

CARACTERIZACIÓN ACÚSTICA DE AMBIENTES URBANOS MEDIANTE EL USO DE REDES NEURONALES

URBAN NOISE PREDICTION USING NEURAL NETWORKS

Martín E. Sequeira^a, Víctor H. Cortínez^{a,b,c} y Adrián P. Azzurro^a

^a*Centro de Investigaciones en Mecánica Teórica y Aplicada, Universidad Tecnológica Nacional,
Facultad Regional Bahía Blanca, 11 de Abril 461, 8000 Bahía Blanca, Argentina
e-mails: martins@frbb.utn.edu.ar; vcortine@frbb.utn.edu.ar; azzurro@frbb.utn.edu.ar*

^b*Departamento de Ingeniería Universidad Nacional del Sur, Alem 1253, 8000 Bahía Blanca,
Argentina*

^c*Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)*

Palabras clave: Ruido urbano, Redes neuronales, Predicción sonora.

Resumen. La contaminación sonora constituye un serio problema en las ciudades modernas. Entre las diferentes fuentes de ruido presentes en una zona urbana, el ruido del tráfico es, indudablemente, la fuente más molesta. Ésta depende de diversos factores influyentes como las características del flujo vehicular y los aspectos arquitectónicos del espacio urbano, todos ellos muy dependientes de las particulares y hábitos locales. Un enfoque para modelar las relaciones acústicas envueltas en estas situaciones es el uso de las Redes Neuronales Artificiales (RNAs). Éstas son básicamente técnicas especiales de regresión no lineal, que permiten relacionar causas y efectos a partir de cierta información para un sistema dado. En este trabajo se propone el uso de una RNA como modelo de predicción sonora. La generación de la red se realiza a partir de datos numéricos obtenidos de un modelo geométrico, implementado en el programa SoundPLAN, para diferentes configuraciones urbanas típicas. Se muestra que el método presenta una gran capacidad para aproximar la relación no lineal de las variables involucradas.

Keywords: Urban noise, Neural Networks, Sound prediction.

Abstract. Noise pollution is a serious problem in modern cities. Among different sources of noise that are present in an urban area, traffic noise is by far the most annoying source. It depends on several influential factors such as the vehicle flow characteristics and the architecture of the urban space, which are very dependent on local features. An approach to modeling the acoustic relationships involved in these situations is the use of Artificial Neural Networks (ANNs). These are basically special non-linear regression techniques, which allow to relate causes and effects from certain information for a given system. This paper proposes the use of an ANN as a sound prediction model. The generation of the network is made from numerical data obtained from a geometric model, implemented in the program SoundPLAN, for different typical urban configurations. It is shown that the method has a great capacity to approximate the non-linear relationship of the variables involved.

1 INTRODUCCIÓN

En los últimos años, el ruido comunitario se ha convertido en un serio problema. En efecto el aumento de la densidad poblacional y la multiplicación de actividades, han incrementado en forma notable las fuentes de ruido en ambientes habitados. Sin embargo, a juicio de la mayoría de los investigadores, la fuente principal de ruido urbano corresponde al tráfico vehicular (Zannin et al., 2003; Pathak et al., 2008). Para aplicar con éxito planes de acción eficaces que permitan prevenir y reducir la exposición a niveles nocivos de ruido de forma sostenible, primero es necesario obtener información sobre los niveles a los que está expuesta la población (Suarez y Barros, 2014). Por lo tanto, para controlar el nivel sonoro en las zonas urbanas, es muy importante desarrollar métodos para predecir el ruido del tráfico. En tal sentido, los modelos matemáticos constituyen una herramienta de gran utilidad. En general, estos modelos se corresponden con fórmulas semi-empíricas, basadas en técnicas de regresión lineal, que predicen el nivel de ruido a partir de un número determinado de variables asociadas al tráfico. Un compendio crítico de los más utilizados se presenta en los trabajos de Quartieri et al. (2009) y Garg y Maji (2014). Asimismo, dichos modelos suelen ser implementados en programas computacionales, basados en la técnica de trazado de rayos, como por ejemplo SoundPLAN (Guarderas Rosales, 2011).

