

## ESTIMACIÓN DE LA COMPOSICIÓN TEMPORAL Y ESPECTRAL DEL RUIDO DE TRÁFICO EN LA CIUDAD DE BAHÍA BLANCA MEDIANTE UN MODELO DE RED NEURONAL

### ESTIMATION OF THE TEMPORAL AND SPECTRAL COMPOSITION OF TRAFFIC NOISE IN THE CITY OF BAHÍA BLANCA USING A NEURAL NETWORK MODEL

Martín E. Sequeira<sup>a</sup>, Adrián P. Azzurro<sup>a</sup>, Lucas E. Di Giorgio<sup>a</sup> y Pablo G. Girón<sup>b</sup>

<sup>a</sup>*Centro de Investigaciones en Mecánica Teórica y Aplicada, Universidad Tecnológica Nacional,  
Facultad Regional Bahía Blanca, 11 de Abril 461, Bahía Blanca, Argentina,  
martins@frbb.utn.edu.ar, azzurro@frbb.utn.edu.ar, ldigiorgio@frbb.utn.edu.ar  
<http://www.frbb.utn.edu.ar>*

<sup>b</sup>*Departamento de Ingeniería Mecánica, Universidad Tecnológica Nacional, Facultad Regional  
Bahía Blanca, Argentina, pgiron@frbb.utn.edu.ar*

**Palabras clave:** Ruido de tráfico, Variación temporal, Variación espectral, Redes neuronales.

**Resumen.** En los ambientes comunitarios existe una gran variedad de fuentes sonoras y espacios, los cuales generan una diversidad de situaciones acústicamente relevantes. En particular, el tráfico rodado es considerado la principal fuente urbana de contaminación sonora. Para explicar adecuadamente como percibe la población el ambiente sonoro, es necesario no solo estimar los niveles globales de exposición sino también caracterizar la estructura temporal y espectral del paisaje acústico. Desde el punto de vista predictivo, el problema es complejo debido a las relaciones no lineales entre las variables involucradas. En este trabajo se propone un modelo de red neuronal artificial para predecir la composición temporal y espectral de los niveles sonoros originada por el tráfico vehicular en la zona céntrica de la ciudad de Bahía Blanca (Argentina). El modelo resultante, ajustado a partir de mediciones in situ, permite incorporar información relevante para evaluar de manera más efectiva las características físicas del nivel sonoro en ambientes urbanos.

**Keywords:** Traffic Noise, Temporal variation, Spectral variation, Neural Networks.

**Abstract.** In community environments there is a great variety of sound sources and spaces, which generate a diversity of acoustically relevant situations. In particular, road traffic is considered the main urban source of noise pollution. To adequately explain how the population perceives the sound environment, it is necessary not only to estimate the overall exposure levels but also to characterize the temporal and spectral structure of the acoustic landscape. From the predictive point of view, the problem is complex due to the non-linear relationships between the variables involved. In this paper, a neural network model is proposed to predict the temporal and spectral composition of sound levels originated by traffic in the downtown area of the city of Bahía Blanca (Argentina). The resulting model, deduced from in situ measurements, allows incorporating relevant information to effectively evaluate the physical characteristics of the sound level in urban environments.

## 1 INTRODUCCIÓN

Una de las principales fuentes de polución urbana se corresponde con el ruido originado por el tráfico rodado. Si bien existen diversos modelos matemáticos que permiten estimar el impacto sonoro causado por el flujo vehicular (Garg y Maji, 2014), éstos no pueden generalizarse fácilmente debido a las variadas condiciones locales de cada escenario analizado. En tal sentido, las diferentes tipologías vehiculares asociadas a las configuraciones urbanas no solo generan niveles sonoros globales heterogéneos sino que también provocan diferencias importantes en la estructura temporal y espectral del paisaje acústico. Evaluar correctamente estas características, especialmente la emisión en distintos rangos de frecuencia, es crucial dada la íntima relación existente entre la naturaleza del ruido, la calidad de vida de la comunidad y las posibles medidas de mitigación a implementar (Wang et al., 2016). Los aspectos mencionados posicionan a la predicción de ruido de origen vehicular como un problema complejo y no lineal.

