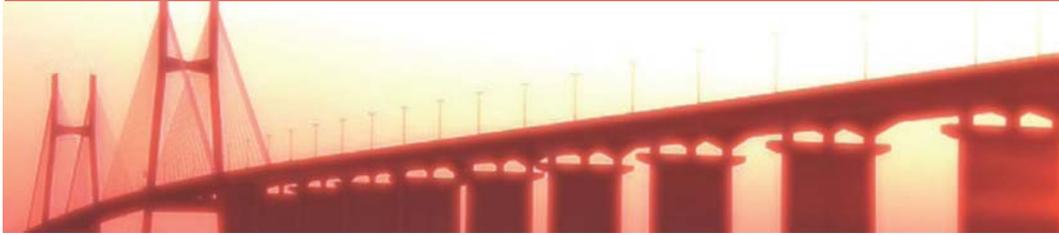


PRIMERAS JORNADAS REGIONALES DE ACÚSTICA AdAA 2009

19 y 20 de noviembre de 2009, Rosario, Argentina



AdAA2009-A060R

Un modelo de caja gris para la acústica de recintos industriales

Martín Sequeira^(a), Víctor Cortínez^(a,b).

(a) Centro de Investigaciones en Mecánica Teórica y Aplicada (CIMTA), Universidad Tecnológica Nacional (FRBB), 11 de Abril 461,8000, Bahía Blanca, Argentina. E-mail: martins@frbb.utn.edu.ar

(b) Consejo Nacional de Investigaciones Científicas y Tecnológicas, (CONICET), Argentina.

Abstract

Noise pollution due to industrial noise sources is a serious problem within industrial rooms. Because of the high cost involved in noise control systems, their design is an important aspect to consider. There are several computer models for this purpose, from simple analytical formulations to more complex methods based on geometric acoustics. An alternative approach to model the different relationships involved in such situations is the use of artificial neural networks (ANN). This tool provides a robust method for solving classification and prediction problems, allowing great flexibility and accuracy. One difficulty associated with this type of technique is the limited predictive extrapolation properties, which lead to erroneous results. This paper deals with an approach that combines the theoretical structure of a Sabine-type acoustic model corrected by an ANN in situations where it is known to present a considerable inaccuracy. This is an attempt to improve the properties of extrapolation.

Resumen

La contaminación acústica debida a fuentes de ruido industrial constituye un serio problema dentro de los establecimientos. Las soluciones técnicas involucradas poseen un alto costo, motivo por el cual se hace necesario diseñar cuidadosamente los sistemas de control de ruido. Existen diversos modelos computacionales para este fin, pudiéndose utilizar desde simples formulaciones analíticas hasta métodos más complejos basados en acústica geométrica. Un enfoque alternativo, para modelar las distintas relaciones acústicas involucradas en este tipo de situaciones, es el uso de las redes neuronales artificiales (RNA). Un problema asociado a este tipo de técnica predictiva consiste en las escasas propiedades de extrapolación, las cuales conllevan a resultados erróneos. En tal sentido, en el presente trabajo se propone un enfoque que combina la estructura teórica de un modelo acústico tipo Sabine con una RNA a los efectos corregir parte de dicho modelo sólo donde se conoce que éste presenta una inexactitud considerable. Tal modelo gris puede mejorar la precisión en el cálculo de niveles sonoros, en comparación con las RNA o el modelo de Sabine usado en forma separada.

1 Introducción

La contaminación acústica constituye un serio problema ocupacional en los establecimientos industriales. Por tal motivo, existen regulaciones cada vez más rigurosas a los efectos de controlar dicho ambiente acústico (Gerges, 2004).

En muchos casos, las soluciones técnicas involucradas poseen un alto costo, motivo por el cual se hace necesario diseñar cuidadosamente los sistemas de control de ruido a partir de la utilización de modelos predictivos a los efectos de estimar la eficiencia de diferentes soluciones técnicas para lograr un ambiente acústico adecuado.

Existen diversos métodos computacionales para este fin, siendo el más utilizado el método de acústica geométrica, que se adapta en forma suficientemente precisa al rango de frecuencias altas existentes en las plantas industriales. Sin embargo, los tiempos de cómputo empleados suelen ser importantes (Girón et. al, 2005).

También es posible utilizar simples formulaciones analíticas, lo que implica una disminución en los tiempos computacionales pero, en muchos casos, con una reducción de la precisión en función de la complejidad de la situación considerada. Estos tipos de modelos se denominan de caja blanca ya que describen el comportamiento físico del problema.

Un modelo empírico ampliamente utilizado es el modelo de Sabine. En su concepción más simple, dicha teoría supone que el nivel sonoro se descompone en dos tipos de contribuciones: el campo directo y el reverberante. Para el primero de ellos asume atenuación esférica a partir de una fuente puntual, mientras que plantea el campo reverberante como uniforme y dependiente de las condiciones de absorción del recinto (Gerges, 2004). Este método simplificado es corrientemente utilizado por los ingenieros acústicos, y brinda soluciones razonables para una cantidad de situaciones. Sin embargo, debe tenerse cuidado en su aplicación puesto que para ciertos casos puede dar predicciones solamente de orden de magnitud.

