

UN MODELO DE PREDICCIÓN DE RUIDO DE TRÁFICO BASADO EN REDES NEURONALES PARA LA CIUDAD DE BAHIA BLANCA

A TRAFFIC NOISE PREDICTION MODEL BASED ON NEURAL NETWORKS FOR THE CITY OF BAHÍA BLANCA

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, Bahía Blanca, Argentina, martins@frbb.utn.edu.ar, vcortine@frbb.utn.edu.ar, azzurro@frbb.utn.edu.ar*
<http://www.frbb.utn.edu.ar>

^b*Departamento de Ingeniería, Universidad Nacional del Sur, Alem 1253, 8000 Bahía Blanca, Argentina, <http://www.uns.edu.ar>*

^c*Consejo Nacional de Investigaciones Científicas y Técnicas, <http://www.conicet.gov.ar>*

Palabras clave: Ruido de tráfico, Redes Neuronales Artificiales, Modelos de predicción.

Resumen. El ruido debido al tráfico vehicular es considerado una de las principales fuentes de contaminación ambiental en la mayoría de las ciudades del mundo. Para lograr medidas de mitigación adecuadas frente a este agente contaminante es necesario conocer los niveles de ruido a partir de mediciones in situ o bien predecir su impacto utilizando modelos matemáticos calibrados. Un problema que presentan la mayoría de los modelos de ruido de tráfico existentes es la falta de generalización debida a las múltiples condiciones locales que es posible encontrar en cada caso analizado. En este trabajo se emplea la técnica de Red Neuronal Artificial (RNA) para modelar el ruido de tráfico en la zona céntrica de la ciudad de Bahía Blanca, Argentina. Para ello, se considera información referente a las características del flujo vehicular y del área urbana especificada. Con estos datos se analizan diferentes estructuras de RNAs a efectos de obtener un modelo adecuado para la predicción de los niveles sonoros.

Keywords: Traffic Noise, Artificial Neural Networks, Prediction Models.

Abstract. Road traffic noise is considered one of the main sources of environmental pollution in most cities of the world. In order to implement adequate action plans against this pollutant, it is necessary to know the noise levels from in situ measurements or to predict its impact using calibrated mathematical models. A problem with most of the existing traffic noise models is the lack of generalization due to the multiple local conditions that can be found in each case analyzed. In this work, the Artificial Neural Network (ANN) technique is used to model traffic noise in the downtown area of the city of Bahía Blanca, Argentina. For this purpose, information regarding the characteristics of vehicular flow and the urban area are considered. With these data, different ANN structures are analyzed in order to obtain an adequate model for the prediction of sound levels.

1 INTRODUCCIÓN

El ruido de tráfico es reconocido en la actualidad como una de las mayores fuentes de contaminación en ambientes urbanos. Diferentes investigaciones han señalado que la contaminación sonora originada por esta fuente afecta notoriamente la calidad de vida y la salud de las personas generando una larga serie de efectos psicológicos y fisiológicos de naturaleza muy variada (Pirrer et al., 2010; Basner et al., 2014; Recio et al., 2016). Para aplicar con éxito planes de acción eficaces que permitan reducir la exposición a niveles nocivos de ruido, es necesario desarrollar metodologías que permitan modelar la naturaleza compleja de los niveles sonoros y evaluar como impactan sobre la calidad de vida de la comunidad. En este sentido, los primeros modelos matemáticos de predicción de ruido vehicular se remontan a la década de 1950. Un compendio crítico de algunos de los más utilizados se presenta en los trabajos de Quartieri et al. (2009) y Garg y Maji (2014). La mayoría de estos modelos empíricos están basados en técnicas de regresión lineal y presentan la desventaja que su eficacia y fiabilidad es muy dependiente de la composición y características del tráfico vehicular y de la configuración urbana de las zonas donde fueron originalmente desarrollados.

Un enfoque alternativo es el uso de modelos predictivos basados en la técnica de redes neuronales artificiales (RNAs). La capacidad de esta técnica para manejar un gran número de información a partir del aprendizaje sin necesidad de conocer las relaciones funcionales del sistema analizado, la ha hecho muy popular en distintas ramas de la ingeniería (Paliwal and Kumar, 2009). En el área de predicción de ruido vehicular, diversos estudios fueron abordados exitosamente a partir de establecer relaciones entre distintos indicadores acústicos (niveles sonoros equivalentes, niveles percentiles, clima de ruido) y parámetros asociados al flujo vehicular y al entorno arquitectónico y climático (Cammarata et al., 1995; Parbat y Nagarnaik, 2008; Givargis y Karimi, 2010; Cirianni y Leonardi, 2012; Kumar et al., 2014; Hamad et al., 2017; Nourani et al., 2020).