En este contexto, una alternativa es el uso de las redes neuronales artificiales (RNAs). Una RNA es un modelo matemático, inspirado en el sistema nervioso, que permite relacionar un gran conjunto de datos a partir del aprendizaje sin necesidad de conocer la relación física entre las variables involucradas. Esta característica convierte a la RNA en una herramienta robusta y simple de predicción para variados problemas complejos en diferentes campos de aplicación (Paliwal y Kumar, 2009). En particular, se ha utilizado exitosamente en diversos estudios relacionados con la estimación de ruido urbano (Torija et al., 2012; Kumar et al., 2014; Nourani et al., 2020).

El presente artículo expone el desarrollo de un modelo de predicción, basado en una RNA, que permite estimar los niveles sonoros globales y las características temporales y espectrales generadas por el tráfico vehicular en la zona céntrica de la ciudad de Bahía Blanca, Argentina. El modelo resultante incorpora información adicional, en relación a otro estudio publicado recientemente (Sequeira et al., 2021), permitiendo evaluar de manera más efectiva las características físicas del nivel sonoro en la zona urbana considerada.

## 2 METODOLOGÍA

### 2.1 Zona de estudio y selección de variables

La ciudad de Bahía Blanca se ubica al sur de la provincia de Buenos Aires (Argentina) y presenta una población aproximada de 300.000 habitantes (Censo 2010, INDEC). Según datos del Registro Nacional de la Propiedad del Automotor, la ciudad tiene un parque automotor de 180.000 vehículos lo que genera un índice por habitante equivalente al de los países más industrializados. Este hecho, sumado a la diversidad de modelos de vehículos existentes en la ciudad, señala la gran dificultad que presenta la caracterización del tráfico rodado y lo posiciona como la principal fuente de ruido urbano.

En este estudio se utilizó la información obtenida en 22 puntos de muestreo, ubicados en la zona céntrica de la ciudad, presentados en un trabajo precedente (Sequeira et al., 2021). En particular, se consideraron entre 3 y 5 mediciones por punto, para diferentes franjas horarias, contemplando un total de 91 muestras. El número total de muestras es inferior al utilizado previamente (Sequeira et al., 2021) dado que algunas mediciones no presentaban registros de información espectral y, por lo tanto, fueron descartadas. Asimismo, se eliminaron los registros de eventos anómalos relacionados o no con el tráfico vehicular. Las mediciones se realizaron con un sonómetro SVANTEK (Svan 958) empleando un tiempo total de 30 minutos por muestra.

En la **Tabla 1** se presentan las variables seleccionadas para el desarrollo del modelo de red neuronal artificial. Las variables de entrada están relacionadas con las características de la morfológica urbana ( $D_{S-B}$ ,  $A$ ,  $H$ ), con la tipología vehicular ( $V_{LIV+MED}$ ,  $V_{PES}$ ,  $V_{MOTOS}$ ) y con la variabilidad temporal del nivel sonoro ( $T_{EST}$ ,  $D-N$ ). Las mismas fueron elegidas a partir de la experiencia en estudios anteriores (Torija et al., 2012; Sequeira et al., 2021). En particular, el parámetro tiempo de estabilización ( $T_{EST}$ ) se define como el tiempo de medición necesario ( $t_i$ ) para que el nivel sonoro equivalente medido  $L_{Aeq,t_i}$  difiera del nivel sonoro equivalente global  $L_{Aeq}$  (del periodo considerado, en este caso 30 minutos) en menos de un valor  $\varepsilon$  establecido (Gaja et al., 2000). En síntesis, el  $T_{EST}$  es el tiempo necesario de medición para que el nivel sonoro se estabilice dentro del rango  $\varepsilon$ , y que el valor medido sea representativo del tiempo tomado como referencia. En este trabajo, se consideró un valor de  $\varepsilon = \pm 1$  dBA (Gaja et al., 2000; Torija et al., 2011). El parámetro periodo del día ( $D-N$ ), contempla dos franjas horarias: Día (de 9 a 22 h) y Noche (de 22 a 24 h).

