

## UN ENFOQUE HÍBRIDO PARA EL REDISEÑO ACÚSTICO ÓPTIMO DE RECINTOS INDUSTRIALES

Victor H. Cortinez<sup>a,b</sup> y Martín E. Sequeira<sup>a</sup>

<sup>a</sup>*Centro de Investigaciones en Mecánica Teórica y Aplicada (CIMTA), Universidad Tecnológica Nacional (FRBB), 11 de Abril 461, 8000, Bahía Blanca, Argentina, vcortine@frbb.utn.edu.ar, <http://www.frbb.utn.edu.ar>*

<sup>b</sup>*Consejo Nacional de Investigaciones Científicas y Tecnológicas, (CONICET), Argentina, <http://www.conicet.gov.ar>*

**Palabras Claves:** redes neuronales, ruido industrial, identificación, diseño.

**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, caracterizando adecuadamente las fuentes que originan el ruido.

Existen diversos modelos computacionales para este fin, pudiéndose utilizar desde simples formulaciones analíticas hasta métodos más complejos basados en acústica geométrica. Sin embargo, en muchos casos, los modelos mencionados en primer término, presentan ciertas restricciones ya sea por su imprecisión en la predicción del campo sonoro o por su limitación en función de la geometría del recinto analizado, mientras que los últimos tiene, en general, un alto costo computacional.

Un enfoque alternativo, para modelar las distintas relaciones acústicas envueltas en este tipo de situaciones, es el uso de las redes neuronales artificiales (RNA). Esta herramienta proporciona un método robusto para resolver problemas de clasificación y predicción, permitiendo una gran flexibilidad y precisión. A través de un proceso de entrenamiento, las RNA son capaces de determinar relaciones no- lineales entre un conjunto de datos, asociando a variables de entrada la o las salidas correspondientes.

En tal sentido, en el presente trabajo se propone un enfoque que combina la estructura teórica de un modelo acústico con una RNA, para estimar las variaciones del campo sonoro en una familia de recintos industriales considerando diversas características geométricas y acústicas.

Finalmente, el modelo resultante, se combina con la técnica de recocido simulado para desarrollar un diseño acústico óptimo.

## 1 INTRODUCCIÓN

El ruido industrial, asociado a los procesos productivos, se ha convertido en un importante problema ocupacional que afecta a los operarios. Por tal motivo el control de este tipo de contaminación constituye una actividad de importancia en prácticamente cualquier establecimiento industrial, más aun considerando las cada vez más exigentes regulaciones laborales (Gerges, 2004).

El diseño acústico de los recintos industriales se basa en 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 o empíricas que describen esencialmente relaciones entre los niveles sonoros en el ambiente específico (*NPS*) y las potencias de las fuentes generadoras (*NWS*), a través de un coeficiente de influencia.

Esto implica una disminución en los tiempos computacionales pero, muchas veces, con una reducción de la precisión en función de la elección de las variables involucradas en la determinación de dicho coeficiente, relacionado directamente con la complejidad de la situación industrial considerada.

A este coeficiente se lo conoce como nivel de propagación sonora (*SP* (dB)) y describe la manera en que las características geométricas y acústicas del recinto y los objetos distribuidos en su interior afectan la variación del nivel de presión sonora, en función de la distancia desde la fuente, independientemente del nivel de potencia sonora de la misma.

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

Recientemente, se ha ido incrementando el uso de esta técnica en el área de acústica como herramienta de predicción de distintas variables debido principalmente a su gran flexibilidad relacionada con la precisión y complejidad de los parámetros involucrados (Nannariello et. al, 1999, 2001a, b, c ; Nagendra and Khare, 2004 ; Mungiole and Wilson, 2006).

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).

En este trabajo se obtiene el valor de *SP* empleando la técnica de *RNA*, para una familia de recintos industriales, a partir de considerar valores muy precisos mediante un modelo computacional de trazado de rayos.

Una vez obtenida la *RNA*, es posible incorporarla dentro de un modelo analítico para predecir las variaciones del campo sonoro en recintos multi-fuentes con características geométricas y acústicas particulares.

Este enfoque proporciona un método eficiente y de bajo costo computacional para poder abordar problemas de optimización considerando múltiples escenarios.