En este trabajo, se presenta un modelo de RNA para predecir el nivel sonoro originado por el tráfico rodado en la zona céntrica de la ciudad de Bahía Blanca, Argentina. El modelo es calibrado a partir de información relevada in situ relacionada con las características del flujo vehicular y del entorno urbano. Se analizan distintas configuraciones de las variables involucradas a fin de identificar las más relevantes. Adicionalmente, se comparan los resultados del modelo de RNA con aquéllos obtenidos mediante enfoques empíricos comúnmente utilizados en estos casos. Se comprueba que el modelo de RNA resultante presenta una mejor capacidad de predicción relacionada con su habilidad para contemplar las relaciones no lineales entre los parámetros involucrados. El presente trabajo es una extensión de otro publicado recientemente por los autores (Sequeira et al., 2019).

2 ASPECTOS GENERALES DEL ESTUDIO

2.1 Zona analizada y relevamiento de información

La ciudad de Bahía Blanca está localizada al sudoeste de la Provincia de Buenos Aires (Argentina), con una población aproximada de 300.000 habitantes (Censo 2010, INDEC). En torno a la Plaza Rivadavia, centro de esparcimiento más antiguo de la ciudad, se desarrolla la principal actividad comercial, bancaria, institucional y hotelera y es donde se concentra la mayoría de los edificios en altura, conformando la zona céntrica de la ciudad. Según datos del Registro Nacional de la Propiedad del Automotor, el parque automotor en Bahía Blanca es de unos 180.000 vehículos. El índice de 1,6 autos por habitante duplica al del país y es similar al

de los países más industrializados. Además, existe una gran heterogeneidad de modelos de vehículos automotores, lo que implica diferentes criterios de diseño circulando por las calles. Esto último, vinculado con la diversidad del estado de las calles y los hábitos del conductor, genera que el flujo vehicular sea particularmente complejo de caracterizar.

El presente estudio se concentró en la zona céntrica de la ciudad donde se seleccionaron 22 puntos de medición ubicados a mitad de cuadra a fin de contemplar un flujo de tráfico continuo y evitando, en la medida de lo posible, la presencia de fuentes de otros orígenes. En la **Figura 1** se muestra la zona de estudio y la ubicación de los puntos de medición. Se empleó el nivel sonoro continuo equivalente con ponderación A, L_{Aeq} (en dBA), para caracterizar el ruido de tráfico vehicular. La campaña de medición se realizó durante los meses de mayo y diciembre de 2019. Los niveles sonoros se registraron utilizando un sonómetro SVANTEK (Svan 958) ubicado a una altura de 1.5 m sobre el nivel de la vereda y alejado de superficies reflejantes. Las mediciones se efectuaron en días hábiles (de lunes a viernes) considerando diferentes franjas horarias entre las 9 y las 24 h y contemplando entre 4 y 5 mediciones por cada punto de muestreo, logrando un total de 107 muestras. El tiempo de medición para cada muestra fue de 30 minutos.




Figura 1: Foto Satelital de la ciudad de Bahía Blanca (izquierda) y zona de estudio (derecha) con los puntos de medición. Se registraron un total de 107 muestras distribuidas en 22 puntos de medición.

Durante la campaña, se registró el volumen y composición del tráfico vehicular y se adoptaron las siguientes tipologías vehiculares: automóviles (V_{LIV}); camionetas y furgones (V_{MED}); camiones y colectivos (V_{PES}) y motos (V_{MOTOS}). La información recopilada se extrapola para una hora de medición por lo que la cantidad de vehículos se multiplicó por dos para considerar el flujo horario. Se adoptó una velocidad de circulación para automóviles, camionetas, furgones y motos de 60 km/h y para camiones y colectivos de 40 km/h (Sequeira y Cortinez, 2012). Además, se registraron las siguientes características asociadas a la configuración urbana: distancia entre el punto de medición y el borde de la calle (D_{S-B}); ancho de la calle (A); altura promedio de los edificios por cuadra (H) y la razón de aspecto entre el ancho de la calle y la altura promedio de los edificios (R). Estos parámetros fueron seleccionados a partir de la experiencia recabada en estudios similares. Las mediciones se llevaron a cabo con velocidades de viento inferiores a 5 m/s utilizándose un anemómetro marca Testo para verificar esta situación. La información recopilada se sintetiza en la **Tabla 1**.