Muchas veces, debido a la complejidad de la situación que se quiera representar, los modelos clásicos de predicción pueden resultar limitados para explicar las relaciones entre el entorno y las fuentes sonoras involucradas. Además, los enfoques numéricos asociados pueden presentar un alto costo computacional en función de la complejidad acústica de las situaciones a evaluar. Esto puede ser una desventaja si se pretende analizar computacionalmente diversas estrategias de mitigación del impacto sonoro en la zona de interés.

Un enfoque alternativo en estos casos es el uso de *metamodelos* generados a partir de la técnica de Redes Neuronales Artificiales (RNAs). Los metamodelos son, en general, elaborados a partir de valores obtenidos experimentalmente o datos simulados por técnicas computacionales robustas (Kleijnen, 1987). De esta manera, el problema presentado consiste en analizar distintas configuraciones urbanas a partir de diferentes variables relacionadas con el flujo vehicular y las características del entorno y obtener estimaciones del nivel de ruido generado. Luego, estos datos se utilizan para ajustar una red neuronal, siendo esta última, básicamente una técnica de regresión no lineal que permiten relacionar las causas y efectos a partir de la información para el sistema dado. La conveniencia de su uso radica en que una vez obtenida la base de datos para las situaciones de interés, es posible establecer un único modelo empírico (tipo caja negra), ajustado a las características propias de los casos analizados, que permite simular cualquier situación intermedia de una manera efectiva y con un costo computacional muy bajo (Fonseca, 2003). En particular, esta metodología ha sido implementada exitosamente por los autores en trabajos previos relacionados con la predicción del ruido en ambientes industriales interiores (Cortínez y Sequeira, 2009; Sequeira y Cortínez, 2011). En ambientes urbanos exteriores, las RNAs se han utilizado como herramientas de predicción sonora contemplando diversas situaciones (Cammarata et al., 1995; Givargis and Karimi, 2010; Nedic et al., 2014; Kumar et al., 2014).

En este trabajo se presenta el desarrollo y aplicación de un metamodelo basado en una RNA para la predicción del ruido del tráfico en un sector urbano virtual. Los datos para la generación y entrenamiento de la red se obtienen numéricamente a partir de un modelo computacional, implementado en el programa SoundPLAN. Luego, se comprueba la eficacia de la red estimando los niveles sonoros para un conjunto de datos no utilizados en la etapa de

entrenamiento. A partir de esto es posible generar una herramienta computacional rápida y precisa para la evaluación del impacto acústico a fin de utilizarse como ayuda a procesos de planificación urbana.

2 METODOLOGÍA

2.1 Generación de los datos y simulación de escenarios

El indicador acústico más adecuado para representar el ruido proveniente del tráfico vehicular es el nivel sonoro continuo equivalente con ponderación A, LAeq, en dBA. Este parámetro representa la media energética del nivel de ruido promediado en el intervalo de tiempo de medición y está directamente vinculado a la sensibilidad del oído humano. Entonces, para predecir el nivel de ruido es necesario conocer la relación funcional entre el nivel equivalente y los parámetros más influyentes. El nivel equivalente depende de varios parámetros tales como la cantidad y tipología del flujo vehicular, sus velocidades y las características geométricas de la calzada y su entorno (Nedic et al., 2014). En particular, en este trabajo se seleccionaron cinco variables: número de vehículos ligeros (VL), número de vehículos pesados (VP), velocidad media del flujo vehicular (V), ancho de la calzada (A) y altura media de edificación (H). Los rangos y valores de dichas variables se adoptaron teniendo en cuenta datos relevados en un estudio previo en la zona del micro-centro de la ciudad de Bahía Blanca, Argentina (Sequeira y Cortínez, 2012). Esto permite contemplar información real de las variables de estudio. En la Tabla 1 se muestra los rangos adoptados.

Los niveles sonoros (LAeq) se simularon, a partir de las variables definidas anteriormente, empleando el modelo de cálculo de ruido de tráfico francés NMPB Routes-96 (Wallstrom, 2003; Quartieri et al., 2009). Los motivos de su elección se deben principalmente a que dicho modelo ha mostrado un buen comportamiento en ciudades sudamericanas (Ausejo, 2009; Sequeira y Cortínez, 2012). Este modelo se resolvió utilizando el método de trazado de rayos implementado en el programa comercial SoundPLAN.