El modelo híbrido resultante, se utiliza entonces, para realizar un rediseño acústico óptimo en un recinto industrial multi-fuente en donde los niveles sonoros globales no deben superar cierto valor límite establecido.

Es decir, en primer lugar, se identifican, las potencias y ubicaciones de las fuentes sonoras y características acústicas preexistentes, a partir de la medición del campo sonoro en diferentes puntos del recinto y luego se realiza un diseño acústico óptimo, estudiando los efectos que producen ciertas modificaciones técnicas tales como instalación de material absorbente en las superficies interiores y/o encapsulamiento de las fuentes sonoras.

Para ello, se emplea una técnica de optimización matemática conjuntamente con el modelo híbrido aludido.

El problema de optimización resultante está caracterizado por la existencia de varios mínimos relativos, lo que dificulta la aplicación de enfoques clásicos, tales como aquellos basados en gradiente. Por tal motivo, se propone utilizar el método de recocido simulado (SA, “simulated annealing”).

Este enfoque evita la convergencia hacia mínimos locales y no requiere el cálculo del gradiente de la función objetivo, lo cual lo hace especialmente apto para analizar problemas de optimización con variables discretas.

Este artículo, presenta la siguiente estructura: En la sección 2 se muestra la formulación del problema a partir del modelo acústico general y el problema de rediseño óptimo. La sección 3 describe la metodología implementada para el desarrollo del modelo acústico híbrido y el método de optimización empleado. La sección 4 muestra los resultados numéricos en función de la eficacia lograda por el modelo de RNA y un rediseño acústico óptimo de una situación particular. Finalmente, en la sección 5 se presentan las conclusiones.

## 2 FORMULACIÓN DEL PROBLEMA

### 2.1 Modelo acústico general

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  $SP$ , en dB.

Este nivel describe como las características geométricas y acústicas del recinto y los objetos distribuidos en su interior afectan la variación del campo sonoro, independientemente del nivel de potencia sonora de la fuente considerara.

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  $f$ .

A partir de esto, los valores del nivel de presión sonora quedan determinados en la forma:

$$NPS_{ijf} = \beta_{jf} NWS_{jf} + SP_{ijf}, \text{ en dB.} \quad (3)$$

donde  $NPS_{ijf}$  representa el nivel de presión sonora, 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  $f$ .

$\beta_{jf}$  representa la atenuación introducida por un potencial encapsulamiento acústico para cada fuente  $j$  y en cada frecuencia  $f$  (este coeficiente solo se considera en el problema de optimización, a los efectos de evaluar un posible encapsulamiento de la fuente, y adopta el valor de 1 para la presente expresión).

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

Para la determinación de nivel de presión sonora total es necesario considerar la suma de los efectos, en cada punto del recinto, generado por cada fuente y en cada banda de frecuencia. Esto se realiza de la siguiente manera:

$$NPS_{if} = 10 \log_{10} \left( \sum_{j=1}^M 10^{(NPS_{ijf}/10)} \right), \text{ en dB.} \quad (4)$$

donde  $NPS_{if}$  representa la contribución sumada de todas las fuentes  $j$  existentes en el recinto para cada banda de frecuencia  $f$  y  $M$  es el número total de fuentes.

Finalmente, es posible obtener el nivel de presión sonora total en cada punto receptor  $i$  del recinto, considerando la adición de efectos en todas las bandas de frecuencias consideradas  $Nf$ .

Este nivel queda expresado de la siguiente manera:

$$NPS_i = 10 \log_{10} \left( \sum_{f=1}^{Nf} 10^{(NPS_{if}/10)} \right), \text{ en dB.} \quad (5)$$

En el presente trabajo, se pretende obtener los valores de  $SP$  mediante la generación de un modelo de red neuronal, a partir de la modelación de un conjunto de recintos industriales empleando una técnica computacional de trazado de rayos.

## 2.2 Rediseño óptimo de recintos industriales

Se entiende como rediseño óptimo aquella situación en la cual se mejoran las condiciones acústicas preexistentes en un recinto industrial. Esta tarea consta de 2 partes fundamentales, por un lado la identificación de las distintas variables involucradas en el escenario inicial y por el otro, el rediseño acústico de mejoras en función de ciertas restricciones impuestas.

