



USO DE REDES NEURONALES ARTIFICIALES EN LA VALORACIÓN ECONÓMICA DE RUIDO DE TRÁFICO.

Luis Bravo-Moncayo^{1,3}, José Lucio-Naranjo², Ignacio Pavón García³

¹Facultad de Ingeniería y Ciencias Agropecuarias, Universidad de las Américas, Quito, Ecuador.

(luis.bravo@udla.edu.ec)

²Facultad de Ingeniería en Sistemas, Escuela Politécnica Nacional, Quito, Ecuador.

(jose.lucio@epn.edu.ec)

³Grupo de Investigación en Instrumentación y Acústica Aplicada, Universidad Politécnica de Madrid, Madrid, España.

(ignacio.pavon@upm.es)

Resumen

Este estudio presenta un método alternativo que valora económicamente la disposición a pagar para reducir la molestia que ocasiona el ruido de tráfico, a través de un conjunto de redes neuronales artificiales. El modelo es capaz de predecir un rango de pago a partir de: un estudio de percepción subjetiva del ruido y sus efectos en la salud, niveles objetivos de exposición al ruido de tráfico obtenidos a partir de un modelo predictivo, características demográficas, socioeconómicas y las geográficas del lugar de residencia de los encuestados. Los resultados de este método han sido comparados con los resultados de un modelo econométrico *probit ordenado*, obteniendo un desempeño superior al 87.5% en términos del error porcentual promedio en los rangos de predicción. El estudio demuestra su capacidad de generalización y puede ser utilizado como una herramienta de valoración en la gestión del ruido urbano.

Palabras-clave: ruido de tráfico, valoración contingente, redes neuronales artificiales, disponibilidad a pagar, molestia.

Abstract

This study presents an alternative approach to value the willingness to pay (WTP) to reduce road traffic noise annoyance, based on an ensemble of artificial neural networks. The obtained model is capable to predict a WTP range from several variables related to: subjective noise perception, noise exposure, demographic and socioeconomic status, and geographic features of the respondent's dwellings. The results of this study have been compared to the results obtained from a *probit ordered* econometric model, reaching 87.5% better performance in terms of average percentage error in the validation and test subsets. This study presents generalization ability, and could be used as an alternative tool for valuing noise in management action plans.

Keywords: road traffic noise, contingent valuation, artificial neural networks, willingness to pay, noise annoyance.

PACS no. 43.50.Rq, 43.50.Lj



1 Introducción

La contaminación acústica es una de las externalidades producidas por el transporte en zonas urbanas. La evaluación de primera fase en el proceso de mapeo estratégico de ruido en la Unión Europea estima que, dentro de las ciudades, aproximadamente 56 millones de personas están expuestas a niveles de ruido ambiental que superan los 55 dBA en períodos diurnos, y 40 millones de personas se exponen a niveles de ruido nocturno que superan los 50 dBA [1]. Estos resultados son alarmantes desde la perspectiva de salud pública una vez que la Organización Mundial de la Salud (OMS) fijó el nivel de ruido nocturno en 40 dBA como el umbral a partir del cual los efectos adversos del ruido son notorios en la salud humana [2].

El impacto de la contaminación acústica causada por el tráfico vehicular puede ser valorado en términos monetarios a través de varios métodos entre los que se destacan: precios hedónicos, análisis de costo – beneficio, y valoración contingente [3]. La valoración contingente es una metodología que estima la disponibilidad a pagar de la población para obtener un beneficio en su nivel de bienestar, en función de la utilidad de la medida planteada [4].

El uso de inteligencia artificial, y específicamente de redes neuronales artificiales (RNA), puede resultar útil para valorar económicamente el ruido de tráfico. Esta herramienta ha sido usada con éxito en varios problemas no lineales relacionados con el transporte [5], sin embargo no se han encontrado estudios que utilicen RNA en valoraciones contingentes de ruido de tráfico.

La valoración económica del ruido de tráfico resulta relevante y pertinente en un contexto de gestión de ruido ambiental, ya que permite valorar y justificar distintas acciones propuestas en planes de acción para mitigar el impacto de la contaminación acústica [6].