Las variables de salida se corresponden con el nivel sonoro equivalente global  $L_{Aeq}$  y con parámetros que permiten caracterizar la composición temporal y espectral del ruido. Respecto a la variación temporal, se utilizó el indicador Varianza Temporal del Nivel Sonoro (*Temporal Sound Level Variance, TSLV*). Este indicador se define como el grado de variabilidad temporal sonora resultante de la combinación de la variabilidad del nivel sonoro instantáneo y del nivel sonoro equivalente para un intervalo de tiempo dado (Torija et al., 2012). Se calcula como el producto entre el desvío estándar del nivel sonoro instantáneo  $\sigma_L$  y el desvío estándar del nivel sonoro equivalente  $\sigma_{eq}$  ( $TSLV = \sigma_L \times \sigma_{eq}$ ). Respecto a la variación espectral, se consideró el nivel sonoro global (promediado) en los rangos de bandas de octava de frecuencias bajas  $L_{31,5-125}$  Hz (31,5, 63, 125 Hz), de frecuencias medias  $L_{250-1000}$  Hz (250, 500, 1000 Hz) y de frecuencias altas  $L_{2000-16000}$  Hz (2000, 4000, 8000, 16000 Hz).

	Variable	Nomenclatura	Máximo	Mínimo
Entrada	Distancia punto medición - borde de calle [m]	$D_{S-B}$	3,15	1,25
	Ancho de calle [m]	$A$	15,0	6,5
	Altura promedio de edificios [m]	$H$	15,0	4,0
	Volumen de vehículos livianos y medianos por hora [vph]	$V_{LIV+MED}$	1388	40
	Volumen de vehículos pesados por hora [vph]	$V_{PES}$	110	0
	Volumen de motos por hora [vph]	$V_{MOTOS}$	180	0
	Tiempo de estabilización [min]	$T_{EST}$	22,4	0,58
	Periodo del día (Día - Noche)	$D-N$	Día (0) - Noche (1)	
Salida	Nivel sonoro equivalente [dBA]	$L_{Aeq}$	74,5	56,8
	Varianza Temporal del Nivel Sonoro [dB <sup>2</sup> ]	$TSLV$	17,5	1,90
	Nivel sonoro global en el rango de frecuencias 31,5 - 125 Hz [dB]	$L_{31,5-125}$ Hz	85,9	71,5
	Nivel sonoro global en el rango de frecuencias 250 - 1000 Hz [dB]	$L_{250-1000}$ Hz	76,0	59,3
	Nivel sonoro global en el rango de frecuencias 2000 - 16000 Hz [dB]	$L_{2000-16000}$ Hz	68,0	49,8

Tabla 1: Variables de entrada y salida del modelo de RNA.

Es importante destacar que la correcta selección de los variables de entrada a utilizar en el modelo de red es una cuestión fundamental para lograr resultados aceptables. En este sentido,

se realizó un análisis de sensibilidad neuronal para determinar la relación y la importancia relativa de los parámetros de entrada en la estimación de las variables de salida. La aplicación de esta metodología se presenta en la sección 3.1.