### 2.2.1 Formulación del problema de identificación

Con el propósito de realizar predicciones acústicas que permitan evaluar el efecto de estrategias de mitigación, se deben identificar en forma previa las fuentes que originan el campo sonoro y sus ubicaciones, además de las características acústicas de los materiales interiores. Esto no siempre es una tarea fácil, como en el caso de recintos industriales multi-fuentes con producción continua, donde no es posible determinar directamente la contribución de cada fuente.

En tal sentido, es posible identificar todas las fuentes simultáneamente a partir de una cierta cantidad de receptores distribuidos dentro el recinto (Luzzato et. al, 1986 ; Cortínez et. al, 2007a; Cortínez et. al, 2007b).

El problema de identificación consiste, entonces, en la determinación de las coordenadas y las potencias sonoras de las fuentes y las características de los materiales interiores de tal

manera que se minimice una función  $F$  que mide la diferencia, en un sentido de mínimos cuadrados, entre los valores “modelados” de los  $NPS$  y los obtenidos teóricamente a partir de los valores estimados de  $SP$  del modelo de RNA, según la expresión (4).

Consecuentemente la función objetivo  $F$  se expresa de la siguiente manera:

$$\left\{ \begin{array}{l} F = \sum_{i=1}^N (NPS_{i[\text{reales}]} - NPS_{i[\text{estimados}]})^2 \\ \text{sujeto a} \\ x \min_j \leq x_j \leq x \max_j \\ y \min_j \leq y_j \leq y \max_j, j = 1 : M \end{array} \right. \quad (6)$$

Siendo  $x_j$  e  $y_j$  coordenadas de la fuente  $j$ ,  $M$  en número total de fuentes y  $N$  el número total de receptores (se ha supuesto que la coordenada vertical  $z$  es conocida tanto para los fuentes como para los receptores).

### 2.2.2 Formulación del problema de diseño óptimo

Se pretende disminuir los niveles de presión sonora globales mediante la aplicación de diferentes calidades de material absorbente, asociados a los coeficientes de absorción de las superficies interiores y/o implementación de cerramientos acústicos (encapsulamientos) sobre las fuentes sonoras, asociados a los coeficientes de atenuación  $\beta_{jf}$  en la expresión (3).

El diseño acústico se plantea de tal manera de minimizar los costos de instalación bajo la restricción de que en ningún punto del recinto se sobrepase un valor admisible del nivel sonoro resultante.

En consecuencia, el problema de optimización se formula de la siguiente manera:

$$\left\{ \begin{array}{l} \text{Min} \quad C(X) = \sum_{i=1}^{NS} C_i X_i + \sum_{j=1}^M C_j X_j \\ \text{sujeto a} \\ NPS_{total} \leq 90 \text{ dB} \end{array} \right. \quad (7)$$

donde  $C$  es la función objetivo (Costo de instalación);  $NS$  es el número total de superficies de absorción posibles (los 4 paredes y el techo);  $M$  el número total de máquinas;  $C_j$  el costo de encapsular la máquina  $j$  y  $C_i$  el costo por unidad de superficie, en función del coeficiente de absorción utilizado, para la superficie  $i$ .

La variable de diseño  $X$  tiene dimensión  $1 \times (NS+M)$  y está definida en función de los valores posibles (en bandas de octavas) que pueden tomar tanto los coeficientes de absorción de las superficies consideradas como así también los valores de pérdida de transmisión de los encapsulamientos de las fuentes.

## 3 METODOLOGÍA

A continuación se presenta la metodología empleada para desarrollar el modelo acústico, basado en la técnica de red neuronal. Finalmente se detalla el método de optimización empleado para el rediseño óptimo.

### 3.1 Desarrollo del modelo acústico: Simulación de escenarios

En el presente trabajo, se obtuvieron los niveles de propagación sonora (*SP*) 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 acústico: Construcción de las redes neuronales artificiales

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 consideraron dos tipos de estructuras de red neuronal para predecir los valores del nivel de propagación sonora, *SP*: el perceptron multicapa (MLP) y el modelo de regresión generalizada (GRNN), siendo este último, un caso especial de las redes de funciones de base radial (RBF).

#### 3.2.1 Modelo 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 utilizó las funciones transferencia tangente hiperbólica para las neuronas de la capa oculta y lineal para la neurona de salida.