Un enfoque alternativo, para modelar las distintas relaciones acústicas involucradas en la acústica de recintos, es el uso de las redes neuronales artificiales (RNA).

Esta herramienta actúa como un modelo de caja negra y puede ser utilizado aún en situaciones en las cuales no se cuenta con el conocimiento necesario para establecer modelos matemáticos adecuados que representen el sistema, mientras se cuente con suficientes datos experimentales.

Recientemente, se ha ido incrementando el uso de la misma, en el área de acústica, para la predicción de distintas variables debido principalmente a su gran flexibilidad relacionada con la precisión y complejidad de los parámetros involucrados (Cammarata et. al, 1995 ; Nannariello et. al, 1999, 2001a, b, c ; Mungiole and Wilson, 2006 ; Cortínez y Sequeira, 2009). Más aún, este método se ha utilizado en el problema de identificación en diversas situaciones con resultados precisos y fiables (Reich et. al, 1998 ; Sequeira y Cortínez, 2009).

Para una adecuada precisión esta metodología debe estar basada en valores numéricos (teóricos o experimentales) suficientemente precisos, y en general se requiere una gran cantidad de valores, ya que se trata en definitiva de una técnica de regresión no lineal que permite efectuar una compleja interpolación para detectar patrones ocultos. Ocurre que muchas veces existen imprecisiones en los datos o éstos resultan insuficientes, lo cual trae aparejado un error de predicción. Por otra parte, cuando se utiliza tal metodología en regiones de datos muy diferentes a las usadas para entrenamiento, no es posible obtener buenos resultados. Es decir presenta una inadecuada capacidad de extrapolación.

En este trabajo se presenta un enfoque que combina la estructura clásica del modelo difuso de Sabine con el enfoque de RNA para determinar la distribución espacial de los

niveles de presión sonora (NPS) en recintos industriales con características geométricas y acústicas particulares. De esta manera, se pretenden minimizar los errores presentados por el modelo de Sabine, aplicando una función de corrección determinada previamente mediante la utilización de una RNA.

Para ello, se entrena la RNA, para una familia de recintos industriales, a partir de considerar valores muy precisos mediante un modelo computacional de trazado de rayos.

De esta manera, el modelo de caja gris resultante se utiliza para predecir las variaciones del campo sonoro, considerando geometrías desproporcionadas y características de absorción no uniformes, en la familia de recintos entrenada. Para tales casos, el modelo de Sabine presenta un error considerable.

Por otra parte, la utilización directa de un modelo de caja negra basado en una red neuronal puede presentar falta de precisión debido a los errores propios de los datos de entrenamiento, como así también del propio procedimiento de determinación (dependiente de la cantidad de datos, estructura de la red, etc.).

Para comprender las ventajas potenciales del modelo propuesto, supóngase, a manera de ejemplo, un error resultante de la red neuronal del orden de 10%. Por otra parte, sea el error dado por el modelo de Sabine del orden de 30%.

En tal caso si se utilizara una red neuronal solo a los efectos de corregir el modelo de Sabine, el error esperado sería del orden del 10% del 30% del valor del NPS, es decir un error del orden del 3%.

Este tipo de comportamiento se hace más evidente cuando el modelo es utilizado fuera de la región de entrenamiento de la red, es decir presenta mejor capacidad de predicción. Finalmente, su estructura principal analítica sería conveniente para su interpretación física adecuada.

2 Formulación del problema

2.1 Modelo acústico de caja gris

En problemas relacionados con el ruido en recintos es conveniente describir el campo acústico interior empleando los niveles de presión sonora, los cuales están directamente vinculados a la sensibilidad del oído humano (Gerges, 2004).

Por lo tanto, dicho nivel se puede expresar, con suficiente generalidad, de la siguiente manera:

$$NPS_{ijf} = F(NWS_{jf}, Q_{jf}, x_i, y_i, z_i, x_j, y_j, z_j, A). \quad (1)$$

Siendo NPS_{ijf} el nivel de presión sonora en cada receptor i , a causa de la fuente j y en la banda de frecuencia f , que depende del nivel de potencia sonora (NWS_{jf}) y de la directividad (Q_{jf}) de cada fuente j para cada banda de frecuencia f , de las coordenadas de la fuente j y los receptores i ($x_j, y_j, z_j, x_i, y_i, z_i$) y de las condiciones acústicas del campo sonoro lejano (A) las cuales varían en función del ambiente acústico que se este considerando.

Los niveles de presión sonora están relacionados con las potencias suministradas por las fuentes industriales, mediante el nivel de propagación sonora SP .

Este nivel describe como las características geométricas y acústicas del recinto afectan la variación del campo sonoro, independientemente del nivel de potencia sonora de la fuente considerada.