Para la confección de los distintos escenarios, se consideraron diferentes flujos vehiculares (emulando distintas franjas horarias) y se adoptaron tres tipos de vías de comunicación: avenidas, calles principales y calles secundarias (semi-peatonales). Éstas permitieron definir diferentes velocidades medias del flujo y anchos de calzada. A partir de esto, se estimaron un total de 140 valores del LAeq en 52 puntos receptores distribuidos en una zona urbana virtual de aproximadamente 0.8 km². Se eliminó la separación entre edificios que forman una misma manzana urbana y se contemplaron diferentes alturas medias para cada una de ellas. Los espacios verdes (plazas), considerados dentro de la zona de estudio, están caracterizados por una absorción promedio superficial correspondiente a vegetación. En la Figura 1 se observa un esquema de la zona urbana simulada y los puntos receptores (en color amarillo).

	Vehículos livianos (VL) [veh./h]	Vehículos pesados (VP) [veh./h]	Velocidad media (V) [km/h]	Ancho calle (A) [m]	Altura media edificación (H) [m]	LAeq [dBA]
Máximo	1500	50	60	18	20	76.6
Mínimo	50	0	30	5	5	60.1

Tabla 1: Rango de las variables de estudio.



Figura 1: Esquema del sector urbano simulado y distribución de los puntos receptores.

3 MODELO DE RED NEURONAL

3.1 Conceptos básicos

Una red neuronal artificial es un modelo matemático capaz de emular el comportamiento de las neuronas biológicas y manejar las imprecisiones e incertidumbres que aparecen cuando se trata de resolver problemas relacionados con el mundo real ofreciendo soluciones robustas y de fácil implementación (Bishop, 1995). Su capacidad de aprendizaje a través de ensayos repetidos, las ha hecho muy populares en distintas ramas de la ingeniería como herramientas de predicción para variados problemas (Paliwal y Kumar, 2009).

Su estructura se compone básicamente de tres partes. En primer lugar, se encuentran las entradas a la neurona donde cada una es ponderada mediante unos coeficientes denominados pesos sinápticos (equivalentes a la eficiencia sináptica de una neurona biológica). Dichos coeficientes permiten que la red adquiera conocimiento, otorgando diferentes grados de importancia a cada uno de los elementos de las entradas. Luego, las entradas ponderadas se suman generando una función a la que es posible adicionarle un valor umbral. Esto es lo que se denomina la regla de propagación. Finalmente, la función lineal resultante pasa a través de otra función conocida como función de activación, generando la salida de la neurona (Haykin, 1999). En la Figura 2 se muestra un diagrama del modelo de una neurona artificial, con cada una de las partes mencionadas.

Desde el punto de vista matemático, el modelo de la neurona se describe a partir de las siguientes ecuaciones:

$$u_k = \sum_{i=1}^n w_{ki} X_i + b_k, \quad (1)$$

$$Y_k = g(u_k), \quad (2)$$

donde X_i representa la entrada i (donde $i = 1, \dots, n$); w_{ki} son los pesos que representan la intensidad de interacción entre cada entrada i y la neurona k ; b_k es el valor umbral; u_k es la función lineal para la neurona k ; Y_k es la salida de la neurona k ; $g(\cdot)$ es la función de activación y Y_k representa la salida de la red. Existen diferentes funciones de activación, las cuales deben ser diferenciables y cuya elección depende del tipo de implementación. En este trabajo, se utilizó la función sigmoïdal la cual se expresa de la siguiente manera:

$$g(u) = \frac{1}{1 + e^{-u}}. \quad (3)$$

Es importante destacar que el número de capas ocultas y su tamaño son parámetros a determinar según el tipo de problema a resolver, ya que no existe una única metodología que permita obtener la estructura más adecuada. En general, es posible recurrir a la experiencia basada en problemas similares o, en la mayoría de los casos, es necesario realizar varias pruebas con diferentes configuraciones de estructuras para definir la más correcta. En general, si hay muy pocas neuronas en las capas ocultas, la red no podrá captar adecuadamente las señales de las neuronas de entrada. Por otro lado, demasiadas neuronas en las capas ocultas pueden resultar en un sobre-ajuste del modelo.




Figura 2: Modelo de una neurona artificial.