El objetivo de este estudio es evaluar una herramienta alternativa, basada en RNA, que prediga rangos monetarios de disponibilidad a pagar para reducir la molestia que ocasiona el ruido de tráfico. Estos resultados son comparados con los obtenidos a través de un modelo econométrico *probit ordenado* [7]. Los datos para los dos modelos fueron obtenidos a través de un estudio socio-acústico desarrollado en la ciudad de Quito, Ecuador; en el que se evaluó: a) la percepción del ruido ambiental de los encuestados, b) el nivel de exposición sonora día-noche (Ldn) en la fachada de sus viviendas, y c) condiciones demográficas y socioeconómicas de los encuestados.

2 Redes Neuronales Artificiales

Las RNA ofrecen, entre otras cosas, técnicas de análisis numérico que simulan la estructura y principios de operación del cerebro humano, y que son capaces de predecir, con un grado específico de precisión, funciones arbitrarias o desconocidas [8], sin requerir de relaciones previas entre las variables analizadas.

La figura 1 muestra la estructura usual de una RNA con tres componentes principales: un vector de variables de entrada, capas neuronales ocultas, y una capa con la(s) variable(s) de salida. Los componentes de cada capa (entradas, neuronas y salidas) está conectados con los elementos de las capas subsiguientes. En las capas ocultas y de salidas se distinguen dos procesos: la sumatoria de los pesos sinápticos que representan la “memoria” del sistema, y la función de activación que calcula el nivel de activación de la neurona.

Los pesos sinápticos de todas las neuronas de cada capa son multiplicados por el vector de entrada y evaluados por la función de activación antes de continuar a la siguiente capa. En términos matemáticos, este proceso neuronal está definido por las ecuaciones (1) y (2).

$$sum_k = \sum_{i=1}^n w_{ki} x_i \quad (1)$$

$$out_k = f(sum_k), \quad (2)$$

donde out_k es la salida de la k -ésima neurona, y w_{ki} es el peso sináptico asociado de la i -ésima entrada x_i .

Las relaciones de entrada – salida ajustan los pesos sinápticos a través de un proceso de entrenamiento denominado retropropagación, que minimiza gradualmente las diferencias entre las salidas deseadas y las obtenidas por la RNA; en otras palabras, la RNA modifica su comportamiento en respuesta a las entradas – salidas, lo que constituye la característica más atractiva de la RNA: la capacidad de aprendizaje.




Fig. 1 – Configuración de una red neuronal artificial [9].

Otra característica de las RNA es su capacidad de generalización. Una vez que la RNA ha sido entrenada, un nuevo vector de entrada (no usado en el entrenamiento) es ingresado a la RNA, del que se espera entregue una salida acorde a los ajustes sinápticos de la red [10].

Es común que al usar RNA se configuren distintas arquitecturas y se seleccione la que presenta mejor precisión, desechando el resto de configuraciones lo que conlleva un desperdicio computacional en el proceso de entrenamiento de las configuraciones no utilizadas. Una alternativa a este enfoque consiste en el uso de distintas RNA que conformen un ensamble, logrando una mejora significativa en la predicción de nuevos datos [11], y en el desempeño de las capacidades de generalización, comparado con el uso de una RNA individual [12].



3 Metodología

3.1 Recolección de datos

Los datos relativos a la disposición al pago, la percepción y experiencia frente al ruido de tráfico, y los atributos demográficos y socioeconómicos fueron obtenidos a través de una encuesta personal en 600 viviendas de la zona urbana del Distrito Metropolitano de Quito. En la primera sección, se desarrollaron preguntas sobre la valoración de la calidad ambiental (EI), la relevancia de la contaminación acústica como problema ambiental (N_P), si el silencio fue considerado como factor de decisión para la elección de la vivienda (S_H), la molestia asociada al ruido de tráfico diurna (DA) y nocturna (NA), la inversión hecha en reformas con propósito de reducir el ruido en el hogar (NC_H), y los efectos del ruido percibidos en la salud: estrés (S), perturbación del sueño (SD), pérdida de audición (HL), dolores de cabeza (HA) y desconcentración (CL).

La segunda sección evalúa la disposición al pago para reducir la molestia ocasionada por el ruido de tráfico. Para ello, inicialmente se explicó la necesidad de crear un mercado hipotético, en el cual se desarrollará un plan de acción por los próximos 10 años que consista en campañas de sensibilización al ruido, mapeo, mantenimiento en la infraestructura vial, planes de movilidad, etc. El medio de pago planteado fue un incremento en el pago de los servicios básicos (agua o energía). Los umbrales de pago utilizados fueron porcentajes del costo de la inspección técnica vehicular anual (\$26 para vehículos livianos).