En el caso de recintos industriales, este nivel puede expresarse con gran generalidad, de la siguiente manera:

$$SP_{ijf} = F(L, W, H, x_i, y_i, z_i, x_j, y_j, z_j, \alpha_{superficiesf}, q_{fitf}). \quad (2)$$

siendo L , W y H el largo, el ancho y la altura, respectivamente del recinto; $x_i, y_i, z_i, x_j, y_j, z_j$ las coordenadas del receptor i y de la fuente j ; $\alpha_{superficiesf}$ los distintos coeficientes de absorción de las superficies y q_{fitf} la densidad de objetos distribuidos en el interior, para la frecuencia f .

Por otro lado, el nivel de presión acústica generado por una fuente puntual omnidireccional se expresa de acuerdo a la teoría de campo difuso de Sabine de la forma (Gerges, 2004):

$$NPS_{sab_{ijf}} = NWS_{jf} + 10 \log_{10} \left[\frac{1}{4 \times \pi \times r_{ij}} + A_f \right] = NWS_{jf} + SP_{sab_{ijf}}, \text{ en dB}, \quad (3)$$

donde $1/4\pi r_{ij}$ tiene en cuenta la contribución del campo directo generado por cada fuente j sobre cada punto receptor i del recinto; r_{ij} es la distancia entre la fuente i y el punto de observación j y A_f representa el campo reverberante uniforme para cada frecuencia f , y depende de las características globales de absorción del recinto. La suma de ambos campos (directo + reverberante), constituyen el nivel de propagación sonora SP_{sab} para la citada teoría.

Mediante la siguiente modificación de la expresión (3), el modelo acústico de caja gris, llamado a partir de aquí modelo de Sabine modificado, queda determinado:

$$NPS_{sab_{mod_{ijf}}} = NWS_{jf} + SP_{sab_{ijf}} \times C_{ijf}, \text{ en dB}, \quad (4)$$

donde:

$NPS_{sab_{mod_{ijf}}}$ representa el nivel de presión sonora dado por el modelo de Sabine, modificado en dB, en cada punto receptor i del recinto bajo estudio, a causa de la fuente j y en la banda de frecuencia f .

NWS_{jf} es el nivel de potencia sonora, en dB, de cada fuente j para cada banda de frecuencia f .

$SP_{sab_{ijf}}$ es el nivel de propagación sonora dado por el modelo de Sabine, en dB, en cada punto receptor i , menos el nivel de potencia de la fuente j y para la banda de frecuencia f .

C_{ijf} es una función de corrección, en dB, que se utiliza para modificar el valor de propagación sonora a fin de considerar los efectos locales de absorción y las características geométricas en el campo reverberante.

Los valores de la función de corrección C se determinan, a partir de un modelo de red neuronal para un conjunto de recintos industriales, mediante la expresión:

$$C_{ijf} = SP_{ijf} / SP_{sab_{ijf}}, \text{ en dB}, \quad (5)$$

donde los niveles SP_{ijf} se consideran valores muy precisos y se obtienen a partir de un modelo de trazado de rayos.

De esta manera, se pretende modificar el modelo de Sabine en aquellas zonas donde sus valores son imprecisos, y mantener su predicción en los lugares donde muestra valores confiables (relaciones geométricas entre $0,5 > L/W > 2$ y variaciones entre los coeficientes de absorción de las diferente superficies interiores menores al 50 %). En estos casos se adopta un

valor de C igual a uno.

Por otra parte, en las regiones donde el modelo de Sabine no alcanza una correcta predicción, la función de corrección, dada por la expresión (5), toma los valores obtenidos por la RNA dentro del dominio de datos utilizado para el entrenamiento.

Con respecto a la distancia fuente receptor, la red se entrena cuando ésta adopta valores entre los límites dados la Tabla 1. Para distancias mayores, la función de corrección toma el valor límite superior de las correspondientes distancias de entrenamiento. De esta manera las propiedades de extrapolación con respecto a la variable distancia fuente –receptor son sustancialmente mejoradas.

Nótese que tal enfoque de extrapolación resulta imposible si se utiliza una red neuronal para la estimación directa del SP.

3 Metodología

A continuación se presenta la metodología empleada para desarrollar el modelo acústico de caja gris, basado en la técnica de red neuronal.

3.1 Desarrollo del modelo de caja gris: Simulación de escenarios

Los niveles de propagación sonora SP , se obtuvieron mediante simulación, empleando el software ([SoundPlan, 2004](#)).

Esencialmente, el modelo considera la geometría básica del recinto y los objetos en su interior (*fittings*), junto con sus correspondientes coeficientes de absorción. La predicción del campo sonoro se realiza considerando la energía y el tiempo de llegada a cada receptor a partir de una serie de rayos emitidos desde cada una de las fuentes y las sucesivas reflexiones de los mismos en las superficies del recinto. El número de rayos y de reflexiones considerados debe ser suficientemente alto para asegurar una correcta predicción.