Variable	Nomenclatura	Máximo	Mínimo	Promedio	Desvío estándar
Nivel sonoro equivalente [dBA]	L_{Aeq}	74,5	59,7	67,6	3,6
Distancia punto medición - borde de calle [m]	D_{S-B}	3,15	1,25	2,13	0,5
Ancho de calle [m]	A	15,0	6,5	10,0	2,2
Altura promedio de edificios [m]	H	15,0	4,0	8,2	2,7
Razón de aspecto entre ancho de calle y altura promedio de edificios	R	5,8	1,3	2,5	1,1
Volumen de vehículos livianos [vph]	V_{LIV}	1214	24	454	264,7
Volumen de vehículos medianos [vph]	V_{MED}	188	0	63	46,7
Volumen de vehículos livianos y medianos [vph]	$V_{LIV+MED}$	1388	40	517	302,1
Volumen de vehículos pesados [vph]	V_{PES}	110	0	15	20,4
Volumen de motos [vph]	V_{MOTOS}	180	0	55	37,4

Tabla 1: Características estadísticas de la información recopilada.

2.2 Análisis exploratorio de los datos

En la [Figura 2](#) se muestran los valores estadísticos (valor promedio, máximo y mínimo) del L_{Aeq} y del flujo vehicular total para las franjas horarias examinadas. En general, se observa una gran similitud en los niveles sonoros en las primeras 4 franjas, donde el L_{Aeq} promedio general es igual a 68,5 dBA. En la franja horaria restante (de 22 a 24 h) el nivel sonoro disminuye aproximadamente 3,5 dBA (L_{Aeq} promedio: 65 dBA). Esta situación está en concordancia con los niveles sonoros medidos en un estudio previo en la ciudad donde se registró un L_{Aeq} promedio día y noche (considerando los mismos periodos horarios) de 70,3 y 66,6 dBA respectivamente ([Sequeira y Cortinez, 2012](#)). Se aprecia una diferencia de aproximadamente 1.5 dBA en cada periodo con respecto al estudio actual.




Figura 2: Valor promedio, máximo y mínimo del L_{Aeq} (izquierda) y del flujo vehicular total (derecha) para distintas franjas horarias.

En referencia al presente estudio, el nivel sonoro continuo equivalente L_{Aeq} varía entre 74,5 y 59,7 dBA. Los valores máximos se registraron principalmente en las franjas horarias de 12 a 14 h y de 16 a 20 h, en calles que sirven de ingreso y/o egreso desde la zona periférica a la zona céntrica de la ciudad. Los valores mínimos se registraron durante la mañana y principalmente a la noche (de 22 a 24 h) en calles secundarias que se utilizan para comunicar calles principales dentro de la zona analizada. Los flujos vehiculares más altos se registraron en inmediaciones de la plaza Rivadavia durante la franja horaria de 12 a 14 h. En esta zona se observaron también los flujos más altos de colectivos. El menor volumen de vehículos/hora (< 100 vph) se observó principalmente en el periodo nocturno en calles secundarias del sector. Por otro lado, se observó una gran heterogeneidad en las características geométricas asociadas a los perfiles de las calles. En particular, los anchos de las calles varían entre 6,5 y 15 m, los anchos de las veredas entre 6,3 y 2,5 m y la altura promedio de los edificios de ambas fachadas entre 4 y 15 m.

3 MODELO DE RED NEURONAL

3.1 Consideraciones generales

Las redes neuronales artificiales son métodos numéricos basados en el comportamiento de las neuronas biológicas. La habilidad de esta técnica radica en que permite detectar relaciones complejas no lineales entre variables con un nivel aceptable de precisión.

Una de las arquitecturas de RNA más utilizada es el Perceptrón multicapa MLP (MultiLayer Perceptron). Consiste en una red de alimentación hacia adelante compuesta por una primera capa de unidades de entrada, otra capa de unidades de salida y un número determinado de capas ocultas. La capa de entrada posee tantas unidades como elementos tenga el vector de información que se va a introducir. La capa de salida tiene tantas neuronas como variables de salida tenga el problema considerado. La información proveniente de la capa de entrada es ponderada por unos coeficientes denominados pesos sinápticos (equivalentes a la eficiencia sináptica de una neurona biológica) que vinculan las neuronas de las capas ocultas con las neuronas de la capa de salida. Dichos coeficientes permiten que la red adquiera conocimiento, otorgando diferentes grados de importancia a cada uno de los elementos del vector de información. Las capas ocultas contienen las neuronas que conforman las unidades básicas de procesamiento de la información. Allí ocurre una operación matemática consistente en la suma de las multiplicaciones de cada dato de información por sus pesos, que será el dato a introducir en la función de activación. Esta última controla la no linealidad del modelo siendo la función sigmoideal la más empleada en este tipo de arquitectura. Finalmente, el resultado de esta función se envía a cada neurona de la capa de salida donde se obtiene la respuesta del sistema (Haykin, 1999). En la Figura 3 se muestra, de manera esquemática, la arquitectura de una RNA tipo MLP con una capa oculta.