La salida estimada  $\hat{SP}_i$  (el nivel de propagación sonora) del perceptrón multicapa con una capa oculta esta dada por la siguiente ecuación:

$$\hat{SP}_i = g_1 \left( \sum_{j=0}^L w_{ji} \left( g_2 \sum_{k=0}^N w_{jk} x_k \right) \right). \quad (8)$$

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:

$$mse = \frac{1}{M} \sum_{i=1}^M (\hat{SP}_i - SP_i)^2. \quad (9)$$

donde  $\hat{SP}_i$  es la salida estimada por la red neuronal e  $SP_i$  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:

$$msereg = \gamma \cdot mse + (1 - \gamma) \cdot msw. \quad (10)$$

siendo  $\gamma$  la tasa de performance y:

$$msw = \frac{1}{N} \sum_{i=1}^N w_i^2. \quad (11)$$

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  $\gamma$ . Para ello, los pesos se asumen como variables aleatorias con distribuciones especificadas. El parámetro  $\gamma$  se asocia con las varianzas de dichas distribuciones, por lo que luego se lo estima utilizando técnicas estadísticas.

### 3.2.2 Modelo de Red neuronal de regresión generalizada (GRNN)

Las Redes de Regresión Generalizada (GRNN) son un tipo de Redes de Funciones de Base Radial (RBF) normalizadas, donde existen tantas neuronas en la capa oculta como vectores de entrada existen en el conjunto de entrenamiento.

Esta red aproxima la función que existe entre las entradas y las salidas, empleando la técnica estadística de regresión no-lineal (Specht, 1991; Nelles, 2001).

Posee la propiedad deseable de no requerir ningún entrenamiento iterativo, es decir, puede aproximar cualquier función arbitraria entre vectores de entrada y salida, realizando la estimación de la función directamente a partir de los datos de entrenamiento.

En términos generales, durante el entrenamiento cada vector de entrada es asignado a una neurona de la capa oculta, y la salida deseada se dispone a manera de los pesos que unen su vector de entrada con las neuronas de salida.

Es así que el entrenamiento es en un solo paso (hacia adelante) y su estructura garantiza un mejor desempeño conforme el conjunto de entrenamiento es mayor.

La desventaja principal de este modelo es que la memoria que requiere en su capa de proceso crece linealmente con el aumento del número de patrones presentados en el entrenamiento.

El valor de la salida puede ser estimado a partir de:

$$\hat{SP}_k = \frac{\sum_{j=1}^N \hat{SP}_{jk} h_j}{\sum_{j=1}^N h_j} \quad (12)$$

donde  $N$  es el número de neuronas en la capa oculta;  $\hat{SP}_{jk}$  es la salida deseada  $k$  cuando  $j$  es el vector de entrada y  $h_j$  es la salida del neurona en la capa oculta (función de transferencia o activación), determinada según la siguiente expresión:

$$h_j(x) = \exp\left(\frac{-\|x - \mu_j\|^2}{2\sigma_j^2}\right) \quad (13)$$

Esta expresión es una función multi-variable gaussiana, donde  $h_j(x)$  es la salida de la neurona de la capa oculta  $j$ ;  $x$  es el vector de entrada;  $\mu_j$  es el vector determinado por los centros de la neurona de la capa oculta  $j$  y  $\sigma$  es el parámetro de normalización o factor de escala y mide la "anchura" de la curva gaussiana. Este coeficiente está directamente relacionado con las habilidades de generalización de la red (controla la dispersión de la función y, por lo tanto, la suavidad de la aproximación).

Es decir, las neuronas de la capa oculta calculan la diferencia (a través de la distancia euclidiana) entre el vector de entradas y los pesos sinápticos, denominados centroides, y a esta diferencia le aplican una función radial con forma gaussiana.



Cuando la distancia entre  $x$  y  $\mu_j$  decrece, la función crece. Su máximo sucede cuando esta diferencia es igual a 0, momento en el cual la función devuelve 1. Cuando presentamos un vector de entrada, cada neurona de la capa oculta, con funciones de transferencia de base radial, darán una u otra salida dependiendo de lo cerca que está el vector de entrada de los pesos sinápticos.