Para la modelización, el algoritmo de trazado de rayos emplea las siguientes simplificaciones:

- Se utilizan las leyes de la acústica geométrica.
- Las superficies se consideran todas planas y reflejan la energía espectralmente como si fueran provenientes de un plano infinito.
- Todas las superficies absorben energía sonora de acuerdo con su coeficiente de absorción, que es independiente del ángulo de incidencia.
- El sonido se considera como función de energía y no como una función de presión, por lo tanto, las energías se suman directamente, por lo que no se tienen en cuenta los efectos de interferencia.
- La dispersión del sonido debido a los “rebotes” en los obstáculos existentes dentro del recinto (máquinas, cañerías, etc.) se tiene en cuenta solo en forma estadística, es decir no se considera la geometría de cada uno y su interacción con los rayos proyectados. Por lo tanto se define como parámetro a la densidad de objetos $q = S/(4V)$, siendo S la superficie total de todos los objetos interiores (cuyas dimensiones sean más grandes que la longitud de onda) y V el volumen del recinto.

3.2 Desarrollo del modelo de caja gris: Construcción de la RNA

Las redes neuronales artificiales (RNA) son un tipo de estructura de computación paralela, donde muchas pequeñas unidades de cálculo llamadas neuronas están masivamente interconectadas con la capa anterior, de donde reciben la información, y con la capa posterior, hacia donde la transmiten. Es una forma de computación que trata de emular el

funcionamiento de las neuronas biológicas y es capaz de manejar las imprecisiones e incertidumbres que aparecen cuando se trata de resolver problemas relacionados con el mundo real (reconocimiento de formas, toma de decisiones, etc.), ofreciendo soluciones robustas y de fácil implementación (Bishop, 1995).

En el presente trabajo se consideró la estructura de red neuronal tipo perceptron multicapa (MLP).

Este modelo esta constituido por una primera capa de entrada (neuronas perceptoras) con tantas unidades como elementos tenga el vector de información que se va a introducir. Esta capa está conectada a una capa oculta donde se realizan los cálculos y finalmente la información transformada llega una capa de salida de donde se obtienen los resultados (Gardner and Dorling, 1998). El almacenamiento del conocimiento adquirido por la red no está ubicado en ningún elemento concreto sino que está distribuido entre todas las neuronas a través del ajuste de unos coeficientes (pesos numéricos o pesos sinápticos).

A cada neurona de la capa oculta se le asigna una función matemática específica denominada función de activación. En el presente trabajo se utilizaron las funciones transferencia tangente hiperbólica para las neuronas de la capa oculta y lineal para la neurona de salida.

La salida estimada, en este caso $\hat{C}_i = SP_i / SP_{sab_i}$ (la función de corrección), del perceptrón multicapa con una capa oculta esta dada por la siguiente ecuación:

$$\hat{C}_i = g_1 \left(\sum_{j=0}^L w_{ji} (g_2 \sum_{k=0}^N w_{jk} x_k) \right), \quad (6)$$

donde L es el numero de neuronas de la capa oculta; N es el numero de neuronas; x_k del vector de entrada; w_{ji} es el peso sináptico de la conexión entre la neurona de salida i y la neurona j de la capa oculta; w_{jk} es el peso sináptico que conecta la neurona j de la capa oculta con la neurona de entrada k ; g_1 es la función de activación de las neuronas de salidas y g_2 es la función de activación de las neuronas de la capa oculta.

El entrenamiento de la red tipo MLP se realiza a través de un aprendizaje supervisado mediante un algoritmo de retropropagación del error (Nelles, 2001). El mismo comienza considerando los pesos (coeficientes) de manera aleatoria y aprende ajustando estos valores iterativamente hasta que llega a un estado estable donde es capaz de establecer una relación funcional dentro de un error objetivo prefijado, en este caso se utilizó el error cuadrático medio (mse), mediante en la siguiente ecuación:

$$mse = \frac{1}{M} \sum_{i=1}^M (\hat{C}_i - C_i)^2. \quad (7)$$

donde \hat{C}_i es la salida estimada por la red neuronal y C_i representa la salida deseada.

El método de entrenamiento presenta distintas variantes, dependiendo de la técnica de optimización utilizada. El algoritmo de optimización empleado fue el de Levenberg-Marquardt, siendo éste una técnica de segundo orden constituyendo una combinación entre el método de Newton y el método de descenso rápido.

En combinación con el algoritmo Levenberg-Marquardt se aplica el método de Regularización, que permite mejorar la generalización de la red. Este método se basa en la

modificación la función de performance de la red mediante el agregado de un término que consiste en la media de la sumatoria de los cuadrados de los pesos de la red. Así, la nueva función de performance es:

$$msereg = \gamma \times mse + (1 - \gamma) \times msw, \quad (8)$$

siendo γ la tasa de performance y:

$$msw = \frac{1}{N} \sum_{i=1}^N w_i^2. \quad (9)$$

Aquí, w_i representa a cada uno los pesos (lineales y no lineales) de la red y N es la cantidad total de pesos de la red. Usando esta nueva función de performance, la red tendrá pesos más pequeños forzándola así a una respuesta más suave y disminuyendo la tendencia al sobre ajuste.

El problema de la regularización es la dificultad radicada en determinar un óptimo valor para la tasa de performance. Si este parámetro es muy grande, la red tiende a sobreajustar; mientras que si es muy pequeño, la red no reproduce de manera adecuada los datos de entrenamiento. Se utiliza entonces la regularización Bayesiana con el objeto de determinar automáticamente un óptimo valor para el parámetro γ . Para ello, los pesos se asumen como variables aleatorias con distribuciones especificadas. El parámetro γ se asocia con las varianzas de dichas distribuciones, por lo que luego se lo estima utilizando técnicas estadísticas.