Una vez definida la estructura de la RNA, es necesario entrenar la misma a partir de un algoritmo que permita obtener un modelo ajustando los pesos, de manera tal que a partir de una cierta entrada, la salida generada sea lo más parecida a la salida verdadera. Durante la etapa de entrenamiento, la RNA puede presentar problemas de sobre-entrenamiento, caracterizados por una respuesta inadecuada de la red ante datos de entrada diferentes a los datos que se utilizaron para este proceso. Para minimizar este fenómeno, se emplean distintas técnicas de regularización. Una muy utilizada corresponde 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, llamada 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. 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. Luego, para estimar la capacidad de predicción del modelo de red neuronal se utiliza un conjunto de datos de testeo, los cuales no fueron utilizados durante la etapa de entrenamiento.

En este trabajo, se utilizó una arquitectura de red tipo MLP con una única capa oculta y el entrenamiento 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). A fin de implementar la técnica de regularización mencionada, el conjunto total de 107 muestras se dividió en tres sub-conjuntos: grupo de aprendizaje con 72 muestras, de validación con 13 muestras y de testeo con 22 muestras.




Figura 3: Esquema de la arquitectura de la RNA (X_i representan las neuronas de entrada e Y la salida).

3.2 Generación de los modelos de RNA

Es importante destacar que el tamaño de la capa oculta es un parámetro a determinar según el tipo de problema a resolver. Entonces, en general, es necesario realizar varias pruebas con diferentes configuraciones para definir la más adecuada. Por otra parte, la correcta selección de los parámetros de entrada es un factor clave para lograr resultados aceptables. Muchas variables pueden conducir a un sobre-ajuste e incrementar la complejidad del modelo. Por otro lado, un modelo con variables de entrada insuficientes no puede estimar correctamente la salida deseada. En tal sentido, se realizó un análisis de sensibilidad de los parámetros relevados (ver Tabla 1) para determinar la importancia relativa de cada uno de ellos en la estimación del nivel sonoro. Para ello, se empleó una metodología, utilizada exitosamente en otros trabajos (Hamad et al., 2017; Nourani et al., 2020), basada en el coeficiente de determinación R^2 . El análisis se realiza de la siguiente manera: inicialmente se entrenan múltiples modelos de RNAs utilizando todas las variables potenciales de entrada para predecir el L_{Aeq} y se selecciona aquel modelo que presenta el valor más alto de R^2 para el conjunto real de datos de entrenamiento y testeo. Seguidamente, se remueve una variable de entrada del conjunto de entrenamiento y testeo, se entrenan múltiples nuevos modelos de red y se calcula el valor medio modificado de R^2 . Finalmente, se obtiene la diferencia entre el valor medio modificado y el valor real de R^2 y esta información se utiliza para clasificar la

importancia relativa de la variable de entrada. Este procedimiento se repite para cada variable de entrada asociada. La variable más importante es la que produce la mayor disminución del valor real de R^2 .

En este trabajo, se consideraron 4 configuraciones para predecir el nivel sonoro (L_{Aeq}) generado por el tránsito vehicular a partir de contemplar diferentes vectores de entrada. Estos últimos fueron seleccionados mediante combinaciones de todas las tipologías de tráfico rodado y distintos parámetros geométricos relacionados con el perfil de la calles. Las relaciones matemáticas para las diferentes configuraciones se expresan de la siguiente manera:

$$RNA_{\text{configuración1}}: L_{Aeq} = f(D_{S-B}, A, H, V_{LIV}, V_{MED}, V_{PES}, V_{MOTOS})$$

$$RNA_{\text{configuración2}}: L_{Aeq} = f(D_{S-B}, A, H, V_{LIV+MED}, V_{PES}, V_{MOTOS})$$

$$RNA_{\text{configuración3}}: L_{Aeq} = f(D_{S-B}, R, V_{LIV+MED}, V_{PES}, V_{MOTOS})$$

$$RNA_{\text{configuración4}}: L_{Aeq} = f(A, H, V_{LIV+MED}, V_{PES}, V_{MOTOS})$$

Los modelos se resolvieron utilizando el toolbox de redes neuronales implementado en el programa Matlab.