Así las salidas son un promedio pesado de los valores deseados de los casos de entrenamiento cercanos al patrón de entrada. Los únicos parámetros libres que deben adaptarse son las dispersiones ( $\sigma$ ). En consecuencia no es necesario “adaptar” los pesos de las conexiones a través de un entrenamiento repetitivo, lo que se traduce en una mayor velocidad de aprendizaje, dado que el único proceso es la ubicación de los centros y el ajuste de los valores de  $\sigma$ .

Una vez finalizado el entrenamiento de ambas redes, se comprueba la eficiencia realizando la validación de la misma mediante la modelación de un conjunto de datos de entrada para los cuales no se conocen los valores de salida.

### 3.3 Método de recocido simulado (SA, “simulated annealing”)

El método de recocido simulado es una técnica heurística de optimización combinatoria basada en una generación random de soluciones factibles cuya principal característica es la de evitar convergencia local en problemas de gran escala (Burkard and Rendl, 1988). El nombre de este método deriva de un proceso termodinámico de recocido (annealing), en el cual se somete un metal a una máxima temperatura de forma tal que se funda, luego se va disminuyendo la temperatura lentamente de manera que el metal fundido tienda a solidificarse hasta alcanzar un equilibrio térmico caracterizado por una energía mínima. Un esquema controlado de disminución de la temperatura evita defectos en el metal.

La optimización basada en esta técnica permite determinar diseños cuasi-optimales buscando la mejor solución sin necesidad de asegurar la correcta elección de un punto inicial de búsqueda como se requiere en los algoritmos basados en descenso del gradiente.

En un problema de optimización estos algoritmos comienzan con una solución factible inicial  $X_0$  y genera sucesivamente, a partir de ella, nuevas soluciones que son aceptadas como soluciones actuales de acuerdo a un cierto criterio probabilístico definido como:

$$P(\text{aceptar } X_i) = \begin{cases} 1 & \text{si } \delta < 0 \\ e^{-\frac{\delta}{kT}} & \text{si } \delta > 0 \end{cases} \quad (14)$$

Donde  $k$  es un factor de escalamiento conocido como constante de Boltzmann y  $\delta = f(X_{i+1}) - f(X_i)$ , representa el cambio en la función objetivo, donde  $f$  es la función objetivo y  $T$  es el parámetro conocido como temperatura.

A medida que el algoritmo avanza se va disminuyendo  $T$  de manera tal de disminuir la probabilidad de aceptar soluciones factibles que no produzcan una mejora en la función objetivo. En la figura 1 se presenta el diagrama de flujo del algoritmo general del método de recocido simulado empleado, donde  $T_i$  y  $T_f$  son la temperatura inicial y final, respectivamente (parámetro de control) y  $iter$  es el número de veces que se repiten las iteraciones internas manteniendo constante la temperatura.