4 Resultados numéricos

A continuación se presentan las consideraciones generales para el entrenamiento de la RNA y luego se procede a verificar la eficacia de predicción mediante el proceso de validación.

4.1 Obtención de los datos de entrada y construcción del modelo de RNA

Los datos utilizados en la confección del modelo de RNA se obtuvieron mediante la modelación de 10 recintos industriales vacíos con diferentes geometrías y configuraciones acústicas interiores, considerando materiales de construcción típicos sobre las paredes y en el cielorraso. Los coeficientes de absorción se consideraron para las bandas de octava desde 250 a 2000 Hz.

Los materiales absorbentes en las paredes se modelaron ubicados a partir de 2 metros de altura a fin de suponer una situación industrial más real, mientras que los coeficientes de absorción del piso se consideraron constantes para todas las configuraciones.

En cada recinto se combinaron distintas ubicaciones de una fuente puntual omnidireccional y un receptor (ambos a una altura de 1,5 metros) de manera de obtener una caracterización completa del campo acústico. Para esto, se varió el número total de ubicaciones del receptor entre 6 y 12, y el número total de ubicaciones de la fuente puntual entre 5 y 8, obteniéndose una combinación mínima y máxima de relaciones fuente-receptor de 30 y 96, respectivamente.

Además, se consideraron distintas combinaciones de las propiedades acústicas interiores (distintos coeficientes de absorción de las superficies), consiguiéndose un conjunto total de

1968 casos.

A partir de esto, en cada punto receptor se determinó el nivel SP para cada banda de octavas, desde 250 a 2000 Hz, considerando cada una de las configuraciones anteriormente mencionadas. Luego, se obtuvieron las funciones de corrección C , que servirán de base para el entrenamiento de la RNA.

El rango de los distintos parámetros geométricos y acústicos utilizados para la construcción del modelo de RNA se presenta en la tabla 1.

Se analizaron varios criterios para elegir las posibles variables de entrada a fin de determinar cuales de ellas eran las más importantes en la estimación de la función de corrección C . El criterio principal de elección residió en la simplicidad en la obtención de las mismas al considerar situaciones reales. Además, se consultaron diversas publicaciones pertinentes (Ondet and Sueur, 1994; Hodgson, 2003).

Tabla 1. Rangos de las variables utilizadas para la construcción del modelo de RNA considerando 10 recintos industriales y 1968 combinaciones posibles en función de la ubicación de receptor, la fuente y de las diferentes configuraciones acústicas interiores.

Parámetro	Símbolo	Unidad	Rango del parámetro
Largo	L	m	12 / 32
Ancho	W	m	4 / 10
Altura	H	m	3.5 / 8
Coordenada x del receptor	R_x	m	1 / 31
Coordenada y del receptor	R_y	m	0.5 / 9.5
Coordenada x de la fuente	F_x	m	2 / 26
Coordenada y de la fuente	F_y	m	1 / 9
Distancia fuente-receptor	$distFR$	m	1,12 / 29,95
Coeficiente de absorción en cada pared por bandas de octava	α_{pared_250}	---	0,07 / 0,35
	α_{pared_500}	---	0,08 / 0,6
	α_{pared_1000}	---	0,08 / 0,7
	α_{pared_2000}	---	0,09 / 0,75
Coeficiente de absorción en el cielorraso por bandas de octava	$\alpha_{cielorraso_250}$	---	0,07 / 0,28
	$\alpha_{cielorraso_500}$	---	0,08 / 0,66
	$\alpha_{cielorraso_1000}$	---	0,08 / 0,82
	$\alpha_{cielorraso_2000}$	---	0,08 / 0,82
Nivel de propagación sonora (SP) por bandas de octava	SP_{250}	dB	-27,22 / -5,92
	SP_{500}	dB	-36,91 / -6,05
	SP_{1000}	dB	-40,77 / -6,12
	SP_{2000}	dB	-41,4 / -6,3
Funciones de corrección ($C = SP/SP_{sab}$) por bandas de octava	C_{250}	dB	0,79/1,29
	C_{500}	dB	0,79/ 1,26
	C_{1000}	dB	0,80/ 1,27
	C_{2000}	dB	0,80/ 1,25

Finalmente se eligieron 9 variables como las más representativas. Las mismas son: largo del recinto (L), sección del recinto ($Secc: W \times H$), coordenadas del receptor (R_x y R_y), coordenadas de la fuente (F_x y F_y), distancia entre la fuente y el receptor ($distFR$) y el

coeficiente de absorción de las paredes y del cielorraso (α_{pared} y $\alpha_{cielorrasso}$).

Previo al inicio del entrenamiento de la RNA, se realizó un pre-proceso a los datos de entrada mediante una normalización y transformación de los mismos de manera de acotarlos dentro de un rango específico con media nula y un desvío estándar igual a uno.