La tercera y última sección evaluó el estrato socioeconómico (SE) de los encuestados de acuerdo a las características de su hogar, educación, ocupación, acceso a tecnología, acceso a salud y seguridad, y niveles de consumo. Las variables demográficas obtenidas en la encuesta fueron: el género (G), la edad (A), los años de residencia en la vivienda (YH), la cantidad de horas diurnas que está en el hogar (H_H), las personas mayores (O) y menores (MO) que residen en el hogar, la parroquia (P), el tipo de vía más próxima a la vivienda (R), la altura del piso en la que pasa la mayor parte del tiempo en casa (H).

Para evaluar la exposición al ruido de tráfico se obtuvo el índice Ldn a través del algoritmo de modelamiento RLS-90, el cual, según estudios previos [13], entrega resultados óptimos en zonas urbanas similares de América Latina.

3.2 Estimación econométrica

En este estudio se asumió la función de utilidad expresada en la ecuación (3):

$$y_i^* = \beta x_i + e_i \quad (3)$$

donde y_i^* es el rango de disponibilidad a pagar, β son los coeficientes de las variables explicativas x_i , y e_i es un vector de atributos no observados que representan el error del modelo. Los valores umbrales de los rangos de disponibilidad a pagar fueron: \$0, \$2.6, \$5.2, \$10.4, \$20.8, \$26 y \$30. El modelo econométrico usa una función de máxima verosimilitud que calcula la probabilidad de que una observación esté el rango correcto de disponibilidad a pagar. La función densidad de probabilidad de la disponibilidad a pagar está definida en la ecuación (4) por:

$$L_i = \prod_{i=1}^8 P(y_i)^{I(y_i)} \quad (4)$$



Donde $P(y_i)$ es la probabilidad para cada rango, e $I(y_i)$ es un índice dicotómico (0 / 1) de la ocurrencia de disponibilidad en cada rango. A través de análisis numérico, se pueden obtener los coeficientes β en términos de la disponibilidad de pago en lugar de su densidad de probabilidad. Las respuestas protesta de disposición a pagar que se identificaron en el estudio fueron excluidas de los modelos [14].

3.3 Configuración y entrenamiento de RNA

La predicción de los rangos de disponibilidad a pagar constituye un problema no lineal debido a la naturaleza subjetiva de los datos, razón por la que el uso de una RNA con un entrenamiento de retropropagación (*perceptron*) es oportuno.

La estructura del modelo de RNA consiste en un comité de 6 redes (5 de ellas con 4 variables de entrada, y 1 con 3 entradas) entrenadas independientemente. La selección de las variables de entrada para cada red se realizó de acuerdo a la ganancia de información de cada variable, que depende de la probabilidad de ocurrencia de las posibles alternativas (rangos de disponibilidad a pagar) y está dada por:

$$\text{Ganancia de información} = 1 - \sum_{i=1}^n p_i I_i \text{ [bits]} \quad (5)$$

Donde n es el número de eventos, p_i es la probabilidad de ocurrencia del i -ésimo evento, e I_i está definido por:

$$I_i = - \sum_{i=1}^n p_i \cdot \log_n(p_i) \quad (6)$$

La salida de cada una de las redes son tomadas como entradas a una RNA consolidada. Para todas las redes del comité, se requirieron subconjuntos de datos para *entrenamiento* (optimización de pesos sinápticos), *validación* (evitar sobreajustes) y *prueba* (evaluar el desempeño del modelo). La distribución de los datos utilizados en cada subconjunto fue definida aleatoriamente (entrenamiento: 90%, validación: 5%, prueba: 5%).

Las variables de entradas fueron normalizadas para homogenizar los valores presentados a las redes y facilitar el proceso de entrenamiento. En cada red se utilizó una arquitectura de una sola capa oculta con 230 neuronas. Para el entrenamiento se utilizó el algoritmo de retropropagación resiliente (*trainrp*), en las neuronas de la capa oculta se utilizó la función de activación tansigmoidal (*tansig*) y en las neuronas de la salida la función de activación lineal (*purelin*), como se indica en la figura 2.

La tabla 1 indica los valores de MSE de cada una de las redes utilizadas en los distintos procesos, evidenciando que la red consolidada presenta valores menores que las redes individuales.