## 2.2 Modelo de Red Neuronal Artificial

Debido a su popularidad y gran desempeño, en este trabajo se utilizó una red de alimentación hacia adelante tipo perceptron multicapa y el entrenamiento se realizó a través de un aprendizaje supervisado mediante el algoritmo de retro-propagación del error (Haykin, 1999). Esta red está conformada por neuronas que se encuentran interconectadas y organizadas en tres capas. La primera capa contiene las variables de entrada y la última las de salida. La capa oculta contiene las neuronas que conforman las unidades básicas de procesamiento de la información. Los datos provenientes de la capa de entrada son ponderados por unos pesos (coeficientes de conexión de la red) que vinculan las neuronas de las capas ocultas con las neuronas de la capa de salida. Estos pesos modulan el efecto de las señales de entrada asociadas (otorgando diferentes grados de importancia a cada uno de los elementos del vector de información), y las características no lineales que presentan las neuronas se representan mediante una función de transferencia. Entonces, el impulso de la neurona se calcula como la suma ponderada de las señales de entrada, transformadas por la función de transferencia. Luego, el resultado de esta función se envía a cada neurona de la capa de salida donde se obtiene la respuesta del sistema. Se eligió la función de transferencia sigmoidea para la capa oculta, y la transferencia lineal para la capa de salida.

La capacidad de aprendizaje de la red se consigue ajustando los pesos, de acuerdo con el algoritmo de aprendizaje mencionado, a partir de minimizar una función cuadrática de los errores entre la salida objetivo y la salida estimada, para el tamaño de muestras establecido. Así, la RNA es un sistema adaptativo que puede aprender la relación a través de la presentación repetida de datos y es capaz de generalizar a nuevos datos no contemplados previamente (Kumar et al., 2014). En particular, se utilizó la técnica de optimización de Levenberg-Marquardt para actualizar los pesos en el algoritmo de retro-propagación del error (Bishop, 1995).

En la etapa de entrenamiento, se pueden presentar problemas de sobre-entrenamiento, donde se genera una respuesta inadecuada de la red ante datos de entrada diferentes a los que se utilizaron para este proceso. Para minimizar este fenómeno, se utilizó la técnica de regularización correspondiente al método de validación cruzada (Bishop, 1995) que consiste en dividir los datos de entrenamiento en dos partes, una parte se utiliza como conjunto de aprendizaje para ajustar los pesos y, la otra parte (conjunto de validación) se emplea para estimar el error de generalización, es decir, la tasa de predicción incorrecta con datos diferentes a los utilizados en el proceso de aprendizaje. Entonces, se entrena la RNA hasta que alcance un mínimo de dicho error y luego, para evaluar la capacidad de predicción del modelo, se utiliza un conjunto de datos de testeo no contemplado en la etapa de entrenamiento. En tal sentido, el conjunto total de 91 muestras se dividió en tres sub-conjuntos: grupo de aprendizaje con 64 muestras, de validación con 11 muestras y de testeo con 16 muestras. Para la generación y evaluación del modelo de RNA se utilizó el toolbox correspondiente implementado en el programa MatLab.

### 3 RESULTADOS

#### 3.1 Análisis de sensibilidad de las variables

Se realizó un análisis de sensibilidad, basado en una red neuronal de una sola entrada y una sola salida, para establecer la importancia relativa de las variables de entrada con respecto a cada uno de los parámetros objetivos del estudio (Nourani et al., 2020). En este análisis, cada variable de entrada se impuso de forma independiente en un modelo de RNA para estimar cada una de las salidas sin tener en cuenta la influencia de las variables de entrada restantes. El rendimiento de los modelos se cuantificó mediante la raíz del error cuadrático medio (Root Mean Square Error, RMSE) para el conjunto de datos de testeo. Entonces, para cada variable de salida, la importancia de la entrada disminuye a medida que aumenta el valor de RMSE, siendo la más significativa la que presenta el menor valor del error. En la [Tabla 2](#) se muestran los resultados obtenidos.