Luego se realizó un análisis de componentes principales para completar el pre-proceso, ortogonalizando los componentes de los vectores de entrada de manera de que queden des-correlacionados (evitando la redundancia de datos) y eliminando aquellos componentes que producen la menor contribución a la variación en el conjunto de datos.

La utilización de estas dos técnicas estadísticas permite presentar los datos de entrada de una forma más compacta y mejora las propiedades numéricas de la optimización (entrenamiento de la red).

Tal metodología está considerada en la herramienta computacional utilizada (Matlab Neural Networks Toolbox, <http://www.mathworks.com/>).

Por último, el conjunto total de 1968 datos se dividió en grupos de entrenamiento (1488 datos), verificación y validación, estos dos últimos con aproximadamente un 25 %, cada uno, del conjunto total de datos (480 datos).

El grupo de entrenamiento se utiliza para estimar los parámetros de la red, el grupo de verificación para comprobar la generalización durante el entrenamiento y evitar posibles efectos de sobre-entrenamiento y el grupo de validación para determinar de forma independiente la red final, la cual es aplicada a cualquier base de datos nueva.

Además, se introdujo en el conjunto de entrenamiento una pequeña componente aleatoria con distribución uniforme que hará las veces de “error” de medición, correspondiente a una aumento del 10% sobre el nivel de propagación sonora SP .

Consecuentemente, la función considerada para el entrenamiento de las RNA se muestra a continuación:

$$C_f = SP_f / SP_{sabf} = F(L, Secc, Rx, Ry, Fx, Fy, distFR, \alpha_{cielorrasso_f}, \alpha_{pared_f}), \quad (10)$$

donde f representa la banda de octava desde 250 a 2000 Hz.

Cabe destacar que el tiempo de cálculo para el entrenamiento, considerando la función anteriormente citada, es inferior al minuto.

4.2 Validación de la RNA

La validación del modelo se realizó considerando un nuevo conjunto de datos de entrada, mediante la elección de dos recintos con varias configuraciones acústicas interiores, considerando un total de 480 casos.

Para cuantificar el error entre los valores modelados y estimados de la función de corrección C (obtenidos a partir del nivel de propagación sonora (SP) modelado y predicho, respectivamente), se utilizaron los siguientes estimadores estadísticos: la raíz del error cuadrático medio ($RMSE$), el error máximo absoluto (MAE) y el coeficiente de correlación (R^2).

En la tabla 2 se muestra el desempeño logrado por el modelo de RNA, para cada banda de octava, tanto para la estimación de la función de corrección C como del nivel SP .

Puede observarse que la red muestra un buen ajuste en la predicción, sin grandes variaciones para las distintas bandas de octava. Se observan, coeficientes de correlación R^2 bastante altos, con valores que van desde 0,94 a 0,92 para la estimación de C y valores desde 0,97 a 0,95 para la estimación del nivel SP . Los errores RMSE obtenidos son aceptables, con rangos entre 0,05 a 0,07 y 1,24 a 1,50 para los valores estimados de C y SP , respectivamente.

Tabla 2. Eficacia en la predicción de los coeficientes C , en función de la raíz cuadrada del error medio (RMSE), del error medio absoluto (MAE) y del coeficiente de correlación (R^2) para las distintas bandas de octava.

Frecuencia [Hz]	Estimadores	RMSE	MAE	R2
250	$C=SP/SP_{sab}$	0,07	0,14	0,92
	SP	1,24	2,66	0,97
500	$C=SP/SP_{sab}$	0,07	0,17	0,92
	SP	1,27	3,44	0,96
1000	$C=SP/SP_{sab}$	0,07	0,15	0,93
	SP	1,40	4,04	0,95
2000	$C=SP/SP_{sab}$	0,05	0,12	0,94
	SP	1,50	4,30	0,95

En la figura 2, se presentan las correlaciones entre las predicciones de la función de corrección C y del nivel SP y los correspondientes valores modelados, para la banda de octavas de 1000 Hz.

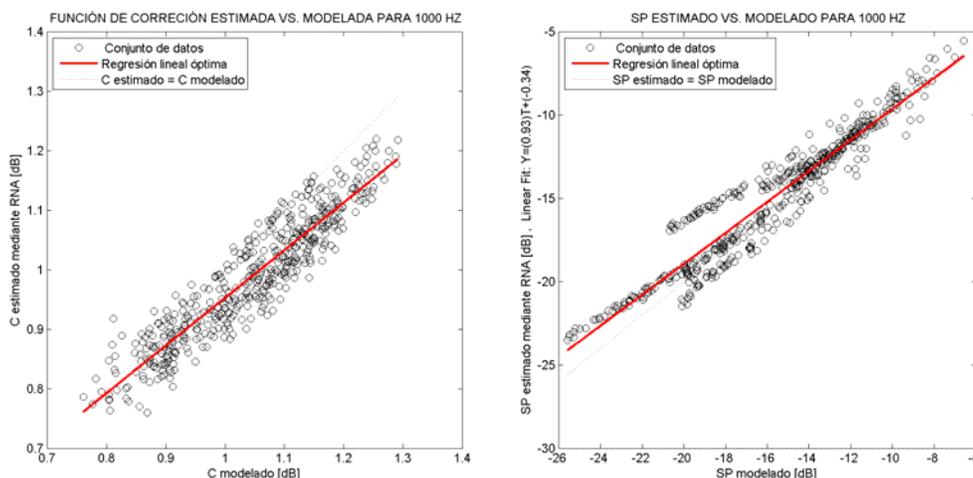


Figura 2. Eficacia en la estimación de la función de corrección C (izquierda) y el nivel de propagación sonora SP (derecha) para la frecuencia de 1000 Hz.