Tabla 1 – Desempeño de la RNA consolidada

Desempeño	0.158
Error de entrenamiento (MSE)	0.1779
Error de validación (MSE)	0.5310
Error de prueba (MSE)	0.4614

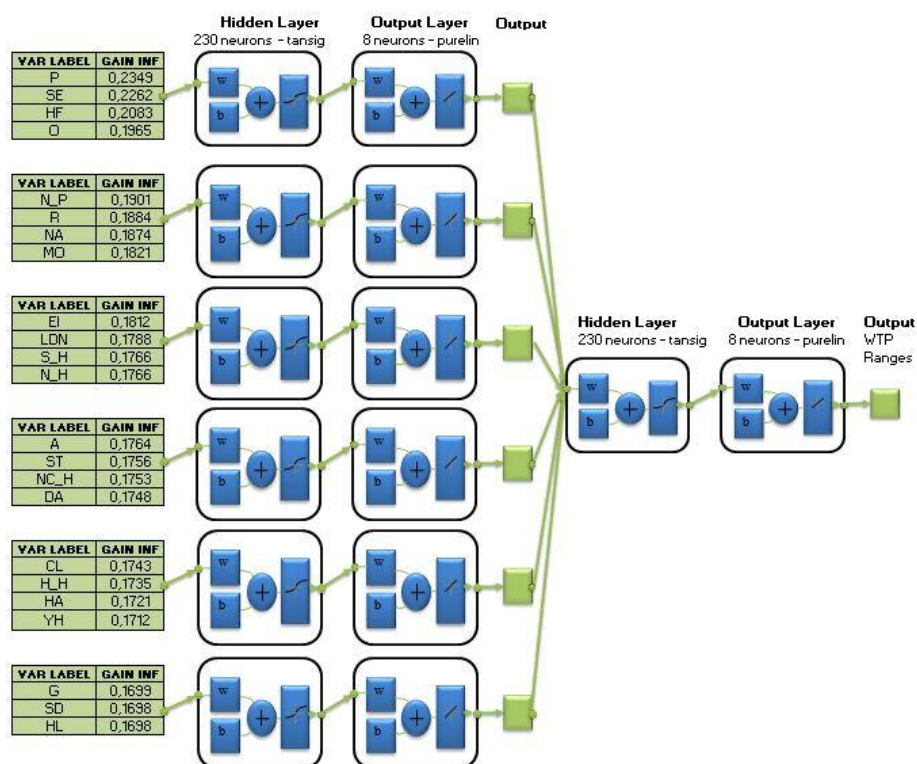


Fig. 2 – Arquitectura del comité de redes utilizado en el modelo

4 Resultados

La tabla 2 indica los porcentajes de error obtenidos para cada rango de disposición a pagar para ambos modelos (econométrico y de comité de RNA), mostrando la proporción de los resultados de los modelos que no coinciden con los datos recogidos en las encuestas. Estos resultados se obtienen a partir de una aproximación utilizando el valor de 0.5 para el modelo econométrico, y el valor más alto de los rangos definidos en la salida de la RNA consolidada.

Tabla 2 – Comparación de los porcentajes de error obtenidos en los modelos.

Rangos	Varianza Media (Entradas)	Ponderación [%]	Modelo Econométrico		Modelo RNA		
			Estimación	Validación	Entrenamiento	Validación	Prueba
			MSE 0.88	MSE 0.87	MSE 0.177	MSE 0.531	MSE 0.461
1	18.08	26.23	16.28	20.72	13.40	11.40	8.57
2	11.76	0.85	0.00	100.00	1,52	0.00	0.00
3	28.52	7.47	8.00	10.00	16.4	2.86	0.00
4	14.53	12.58	12.20	16.67	9.73	2.86	2.86
5	13.31	18.76	19.05	16.00	10.00	7.14	12.90
6	20.34	8.96	10.34	7.69	5.47	4.29	5.71
7	14.43	4.69	6.67	42.86	4.26	2.86	2.86
8	17.96	20.46	19.40	17.24	7.29	5.71	4.29
Error Medio ponderado			15.20	18.57	8.69	6.37	2.65



El porcentaje de error medio ponderado se basa en el número de casos presentes en cada uno de los rangos de acuerdo a los datos de las encuestas. Al comparar el error porcentual medio ponderado en las etapas de estimación (modelo econométrico) y entrenamiento (modelo RNA) se aprecia que el modelo de RNA presenta una precisión 42.8% mejor que el modelo econométrico. Por su parte, la comparación en las etapas en las que se incorporan nuevos datos a los modelos: validación (modelo econométrico) y prueba (modelo RNA), los resultados son más significativos a favor del modelo RNA, que presenta un 85.7% mejor desempeño que el modelo econométrico.