Una vez definida la estructura de la RNA, el siguiente paso consiste en entrenar la misma a partir de un algoritmo que permita obtener un modelo que ajuste lo mejor posible los datos de salida. El objetivo del entrenamiento es ajustar los pesos de la RNA, de manera tal que a partir de una cierta entrada, la salida generada sea lo más parecida a la salida verdadera. En tal sentido, la RNA trata de encontrar un modelo al proceso desconocido que generó la salida. Luego de finalizado el entrenamiento, se comprueba la eficiencia de la red a partir de la modelación de un conjunto de datos de entrada, para los cuales no se conocen los valores de salida. Obviamente, estos valores no deben haber sido utilizados en la fase de entrenamiento.

3.2 Estructura y características del modelo de red elegido

En este trabajo se utilizó una red neuronal multicapa compuesta por cinco neuronas de entrada: VL, VP, V, A y H (ver sección 2.1); una capa oculta con 10 neuronas y una neurona de salida correspondiente al valor del LAeq. En la Figura 3 se muestra el esquema de la RNA elegida.

El conjunto total de datos simulados (140 muestras) se dividió en tres sub-conjuntos: grupo de aprendizaje (87 muestras), de validación (21 muestras) y de verificación (32 muestras). Los dos primeros grupos se utilizaron para entrenar la red. El grupo de aprendizaje permite estimar

los parámetros (pesos) de la red, mientras que el grupo de validación se utiliza para estimar el error de generalización, es decir, la tasa de predicción incorrecta con datos diferentes a los utilizados en el proceso de aprendizaje. Como el objetivo final es lograr un error de generalización pequeño, entonces se entrenará la RNA hasta que alcance un mínimo de dicho error de validación. Es por ello que se toma como criterio de finalización del entrenamiento la tendencia ascendente del error de validación evitando posibles efectos de sobreentrenamiento. Luego, para estimar la capacidad de predicción del modelo de red neuronal se utiliza el grupo de datos de verificación, los cuales no fueron utilizados durante la etapa de entrenamiento de la red.

El enfoque empleado más habitual consiste en dividir arbitrariamente el conjunto total de datos. En este trabajo los subconjuntos están formados por una selección aleatoria de medidas, teniendo cuidado que los datos de verificación no estén fuera del rango de los datos utilizados para el entrenamiento.




Figura 3: Estructura propuesta del modelo de red neuronal para la predicción del LAeq.

El entrenamiento de la RNA se realizó a través de un aprendizaje supervisado mediante el algoritmo de retro-propagación del error, utilizando la técnica de optimización Levenberg-Marquardt (Bishop, 1995). En el proceso se comienza considerando los pesos sinápticos de manera aleatoria y a partir del vector de entrada se propaga la señal a través de todas las capas intermedias, hasta generar una estimación de las salidas. Luego, estas salidas se comparan con las deseadas obteniéndose un error, que se utiliza para ajustar los pesos de la red. Dicho ajuste comienza en la capa de salida y continuando de atrás hacia delante, hasta llegar a la capa de entrada. Este proceso se realiza de manera iterativa, a los efectos de que la salida de la red se aproxime cada vez más a la deseada, hasta llegar a un estado estable donde la red es capaz de

establecer una relación funcional dentro de un error objetivo prefijado. Para cuantificar este error se utiliza el error cuadrático medio MSE (*Mean Square Error*) definido como:

$$MSE = \frac{1}{N} \sum_{i=1}^N e_i^2, \quad (4)$$

donde N es el número total de muestras y e_i representa la diferencia entre los valores simulados y estimados del LAeq para cada muestra.

La simulación se realizó utilizando el toolbox de redes neuronales implementado en el programa MATLAB.

4 RESULTADOS

En las Figuras 4(a) y (b) se observan la comparaciones de los valores del LAeq simulados (SoundPLAN) y aquéllos estimados mediante el modelo de RNA para el conjunto de datos de entrenamiento y verificación, respectivamente. Las Figuras 5(a) y (b) presentan dichas comparaciones en función de los diagramas de dispersión de regresión lineal para el conjunto de datos de entrenamiento y verificación, respectivamente. Es posible apreciar que existe un muy buen ajuste entre los datos simulados y estimados para ambos conjuntos de datos. Además, para cuantificar el error entre los valores simulados y estimados, se presentan los siguientes estimadores estadísticos: el error máximo absoluto MAE (*Maximum Absolute Error*), la raíz del error cuadrático medio RMSE (*Root Mean Square Error*) y el coeficiente de determinación R^2 . En la Tabla 2 se observa dicha información.