4 RESULTADOS

4.1 Importancia relativa de las variables de entrada

En la [Tabla 2](#) se muestra la clasificación de las variables de entrada una vez realizado el análisis de sensibilidad basado en el indicador R^2 . En general, se observa que todas las variables presentan cierto grado de importancia en la estimación del nivel sonoro ya que la remoción de cada una de ellas genera una reducción en el valor de R^2 . En particular, se muestra que las variables geométricas tiene un grado de importancia relevante. Respecto a los parámetros asociados al flujo vehicular, el volumen de vehículos livianos y medianos ($V_{LIV+MED}$) presenta la mayor importancia dentro del modelo. Los volúmenes de motos (V_{MOTOS}) y vehículos medianos (V_{MED}) muestran el menor efecto relativo sobre el nivel sonoro.

Variable de entrada removida	D_{S-B}	A	H	$V_{LIV+MED}$	R	V_{LIV}	V_{PES}	V_{MOTOS}	V_{MED}
Disminución de R^2 (%)	11,5	11,1	10,1	9,6	9,2	8,9	8,6	8,1	7,5
Clasificación	1	2	3	4	5	6	7	8	9

Tabla 2: Análisis de importancia de las variables según el coeficiente de determinación (R^2 real = 0.954 para el conjunto total de datos).

4.2 Desempeño de los modelos de RNA

Cada una de las configuraciones presentadas en la sección 3.2 se entrenó contemplando entre 4 y 14 neuronas en la capa oculta. Para cuantificar el error entre los valores medidos y estimados del L_{Aeq} , se utilizaron los siguientes estimadores estadísticos: el error máximo absoluto MAE (Maximum Absolute Error), la raíz del error cuadrático medio RMSE (Root Mean Square Error) y R^2 . En cada caso, la configuración que presentó el mayor valor de R^2 y el menor RMSE para el conjunto de datos de testeo se consideró el mejor modelo de RNA. Los resultados se presentan en la [Tabla 3](#). Se observa que todas las configuraciones

propuestas presentan valores altos de R^2 . En particular, la configuración 2 exhibe el mejor ajuste, mejorando la eficacia de predicción con respecto a las restantes, entre un 13,5 y 19,5 % para el conjunto de testeo. En las Figura 4 se muestran las comparaciones entre los valores del L_{Aeq} medido y estimado para el modelo de red elegido (configuración 2) en función de los diagramas de dispersión de regresión lineal contemplando los distintos conjuntos de datos.

Modelo	Neuronas capa oculta	Conjunto Entrenamiento			Conjunto Testeo		
		MAE	RMSE	R^2	MAE	RMSE	R^2
RNA _{configuración1}	10	2,63	0,616	0,968	1,97	0,881	0,925
RNA _{configuración2}	10	1,81	0,596	0,970	1,41	0,776	0,945
RNA _{configuración3}	8	2,38	0,775	0,950	2,11	0,860	0,944
RNA _{configuración4}	8	2,94	0,768	0,951	1,85	0,927	0,927

Tabla 3: Desempeño de los modelos de RNA.