5 Conclusiones

En este estudio se presenta una herramienta alternativa para valorar el rango de disposición a pagar para mitigar el impacto del ruido de tráfico. Esta herramienta consiste en un comité de RNA entrenado a partir de datos de valoración contingente observados en la población del Distrito Metropolitano de Quito.

Las variables más significativas del modelo son: la parroquia, el estrato socioeconómico, la cantidad de habitantes mayores y menores en la vivienda, y la molestia diurna y nocturna asociada al ruido de tráfico, obtenidas a través de la ganancia de información de cada variable. Se configuró una estructura basada en un comité de 6 RNA con una capa oculta de 230 neuronas, cuyas salidas alimentaron una RNA consolidada que entrega el rango de disposición a pagar para reducir la molestia del ruido de tráfico.

Al comparar con un modelo econométrico probit ordenado, la estructura propuesta basada en RNA, presenta considerables mejoras en la precisión predictiva: 85.7% en términos del error porcentual ponderado en el proceso de validación / prueba.

Estos resultados plantean que el uso de un comité de RNA puede aproximar una solución satisfactoria al problema de valoración económica de ruido de tráfico, y aportar a la gestión de ruido ambiental en la obtención de recursos monetarios para el desarrollo de planes de acción.

Agradecimientos

Los autores expresamos un sincero agradecimiento a los estudiantes: Francisco Aguirre, Daniela Guerra, Daniela Tello, y Diego Zurita, por su valiosa ayuda en el levantamiento de datos (mediciones y encuestas); gracias también a quienes accedieron a participar en las encuestas de valoración económica. Un agradecimiento especial a la Secretaría de Ambiente del Municipio de Quito, Dirección de Investigación de la Universidad de las Américas, y SENESCYT.

Referencias

- [1] Murphy, E.; King, E. *Environmental noise pollution: Noise mapping, public health, and policy*, Elsevier, Burlington (UK), 1st edition, 2014.
- [2] Hurlley, C. *Night Noise Guidelines for Europe*, World Health Organisation Regional Office for Europe, Copenhagen (Denmark), 2009.
- [3] Istamto, T.; Houthuijs, D.; Lebret, E. Willingness to pay to avoid health risks from road-traffic-related air pollution and noise across five countries. *Science of the Total Environment*, Vol 497-498, 2014, pp 420-429.



- [4] Brouwer, R. Environmental value transfer: State of the art and future prospects. *Ecological Economics*, Vol 32(1), 2000, pp 137-152.
- [5] Dougherty, M. A review of neural networks applied to transport, *Transportation Research Part C: Emerging Technologies*, Vol 3(4), 1995, pp 247-260.
- [6] Barreiro, J.; Sánchez, M.; Viladrich-Grau, M. How much are people willing to pay for silence? A contingent valuation study. *Applied Economics*, Vol 37(11), 2005, pp 1233-1246.
- [7] Vásquez, F.; Cerda, A.; Orrego, S. *Valoración económica del ambiente*, Thomson, Buenos Aires (Argentina), 1^{ra} edición, 2007.
- [8] Curry, B.; Morgan, P.; Silver, M. Neural networks and non-linear statistical methods: An application to the modelling of price-quality relationships, *Computers & Operations Research*, Vol 29(8), 2002, pp 951-969.
- [9] Lucio, J.F. Inteligência computacional aplicada na geração de respostas impulsivas bi-auriculares e em aurilização de salas. Doctoral thesis. Universidade do Estado do Rio de Janeiro, Rio de Janeiro, Brazil, 2014.
- [10] Haykin, S. *Neural networks and learning machines*, Prentice Hall/Pearson, New York (USA), 2009.
- [11] Bishop, C. *Neural Networks for Pattern Recognition*, Oxford University Press, New York (USA), 2005.
- [12] Granitto, P.; Verdes, P.; Ceccatto, H. Neural network ensembles: Evaluation of aggregation algorithms, *Artificial Intelligence*, Vol 163(2), 2005, pp 139-162.
- [13] Suárez, E.; Barros, J. Traffic noise mapping of the city of Santiago de Chile. *Science of the Total Environment*, Vol 466-467, 2014, pp 539-546.
- [14] Osorio, J.; Correa, F. An analysis of the empiric application of the contingency valuation method, *Semestre Económico*, Vol 12(25), 2009, pp 11-30. Recuperado de: http://www.scielo.org.co/scielo.php?pid=S0120-63462009000300002&script=sci_arttext&tlng=en