A partir de los resultados se puede observar la gran capacidad del modelo de red neuronal para aproximar la relación no lineal entre las características del flujo vehicular y su entorno y el nivel de ruido generado.

Etapa	MAE	RMSE	R^2
Entrenamiento	0.98	0.17	0.997
Verificación	0.92	0.44	0.991

Tabla 2: Eficacia de predicción del modelo de la RNA.




Figura 4: Comparación del LAeq simulado y estimado. (a) Conjunto de datos de entrenamiento. (b) Conjunto de datos de verificación.

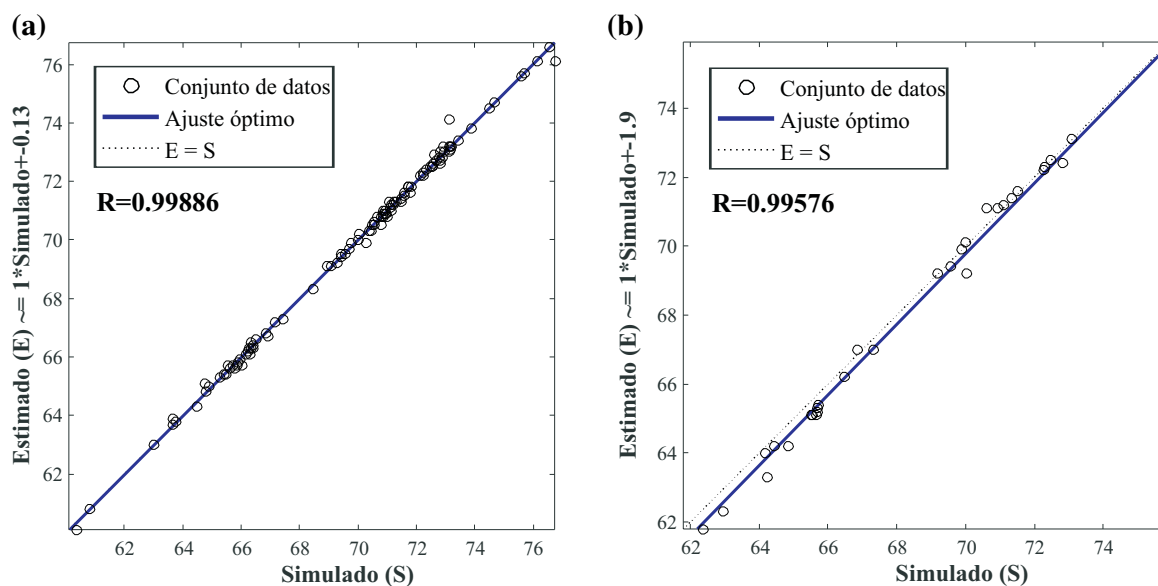


Figura 5: Diagramas de regresión lineal del LAeq simulado (S) y estimado (E). (a) Conjunto de datos de entrenamiento. (b) Conjunto de datos de verificación.

5 CONCLUSIONES Y TRABAJO A FUTURO

En este trabajo se ha desarrollado un modelo de red neuronal para predecir el nivel sonoro a partir de distintos parámetros relacionados con las características del flujo vehicular y de la geometría de las vías de comunicación. Estos datos se obtuvieron contemplando diferentes escenarios virtuales mediante la utilización de un modelo robusto de trazado de rayos implementado en el programa SoundPLAN. El metamodelo resultante ha demostrado una alta capacidad de predicción del nivel sonoro al considerar datos no utilizados durante la etapa de entrenamiento.

Como trabajo a futuro, sería importante implementar esta metodología en un ambiente urbano real, a partir del relevamiento *in situ* de las características del flujo vehicular y del entorno circundante, de manera tal de lograr relacionar las particularidades locales con el nivel de ruido existente. Actualmente, los autores están trabajando en esta dirección.