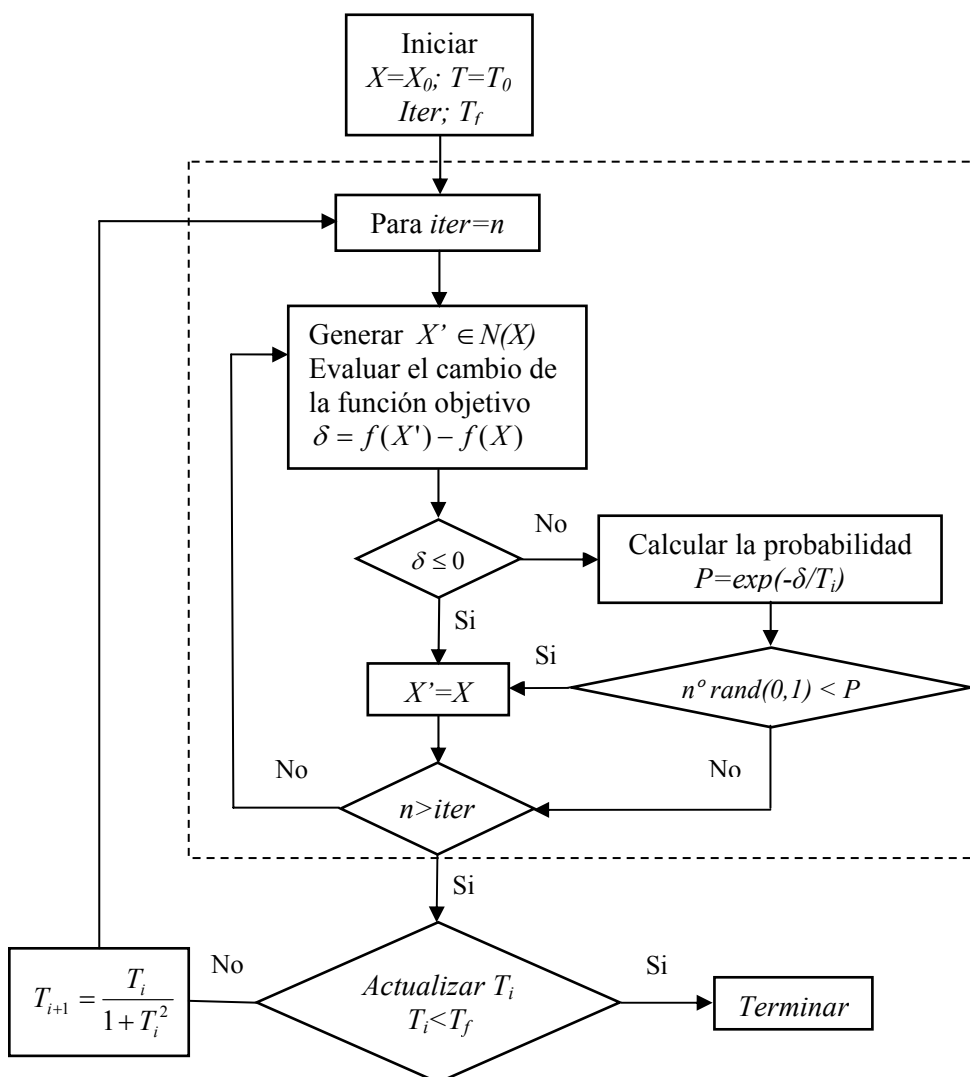


Figura 1: Diagrama de flujo del algoritmo Recocido Simulado empleado.

El valor inicial  $T_i$ , se debe determinar de manera de producir una alta aceptación de soluciones factibles propuestas.

La función que determina y controla el descenso de la temperatura, juega un rol fundamental en la eficiencia del método. El esquema más utilizado por distintos autores es el esquema geométrico en el cual se disminuye la temperatura de acuerdo al siguiente criterio:

$$T_{i+1} = \alpha \cdot T_i \text{ con } \alpha \in (0,1) \quad (15)$$

con  $\alpha$  elegido de manera adecuada, en general  $\alpha \in (0.3, 1)$ .

Sin embargo, aún obteniendo buenas soluciones, el principal inconveniente que presentan estos algoritmos es el tiempo de ejecución necesario para obtener las mismas. En algunos casos resultan más costosos que si se aplicara un método de resolución enumerativo (Lundy and Mess, 1986).

En este trabajo se presenta una nueva estrategia (Vidal, 2003) para disminuir la temperatura cuyo principal objetivo es establecer parámetros de manera de obtener un equilibrio entre el tiempo final de ejecución del algoritmo y el número de búsquedas que realice el mismo. La misma consiste en disminuir la temperatura de acuerdo al siguiente

esquema:

$$T_{i+1} = \frac{T_i}{1 + T_i^2} \quad (16)$$

Con esta nueva propuesta se logra disminuir la temperatura más rápidamente al inicio algoritmo. El efecto más importante de esto es evitar aceptar en un comienzo la mayoría las soluciones factibles y en consecuencia reducir el elevado costo inicial que presentan la mayoría de estos algoritmos.

La implementación de este nuevo esquema muestra una sorprendente efectividad, relacionada tanto en una excelente calidad de las soluciones obtenidas como en la disminución substancial del tiempo de ejecución del algoritmo.

## 4 RESULTADOS NÚMERICOS

A continuación se presentan las consideraciones generales para el entrenamiento de las RNA y luego se procede a verificar la eficacia de predicción mediante el proceso de validación. Finalmente se abordará un problema de rediseño acústico óptimo de un recinto industrial multi-fuente con características geométricas y acústicas dentro del rango de entrenamiento.

### 4.1.1 Obtención de los datos de entrada y construcción de los modelos de RNA

Los datos utilizados en la confección de los modelos de RNA se obtuvieron mediante simulación computacional.