Variable de salida	RMSE (Variable de entrada)							
	$D_{S-B}$	$A$	$H$	$V_{LIV+MED}$	$V_{PES}$	$V_{MOTOS}$	$T_{EST}$	$D-N$
$L_{Aeq}$	2,85	2,46	<b>1,81</b>	<b>1,52</b>	1,90	<b>1,53</b>	3,03	3,23
$TSLV$	1,94	1,98	1,92	<b>1,81</b>	1,95	2,14	<b>1,70</b>	<b>1,49</b>
$L_{31,5-125\text{ Hz}}$	1,94	1,63	1,54	<b>1,05</b>	<b>1,34</b>	<b>1,08</b>	2,00	2,21
$L_{250-1000\text{ Hz}}$	2,71	2,40	1,94	<b>1,42</b>	<b>1,87</b>	<b>1,34</b>	2,90	3,19
$L_{2000-16000\text{ Hz}}$	3,19	2,65	<b>2,06</b>	<b>1,83</b>	2,20	<b>1,81</b>	3,38	3,43

Tabla 2: Análisis de sensibilidad del modelo de RNA de una entrada y una salida (en negrita se destacan los 3 valores con menor RMSE para cada variable de salida).

En general, se observa una fuerte dependencia de las variables de entrada relacionadas con el volumen de las tipologías vehiculares (en particular  $V_{LIV+MED}$ ) respecto a todos los parámetros de salida. Además, se observa cierta dependencia entre los parámetros de entrada asociados a la morfología urbana (principalmente  $H$ ) y los niveles sonoros globales para los diferentes rangos de frecuencias. Las variables vinculadas con la variabilidad temporal sonora ( $T_{EST}$  y  $D-N$ ) son las más relevantes para caracterizar el parámetro  $TSLV$ .

De manera adicional, se construyeron modelos de RNA para cada variable de salida, incluyendo, de manera acumulada, cada una de las variables de entrada siguiendo el orden de importancia general obtenido en el análisis de sensibilidad. En cada caso, se evaluó el ajuste logrado a partir del coeficiente de determinación  $R^2$  para el conjunto de datos de testeo. En la [Figura 1](#) se muestra la variación del  $R^2$  del modelo de red para cada variable de salida. Se observa que al añadir, de manera acumulativa, cada variable de entrada en la RNA, el indicador  $R^2$  aumenta gradualmente, en mayor o menor medida, para cada una de las variables de salida. En consecuencia, se asume que todos los parámetros de entrada seleccionados presentan un importante nivel de correlación con respecto a los parámetros objetivos.

#### 3.2 Ajuste del modelo de RNA

La estructura final del modelo de RNA contempla 8 variables de entrada, 9 neuronas en la capa oculta y 5 salidas objetivo. En las [Figuras 2 y 3](#) se exhiben las comparaciones entre los valores de cada parámetro de salida medido y estimado (modelo de RNA) para el conjunto de datos de entrenamiento y testeo, respectivamente. En la [Tabla 3](#) se presenta el desempeño logrado por la RNA, tanto para el conjunto de datos de entrenamiento como de testeo, considerando los estimadores estadísticos RMSE y  $R^2$ . De manera adicional, y a efectos

comparativos, en la **Tabla 3** se muestran los resultados obtenidos por un Modelo de Regresión lineal Múltiple (MRM) para el mismo conjunto de datos.

Se observa un buen ajuste del modelo de RNA. En particular, se aprecia que los indicadores acústicos  $L_{Aeq}$ ,  $L_{31,5-125}$  Hz,  $L_{250-1000}$  Hz y  $L_{2000-16000}$  Hz son estimados con mayor precisión en relación al parámetro  $TSLV$ , el cual presenta un nivel de precisión ligeramente menor. Por otro lado, el modelo de RNA presenta un rendimiento superior al MRM en la estimación de todos los parámetros de salida, especialmente al considerar el parámetro  $TSLV$ .