En la figura 3, se muestra una comparación entre los niveles SP modelados (a partir del software SoundPlan) y aquellos estimados por los modelos de RNA, de Sabine y de caja gris (éste último determinado a partir del coeficiente de corrección C), para un recinto con una configuración geométrica y acústica acotada al conjunto de datos de validación.

A partir de la figura 3 puede observarse que, mientras el modelo de Sabine considera un campo sonoro reverberante uniforme, el modelo de caja gris (modelo de Sabine modificado) tiene en cuenta las variaciones sonoras en el campo lejano mejorando las propiedades de interpolación con respecto al modelo de RNA (las propiedades de predicción de este último, están supeditadas a la suficiente cantidad de datos y al error de los mismos introducido durante la fase de entrenamiento).

Por otra parte, al considerar regiones fuera del dominio del entrenamiento, el modelo de RNA presenta un pobre desempeño, mientras que el modelo de caja gris mejora las

propiedades de extrapolación a partir de la estrategia descrita en la sección 2.

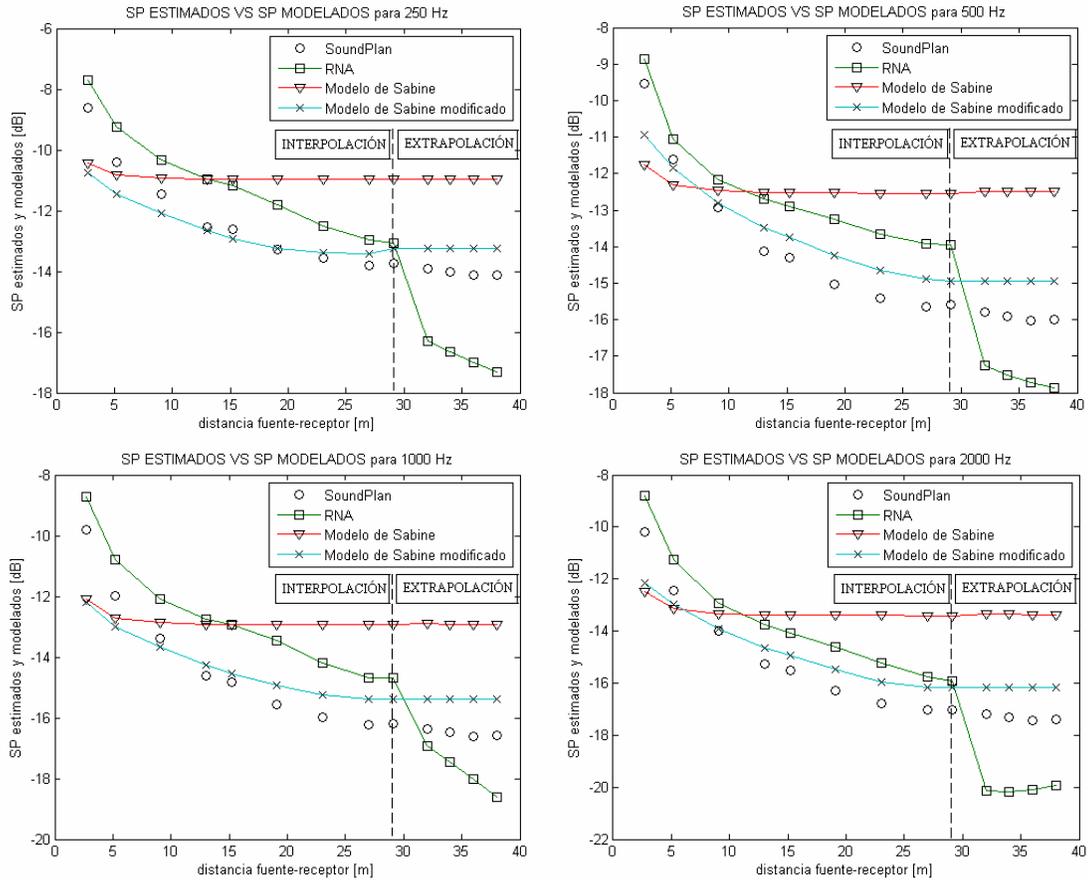


Figura 3. Comparación entre el nivel *SP* modelado mediante Soundplan y aquellos aproximados por los distintos modelos estudiados para las bandas de octava desde 250 a 1000 Hz, considerando un recinto de $32 \times 4 \times 3,5 \text{ m}^3$, con las siguientes características acústicas: $\alpha_{\text{pared}} = 0,35; 0,6; 0,7 \text{ y } 0,75$; $\alpha_{\text{cielorraso}} = 0,07; 0,08; 0,08 \text{ y } 0,09$ para las bandas de octava de 250, 500, 1000 y 2000 Hz, respectivamente.