AGRADECIMIENTOS

Los autores agradecen el apoyo de la Secretaría de Ciencia y Tecnología de la Universidad Tecnológica Nacional, del departamento de Ingeniería de la Universidad Nacional del Sur y de CONICET.

REFERENCIAS

- Ausejo Prieto, M., Estudio de la valoración, errores e incertidumbres en la elaboración de mapas de ruido, Tesis Doctoral, Universidad politécnica de Madrid, España, 2009.
- Bishop, C.M., Neural Network for pattern recognition, Oxford, U.K., Oxford Univ. Press, 1995.
- Cammarata, G., Cavalieri, S., Fichera, A., A neural network architecture for noise prediction. *Neural Networks*, 8(6), 963-973, 1995.

- Cortínez, V.H., Sequeira, M.E. Un enfoque híbrido para el rediseño acústico óptimo de recintos industriales, *Mecánica Computacional*, 28, 39-61, 2009.
- Fonseca, D.J., Navarrese, D.O., Moynihan, G.P., Simulation metamodeling through artificial neural networks. *Engineering Applications of Artificial Intelligence*, 16(3), 177-183, 2003.
- Garg, N., Maji, S., A critical review of principal traffic noise models: Strategies and implications. *Environmental Impact Assessment Review*, 46, 68-81, 2014.
- Givargis, S., Karimi, H., A basic neural traffic noise prediction model for Tehran's roads. *Journal of Environmental Management*, 91(12), 2529-2534, 2010.
- Guarderas Rosales, J.E., Evaluación de modelos de predicción de ruido de tráfico aplicados a la ciudad de Quito mediante el software Soundplan 6.3, Bachelor's thesis, Quito: Universidad de las Américas, 2011.
- Haykin, S., *Neural Networks. A Comprehensive Foundation*. 2nd edition. Prentice-Hall, 1999.
- Kleijnen, J.P.C, *Statistical Tools for Simulation Practitioners*, Marcel Dekker, 1987.
- Kumar, P., Nigam, S.P., Kumar, N., Vehicular traffic noise modeling using artificial neural network approach. *Transportation Research Part C: Emerging Technologies*, 40, 111-122, 2014.
- Nedic, V., Despotovic, D., Cvetanovic, S., Despotovic, M., Babic, S. Comparison of classical statistical methods and artificial neural network in traffic noise prediction. *Environmental Impact Assessment Review*, 49, 24-30, 2014.
- Paliwal, M., Kumar, U.A., Neural networks and statistical techniques: a review of applications. *Expert Systems with Applications* 36(1), 2-17, 2009.
- Pathak, V., Tripathi, B.D., kumar Mishra, V., Evaluation of traffic noise pollution and attitudes of exposed individuals in working place. *Atmospheric Environment*, 42(16), 3892-3898, 2008.
- Quartieri, J., Mastorakis, N.E., Iannone, G., Guarnaccia, C., D'ambrosio, S., Troisi, A., Lenza, T.L.L., A review of traffic noise predictive models. In Recent Advances in Applied and Theoretical Mechanics, 5th WSEAS International Conference on Applied and Theoretical Mechanics (MECHANICS'09) Puerto De La Cruz, Tenerife, Canary Islands, Spain December, 14-16, 2009.
- Sequeira, M.E., Cortínez, V.H., Optimal acoustic design of industrial buildings by means of a hybrid model. In Proceedings of the 18th International Congress on Sound and Vibration (ICSV18). Formato digital, 2011.
- Sequeira, M.E., Cortínez, V.H., Estudio acústico de la ciudad de Bahía Blanca mediante un modelo computacional. *Mecánica Computacional*, 31, 4057-4080, 2012.
- Suarez, E., Barros, J., Traffic noise mapping of the city of Santiago de Chile. *Science of the Total Environment*, 466,539-546, 2014.
- Wallstrom M., Guidelines on the revised interim computation methods for industrial noise, aircraft noise, road traffic noise and railway noise, and related emission data. *Official Journal of the European Union*, 2003.
- Zannin, P.H., Calixto, A., Diniz, F.B., Ferreira, J.A., A survey of urban noise annoyance in a large Brazilian city: the importance of a subjective analysis in conjunction with an objective analysis. *Environmental Impact Assessment Review*, 23(2), 245-255, 2003.