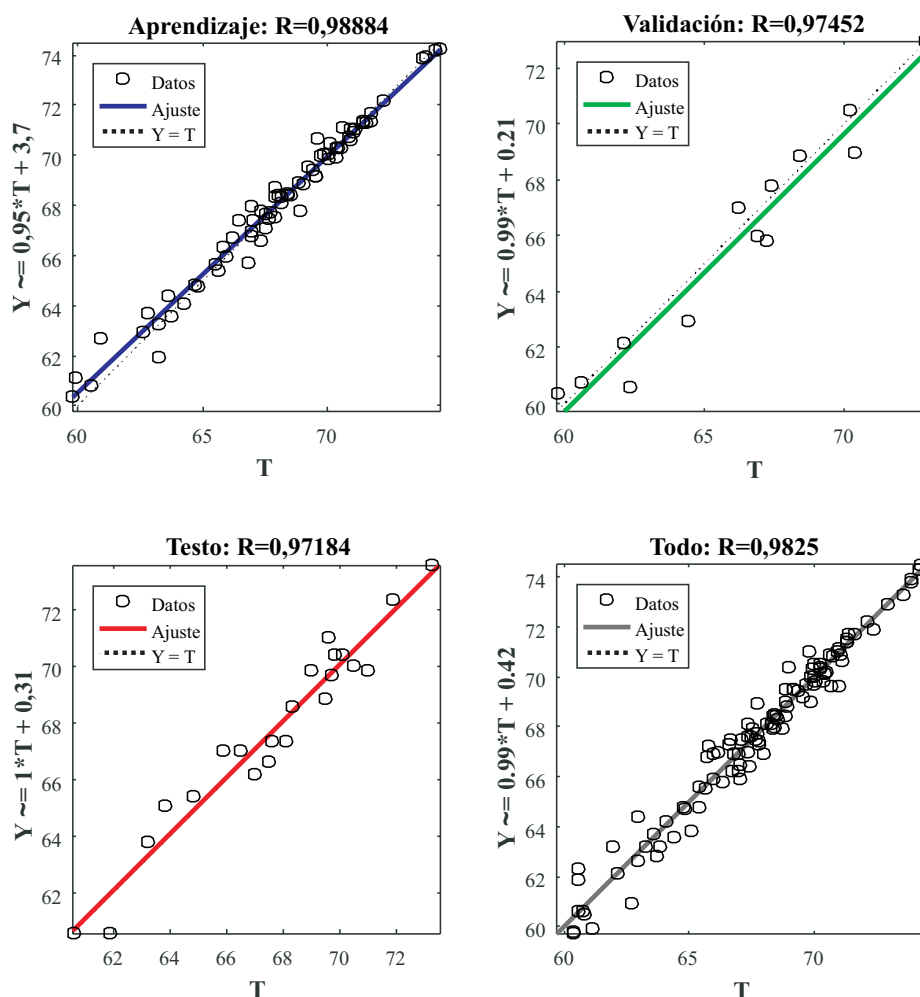


Figura 4: Diagramas de regresión lineal del L_{Aeq} medido (T) y estimado (Y) para el modelo RNA_{configuración2}.

4.3 Comparación entre el modelo de RNA y enfoques clásicos de predicción

El desempeño logrado por el modelo propuesto de RNA se evaluó mediante una comparación con un modelo de regresión múltiple MRM y algunos enfoques clásicos

reconocidos internacionalmente. En este último caso, los modelos elegidos fueron: el modelo alemán (RLS-90), el modelo de los Países Nórdicos (SP-96) y el modelo Suizo (STL-86). Esta elección se debe a que dichos modelos han sido implementados de manera exitosa en distintas ciudades latinoamericanas (Pinto y Mardones, 2009; Suárez y Barros, 2014; Murillo-Gómez et al., 2015; Bastian-Monarca et al., 2016; Bravo-Moncayo et al., 2019). Los enfoques clásicos seleccionados se componen de un modelo de emisión y un modelo de propagación. En este trabajo sólo se consideró el modelo de emisión para la comparación, dada la cercanía de los puntos de medición respecto del flujo vehicular. A continuación se presenta una breve descripción de cada modelo.

El RLS-90 es un modelo alemán que calcula el nivel de emisión de ruido a una altura de 4 m y a una distancia de 25 m desde el centro de un carril de la calle. El nivel de emisión es función de la cantidad de vehículos por hora Q y del porcentaje de camiones pesados P en condiciones idealizadas, es decir, para una velocidad de 100 km/h, una pendiente de la calle inferior al 5% y un tipo especial de pavimento (Quartieri et al., 2009). La expresión matemática del modelo se define de la siguiente manera:

$$\text{RLS-90} \rightarrow L_{\text{Aeq},25\text{m}} = 37,5 + 10 \log [Q(1 + 0,982P)] + C_{\text{VEL}} + C_{\text{PAV}} + C_{\text{GRAD}}, \quad (1)$$

donde C_{VEL} , C_{PAV} y C_{GRAD} son términos de corrección de velocidad, tipo de pavimento y pendiente de la calle.

El modelo Statens Planverk 96 (SP-96) es el método oficial de predicción de ruido de tránsito para los países nórdicos. El nivel de emisión se estima aplicando ciertas correcciones al nivel básico calculado para una distancia de 10 m del centro de la calle de dos carriles y para una altura de 1.5 m sobre el terreno (Álvarez, 2010). El descriptor utilizado es el L_{Aeq} para un periodo de 24 horas, aunque puede ser evaluado para cualquier intervalo de tiempo T en segundos. El modelo se define mediante la siguiente expresión:

$$\text{SP-96} \rightarrow L_{\text{Aeq},10\text{m}} = 10 \log \left[10^{\frac{LA_{\text{eq(livianos)}}}{10}} + 10^{\frac{LA_{\text{eq(pesados)}}}{10}} \right], \quad (2)$$

donde:

$$\begin{aligned} LA_{\text{eq(livianos)}} &= L_{\text{AE(livianos)}} + 10 \log \left(\frac{Q_L}{T} \right), \\ LA_{\text{eq(pesados)}} &= L_{\text{AE(pesados)}} + 10 \log \left(\frac{Q_P}{T} \right), \\ L_{\text{AE(livianos)}} &= 73,5 + 20 \log \left(\frac{v_L}{50} \right), \text{ para } v_L \geq 40 \text{ km/h,} \\ L_{\text{AE(pesados)}} &= 81, \text{ para } v_P < 50 \text{ km/h,} \end{aligned} \quad (3)$$

siendo Q_L y Q_P el número de vehículos livianos y pesados respectivamente, y v_L y v_P la velocidad de cada categoría vehicular.