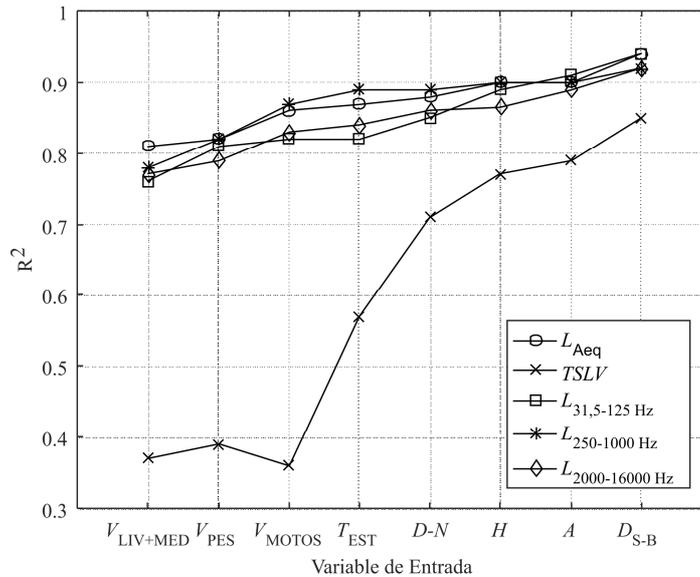


Figura 1: Variación del  $R^2$  en la estimación de cada variable de salida ( $L_{Aeq}$ ,  $TSLV$ ,  $L_{31,5-125}$  Hz,  $L_{250-1000}$  Hz y  $L_{2000-16000}$  Hz) en función de la incorporación acumulativa de las 8 variables de entrada en el modelo de RNA.

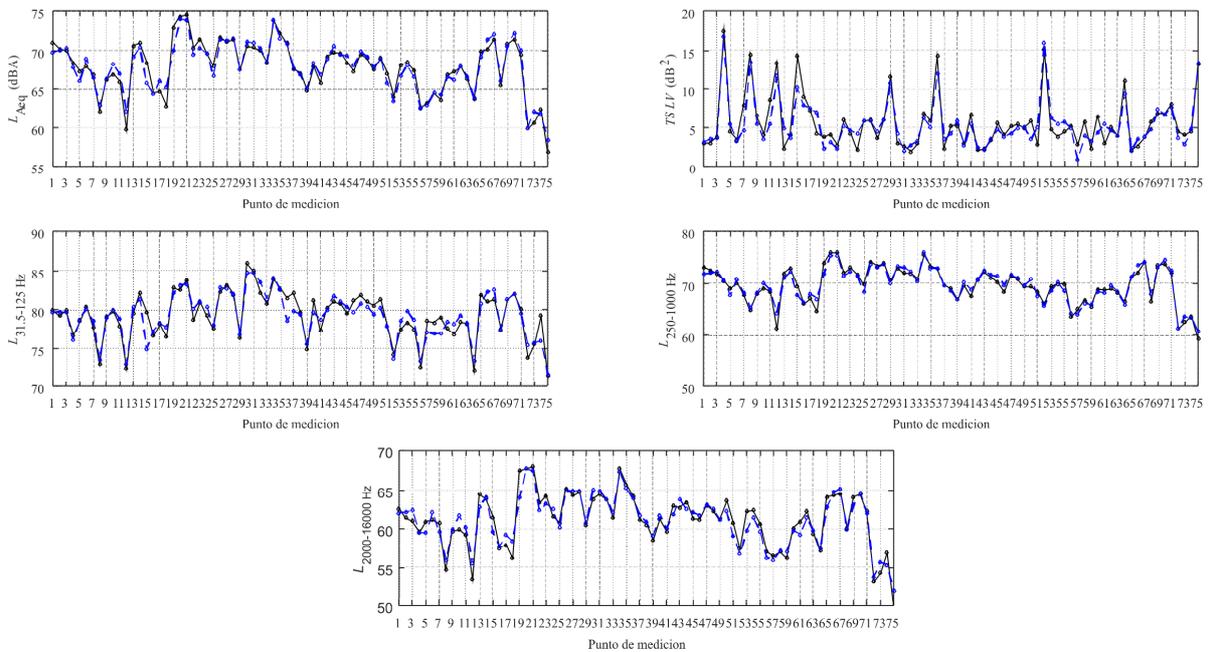


Figura 2: Comparación de las variables de salida medidas (—●—) y estimadas (---●---) para el conjunto de datos de entrenamiento.