5 Conclusiones

A partir del modelo de campo difuso de Sabine, se formuló, mediante un enfoque de redes neuronales, un método simple y efectivo para predecir la distribución no uniforme de los niveles sonoros en recintos industriales.

El modelo de caja gris resultante combina el conocimiento limitado de la acústica de recintos dado por la formulación de Sabine (caja blanca) con una RNA (caja negra) a los efectos de obtener un factor de corrección de la fórmula mencionada donde ésta es imprecisa.

Para ello y a partir de la simulación de numerosos escenarios empleando el software comercial SoundPlan, se obtuvo el nivel de propagación sonora *SP*, el cual se utilizó para determinar la función de corrección *C* y entrenar la RNA tipo perceptron multicapa.

Esta función de corrección modifica el modelo de Sabine y le permite considerar las variaciones en el campo reverberante debidas principalmente a geometrías desproporcionadas y a los efectos acústicos no uniformes como la colocación de diferentes materiales

absorbentes en las superficies interiores.

En tal sentido, esta metodología presenta ciertas ventajas en comparación con la utilización de un modelo de RNA que obtenga directamente el nivel SP, a saber:

- a) Dado un mismo conjunto de entrenamiento, la precisión del presente modelo de caja gris es superior a un modelo directo de RNA.
- b) El costo computacional para la generación de la base de datos necesaria para entrenar la red es menor con respecto a un modelo de caja negra.
- c) Se mejoran las propiedades de extrapolación espacial.

Agradecimientos

Este trabajo ha sido auspiciado por la Secretaría de Ciencia y Tecnología de la Universidad Tecnológica Nacional, Proyecto “Contaminación Acústica en Ambientes Urbanos e Industriales”, Código: 25/B017.

Referencias

- Bishop, C.M. (1995). “Neural Network for pattern recognition”. Clarendon Press, Oxford, U.K.
- Braunstein + Berndt GmbH. (2004). “User’s Manual for SoundPlan LLC”. New York.
- Cammarata, G., Cavalieri, S. and Fichera, A. (1995). “A Neural Network Architecture for Noise Prediction”. *Neural Networks* (8) 6, 963-973.
- Cortínez, V. y Sequeira, M. (2009). “Un enfoque híbrido para el rediseño acústico óptimo de recintos industriales”. *Mecánica Computacional Vol. XXVIII*.
- Gardner, M.W. and Dorling, S.R. (1998). “Artificial Neural Networks (The Multi Layer Perceptron), A Review of Applications in the Atmospheric Sciences”. *Atmospheric Environment* 32,2627-2636.
- Gerges, S.N.Y. y Arenas, J.P. (2004). “Fundamentos y Control del Ruido y Vibraciones”. NR Editora, Florianópolis, Brasil.
- Giron, P., Sequeira, M., Azzurro, A. y Cortínez, V. (2005). “Control de ruido industrial mediante un modelo computacional: estudio de caso”. *Mecánica Computacional Vol. XXIV* 2325-2341.
- Hodgson, M. (2003). “Ray-tracing evaluation of empirical models for predicting noise in industrial workshops”. *Journal of Applied Acoustics* 64,1033-1048.
- Mungiole, M. and Wilson, D. (2006). “Prediction of outdoor sound transmission loss with an artificial neural network”. *Journal of Applied Acoustics* 67,324-345.
- Nannariello, J. and Fricke, F. (1999). “The prediction of reverberation time using neural network analysis”. *Journal of Applied Acoustics* 58,305-325.
- Nannariello, J., Hodgson, M. and Fricke, F. (2001a). “Neural network predictions of speech levels in university classrooms”. *Journal of Applied Acoustics* 62,749-767.
- Nannariello, J. and Fricke, F. (2001b). “The use of network analysis to predict the acoustic performance of large rooms Part I. Predictions of the parameter G utilizing numerical simulations”. *Journal of Applied Acoustics* 62,917-950.
- Nannariello, J. and Fricke, F. (2001c). “The use of neural network analysis to predict the acoustic performance of large rooms Part II. Predictions of the acoustical attributes of concert halls utilizing measured data”. *Journal of Applied Acoustics* 62, 951-977.
- Nelles, O. (2001). “Nonlinear System Identification”. Springer, Berlin.
- Ondet, A. and Sœur, J. (1994). “Development and validation of a criterion for assessing the acoustic performance of industrial rooms”. *Journal of the Acoustical Society of America* 97,1727-1731.
- Reich, S.L., Gomez, D.R. and Dawidowski, L.E. (2009). “Artificial neural network for the identification of unknown air pollution sources”. *Journal of Atmospheric Environment* 33,3045-3052.
- Sequeira, M. y Cortínez, V. (2009). “El uso de redes neuronales para identificación de fuentes de ruido industrial”, *Jornadas Argentinas de Informática* 38,110-124.