el ancho de la vía y la altura de la edificación en el punto de medición. De acuerdo a los resultados encontrados en este trabajo, la red MLP con arquitectura (4, 6, 1), es capaz de predecir el nivel de presión sonora con un coeficiente de correlación  $R^2 = 0.99883$ . Menor al obtenido mediante la red neuronal RBF de estructura (4, 6, 1) con  $R^2 = 0.99904$ . Por lo tanto la RNA RBF se desempeña mejor que la red MLP en estimar el nivel de presión sonora  $L_{Aeq}$  a partir de las 4 características del área urbana consideradas como entradas a las RNA en este estudio.

## REFERENCIAS

- Dolores, M., Fernández, F., and Gutiérrez, P. (2013). Ensembles of evolutionary product unit or RBF neural networks for the identification of sound for pass-by noise test in vehicles. *Neurocomputing*, 109, 56-65.
- Efron, B., and Tibshirani, R. (1993). *An Introduction to the Bootstrap*. Chapman & Hall, London.
- Jennings, P., and Cain, R. (2013). A framework for improving urban soundscapes. *Applied Acoustics*, 74 (2), 293-299.
- Kumar, P., Nigam, S., and Kumar, N. (2014). Vehicular traffic noise modeling using artificial neural network approach. *Transportation Research Part C*, 40, 111-122.
- Öhrström, E., Skånberg, A., Svensson, H., and Gidlöf, A. (2006). Effects of road traffic noise and the benefit of access to quietness. *Journal of Sound and Vibration*, 295(1),40-59.
- Sharma, M., Dahiya, M., Kumar, P., and Garg, N. (2012). Application of Artificial Neural Network for Modelling of Traffic Noise on Roads in Delhi. *Journal of Mechanical and Civil Engineering*. 1(6),31-36.
- Simpson, P. (1990). *Artificial neural systems: foundations, paradigms, applications and implementations*. Pergamon Press, New York, USA.
- Souza, L., and Giunta, M. (2011). Urban indices as environmental noise indicators. *Computers, Environment and Urban Systems*, 35, 421-430.
- Torija, A., and Ruiz, D. (2012a). Using recorded sound spectra profile as input data for real-time short-term urban road-traffic-flow estimation. *Science of the Total Environment*, 435, 270-279.
- Torija, A., Ruiz, D., and Ramos, A. (2012b). Use of back-propagation neural networks to predict both level and temporal-spectral composition of sound pressure in urban sound environments. *Building and Environment*, 52, 45-56.
- Vernez, A. (2009). Real Noise from the Urban Environment. *American Journal of Preventive Medicine*, 37(2), 167-171.