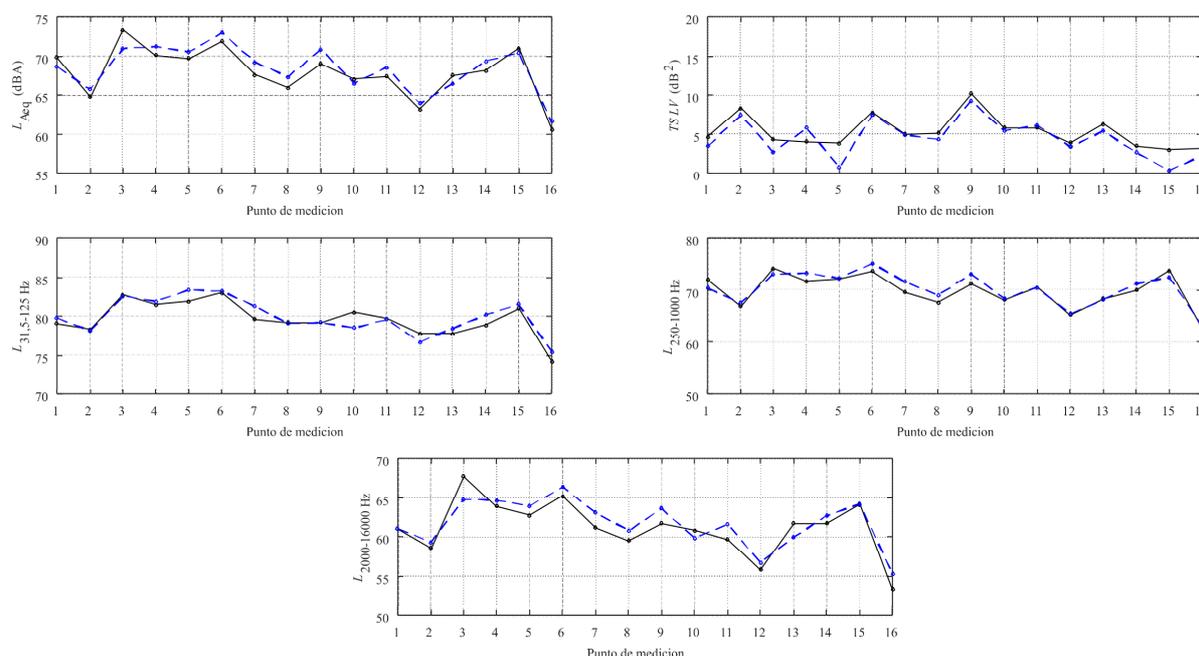


Figura 3: Comparación de las variables de salida medidas (—●—) y estimadas (---●---) para el conjunto de datos de testeo.

Indicadores acústicos	Conjunto entrenamiento				Conjunto Testeo			
	RNA		MRM		RNA		MRM	
	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>
$L_{Aeq}$ (dBA)	0,91	0,93	2,04	0,73	1,24	0,86	2,42	0,63
$TSLV$ (dB <sup>2</sup> )	1,31	0,86	2,59	0,32	1,35	0,81	3,33	0,23
$L_{31,5-125}$ Hz (dB)	1,16	0,85	1,87	0,62	0,95	0,83	2,15	0,65
$L_{250-1000}$ Hz (dB)	0,88	0,94	2,02	0,74	1,18	0,88	2,37	0,64
$L_{2000-16000}$ Hz (dB)	1,04	0,91	2,07	0,72	1,48	0,84	2,09	0,62

Tabla 3: Desempeño del modelo de RNA.