El modelo STL-86 es el método oficial de predicción de ruido de tráfico usado en Suiza y permite calcular el L_{Aeq} a partir del nivel de emisión determinado a una distancia de referencia de 1 m y una altura de referencia de 1 m (Álvarez, 2010). El modelo se define a partir de la siguiente expresión:

$$\text{STL-86} \rightarrow L_{\text{Aeq},1m} = 42 + 10 \log \left[\left(1 + \left(\frac{v}{50} \right)^3 \right) \left(1 + 20p + \left(1 - \frac{v}{50} \right) \right) \right] + 10 \log(Q) + C_{\text{SP}}, \quad (4)$$

donde v es la velocidad media, en km/h, del flujo vehicular total, p es la razón entre el número de vehículos pesados y la cantidad total de vehículos y C_{SP} es un término de corrección que contempla el tipo de pavimento y la pendiente de la calle.

Es importante mencionar que los modelos de emisión mencionados están calibrados para distintas distancias de referencia. En tal sentido, es necesario realizar una corrección asociada a dicha distancia a efectos de poder comparar los niveles estimados con los medidos. Para ello, se utilizó el factor de corrección $C_{\text{DIST}} = 10 \log(d/d_0)$, donde d_0 es la distancia de referencia de cada modelo y d es la distancia relevada in situ entre el punto de medición y el eje de la calle.

En la [Tabla 4](#) se presenta la comparación del desempeño logrado entre el modelo de RNA y los modelos citados en función de los estimadores estadísticos previamente mencionados (ver sección 4.2). Se observa, un ajuste superior en el modelo de RNA y una performance similar en el resto de los enfoques. En la [Figura 5](#) se muestra, para cada modelo, el porcentaje de muestras con una diferencia absoluta entre el nivel sonoro medido y estimado mayor a 1 dBA y 3 dBA. Se observa que el 100% de los resultados obtenidos con el modelo de RNA se encuentran por debajo de los 3 dBA mientras que un 15 % aproximadamente de los resultados presentan diferencias mayores a 1 dBA. Los modelos restantes muestran diferencias mayores a 1 dBA en más del 55 % de los casos y diferencias mayores a 3 dBA entre el 3 y 10 % de los resultados.

Modelo	MAE	RMSE	R ²
RNA _{configuración2} (conjunto total de datos)	1,81	0,638	0,965
MRM _{configuración2} (conjunto total de datos)	4,33	1,791	0,725
RLS-90	4,76	1,832	0,775
SP-96	3,93	1,628	0,786
STL-86	4,62	1,789	0,773

Tabla 4: Desempeño de los distintos modelos de predicción.




Figura 5: Porcentaje de muestras con una diferencia absoluta mayor a 1 dBA y a 3 dBA entre el L_{Aeq} medido y estimado.

5 CONCLUSIONES Y TRABAJO A FUTURO

En este trabajo, se desarrolló un modelo basado en la técnica de RNA para predecir el ruido originado por el tráfico vehicular en la zona céntrica de la ciudad de Bahía Blanca. Inicialmente, se realizó un análisis de sensibilidad de las variables involucradas en la estimación del nivel sonoro, encontrando una gran dependencia de aquéllas de carácter geométrico y en particular del volumen de vehículos livianos. Luego, se analizaron distintas configuraciones de red para diferentes combinaciones de los parámetros mencionados. A partir de los resultados, se destaca que la configuración 2 presentó el mejor ajuste contemplando las siguientes variables de entrada: distancia entre el punto de medición y el borde de la calle (D_{S-B}); ancho de calle (A); altura promedio de edificios (H); volumen de vehículos livianos y medianos ($V_{LIV+MED}$); volumen de vehículos pesados (V_{PES}) y volumen de motos (V_{MOTOS}). Además, el modelo de RNA refleja una mayor capacidad predictiva en comparación con la técnica de regresión múltiple y con algunos modelos clásicos reconocidos internacionalmente.