#### 4 CONCLUSIONES

Se desarrolló un modelo de red neuronal artificial para estimar los valores globales y las características temporales y espectrales del nivel de ruido generado por el tráfico rodado en la zona céntrica de la ciudad de Bahía Blanca. Para ello, se contemplaron distintos parámetros de entrada relacionados con la geometría de las calles, la tipología vehicular y la fluctuación temporal del nivel sonoro. Los resultados mostraron que todas las variables de entrada presentan cierto grado de correlación respecto a los parámetros objetivos adoptados. Finalmente, el modelo de red propuesto consigue predecir, de manera adecuada, la composición temporal ( $TSLV$ ) y espectral ( $L_{31,5-125}$  Hz,  $L_{250-1000}$  Hz,  $L_{2000-16000}$  Hz) así como el nivel sonoro global ( $L_{Aeq}$ ), logrando caracterizar de manera más acabada la zona de estudio y permitiendo generar una herramienta complementaria para los procesos de planificación en la ciudad.

Como actividad a futuro, sería interesante extender el modelo contemplando parámetros asociados a otros paisajes acústicos de la ciudad, con características diferenciadas, como son los espacios públicos de esparcimiento y zonas residenciales-industriales donde coexisten diversos tipos de fuentes sonoras.

## AGRADECIMIENTOS

Los autores agradecen el apoyo de la Secretaría de Ciencia y Tecnología de la Universidad Tecnológica Nacional.

## REFERENCIAS

- Bishop, C.M., *Neural Network for pattern recognition*, Oxford, U.K., Oxford Univ. Press, 1995.
- Gaja Díaz, E., González, E., Reig Fabado, A., Sancho Vivó, S., y Bonet, A.M., Influencia de los anómalos acústicos en el tiempo de estabilización del nivel equivalente horario. In Proceedings of the XXXI Congreso Nacional de Acústica (Tecnacústica 2000), Madrid, Spain, 2000.
- Garg, N., and Maji, S., A critical review of principal traffic noise models: Strategies and implications. *Environmental Impact Assessment Review*, 46:68-81, 2014.
- Haykin, S., *Neural Networks. A Comprehensive Foundation*. 2nd edition. Prentice-Hall, 1999.
- Kumar, P., Nigam, S.P., and Kumar, N., Vehicular traffic noise modeling using artificial neural network approach. *Transportation Research Part C: Emerging Technologies*, 40:111-122, 2014.
- Nourani, V., Gökçekuş, H., Umar, I.K., and Najafi, H., An emotional artificial neural network for prediction of vehicular traffic noise. *Science of the Total Environment*, 707:136134, 2020.
- Paliwal, M., and Kumar, U.A., Neural networks and statistical techniques: a review of applications. *Expert Systems with Applications*, 36(1):2-17, 2009.
- Sequeira, M.E., Cortínez, V.H., y Azzurro, A.P., Un modelo de predicción de ruido de tráfico basado en redes neuronales para la ciudad de Bahía Blanca. *Mecánica Computacional*, 38(7):177-188, 2021.
- Toriya, A.J., Ruiz, D.P., and Ramos-Ridao, Á., Required stabilization time, short-term variability and impulsiveness of the sound pressure level to characterize the temporal composition of urban soundscapes. *Applied Acoustics*, 72(2-3): 89-99, 2011.
- Toriya, A.J., Ruiz, D.P., and Ramos-Ridao, A.F., 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, 2012.
- Wang, V.S., Lo, E.W., Liang, C.H., Chao, K.P., Bao, B.Y., and Chang, T.Y., Temporal and spatial variations in road traffic noise for different frequency components in metropolitan Taichung, Taiwan. *Environmental Pollution*, 219:174-181, 2016.