Aunque la técnica de RNA ha demostrado ser robusta para el conjunto de muestras analizadas, la utilización de un conjunto mayor de datos podría proporcionar mejores resultados. Asimismo, existen algunos factores asociados al nivel de ruido que deberían incluirse en futuros trabajos como, por ejemplo, la velocidad de circulación, el tipo de pavimento, la presencia de barreras y los eventos anómalos (bocinas, frenadas bruscas), estos últimos muy dependientes del hábito del conductor. Finalmente, sería interesante incorporar las características espectrales del nivel sonoro dado que éstas afectan notoriamente la reflexión, difracción y efectos de apantallamiento durante la propagación.

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

- Álvarez, J., Estudio Comparativo para Modelos Predictivos del Ruido de Tráfico Rodado, a Través de Mediciones in Situ en un Sector de la Comuna de Osorno. Tesis presentada como parte de los requisitos para optar al grado de Ingeniero Civil Acústico, Escuela de Ingeniería Civil Acústica. Facultad de Ciencias de la Ingeniería. Universidad Austral de Chile. Valdivia, Chile, 2010.
- Basner, M., Babisch, W., Davis, A., Brink, M., Clark, C., Janssen, S., Stansfeld, S., Auditory and non-auditory effects of noise on health. *The lancet*, 383(9925):1325-1332, 2014.
- Bastian-Monarca, N.A., Suarez, E., Arenas, J.P., Assessment of methods for simplified mapping of traffic noise in small cities: Casework of the city of Valdivia, Chile. *Science of the Total Environment*, 550:439-448, 2016.
- Bishop, C.M., *Neural Network for pattern recognition*, Oxford, U.K., Oxford Univ. Press, 1995.
- Bravo-Moncayo, L., Chávez, M., Puyana, V., Lucio-Naranjo, J., Garzón, C., Pavón-García, I., A cost-effective approach to the evaluation of traffic noise exposure in the city of Quito, Ecuador. *Case Studies on Transport Policy*, 7(1):128-137, 2019.
- Cammarata, G., Cavalieri, S., Fichera, A., A neural network architecture for noise prediction. *Neural Networks*, 8(6):963-973, 1995.
- Cirianni, F., Leonardi, G., Environmental modeling for traffic noise in urban area. *American*

- Journal of Environmental Sciences*, 8(4):345, 2012.
- 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.
- Hamad, K., Khalil, M. A., Shanableh, A., Modeling roadway traffic noise in a hot climate using artificial neural networks. *Transportation Research Part D: Transport and Environment*, 53:161-177, 2017.
- Haykin, S., *Neural Networks. A Comprehensive Foundation*. 2nd edition. Prentice-Hall, 1999.
- 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.
- Murillo-Gómez, D.M., Gil-Carvajal, J.C., Zapata-Rodríguez, V., Téllez-García, J.J., Assessment of the RLS 90 calculation method for predicting road traffic noise in Colombian conditions. *Revista Facultad de Ingeniería Universidad de Antioquia*, (75):175-188, 2015.
- Nourani, V., Gökçekuş, H., Umar, I. K., Najafi, H., An emotional artificial neural network for prediction of vehicular traffic noise. *Science of the Total Environment*, 707:136134, 2020.
- Paliwal, M., Kumar, U.A., Neural networks and statistical techniques: a review of applications. *Expert Systems with Applications* 36(1):2-17, 2009.
- Parbat, D. K., Nagarnaik, P. B., Artificial neural network modeling of road traffic noise descriptors. In *Emerging Trends in Engineering and Technology*, First International Conference on (pp. 1017-1021). IEEE, 2008.
- Pinto, F.A.D.N.C., Mardones, M.D.M., Noise mapping of densely populated neighborhoods—example of Copacabana, Rio de Janeiro—Brazil. *Environmental monitoring and assessment*, 155(1):309-318, 2009.
- Pirrerá, S., De Valck, E., Cluydts, R., Nocturnal road traffic noise: A review on its assessment and consequences on sleep and health. *Environment international*, 36(5):492-498, 2010.
- Quartieri, J., Mastorakis, N., 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, 2009.
- Recio, A., Linares, C., Banegas, J. R., Díaz, J., Road traffic noise effects on cardiovascular, respiratory, and metabolic health: An integrative model of biological mechanisms. *Environmental research*, 146:359-370, 2016.
- Sequeira, M.E., Cortínez, V.H., Azzurro, A.P., Caracterización Acústica de Ambientes Urbanos Mediante el Uso de Redes Neuronales. *Mecánica Computacional*, 37(5):97-105, 2019.
- 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.