Para ello se modelaron 10 recintos industriales con diferentes geometrías y configuraciones acústicas interiores, considerando en todos los casos, materiales de construcción típicos.

Se tuvieron en cuenta distintas densidades de objetos en el interior de cada recinto y diferentes tratamientos acústicos sobre sus superficies interiores.

Los materiales absorbentes en las paredes se consideraron ubicados a partir de 2 metros de altura a fin de considerar una situación industrial más real. Los coeficientes de absorción tanto del piso como de los objetos interiores 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 y densidades de objetos), consiguiéndose un conjunto total de 4332 casos.

A partir de esto, en cada punto receptor se determinó el nivel  $SP$  para cada bandas de octavas, desde 250 a 2000 Hz, considerando cada una de las configuraciones anteriormente mencionadas.

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

A partir de esto, se analizaron las posibles variables de entrada a las RNA para determinar cuales de ellas eran las más importantes en la estimación del nivel de propagación sonora

(SP). Se utilizaron varios criterios para tal fin, considerándose un análisis de sensibilidad de las variables involucradas como así también, consultando diversas publicaciones pertinentes (Ondet and Sueur, 1994; Hodgson, 2003).

Además, se tuvo en cuenta para la elección, la simplicidad en la obtención de las mismas al considerar situaciones reales.

Parámetro	Símbolo	Unidad	Rango del parámetro
Largo	$L$	m	12 / 32
Ancho	$W$	m	4 / 10
Altura	$H$	m	3.5 / 8
Densidad de objetos	$q_{fit}$	1/m	0.0001 / 0.2
Coordenada $x$ del receptor	$Rx$	m	1 / 31
Coordenada $y$ del receptor	$Ry$	m	0.5 / 9.5
Coordenada $x$ de la fuente	$Fx$	m	2 / 26
Coordenada $y$ de la fuente	$Fy$	m	1 / 9
Distancia fuente-receptor	$distFR$	m	1.12 / 29.95
Coeficiente de absorción en cada pared por banda de octavas	$\alpha_{pared\ 250}$	---	0.07 / 0.35
	$\alpha_{pared\ 500}$	---	0.08 / 0.6
	$\alpha_{pared\ 1000}$	---	0.08 / 0.7
	$\alpha_{pared\ 2000}$	---	0.09 / 0.75
Coeficiente de absorción en el techo por banda de octavas	$\alpha_{techo\ 250}$	---	0.07 / 0.28
	$\alpha_{techo\ 500}$	---	0.08 / 0.66
	$\alpha_{techo\ 1000}$	---	0.08 / 0.82
	$\alpha_{techo\ 2000}$	---	0.08 / 0.82
Nivel de propagación sonora ( $SP$ ) por banda de octavas	$SP_{250}$	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

Tabla 1: Rangos de las variables utilizadas para la construcción del modelo de RNA considerando 10 recintos industriales y 4332 combinaciones posibles en función de la ubicación de receptor, la fuente y de las diferentes configuraciones acústicas interiores.

Finalmente se eligieron 10 variables como las más representativas. Las mismas son: largo del recinto ( $L$ ), sección del recinto ( $Secc: W*H$ ), densidad de objetos ( $q_{fit}$ ), coordenadas del receptor ( $Rx$  y  $Ry$ ), coordenadas de la fuente ( $Fx$  y  $Fy$ ), distancia entre la fuente y el receptor ( $distFR$ ) y el coeficiente de absorción de las paredes y del techo ( $\alpha_{pared}$  y  $\alpha_{techo}$ ).

Previo al inicio del entrenamiento de las RNA, se realizó un pre-proceso de los componentes del vector 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. La normalización es importante especialmente en el caso de la red neuronal del tipo base radial ya que la función de activación de la misma se determina a partir de la distancia euclídea entre el vector de entrada y el centro de la función de activación (Nelles, 2001).

Luego se realizó un análisis de componentes principales para completar el pre-proceso, ortogonalizando los componentes del vector de entrada de manera de que queden des-correlacionados (evita 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 mas compacta y mejora las propiedades numéricas de la optimización (entrenamiento de la red).

Finalmente, el conjunto total de 4332 datos se dividió en grupos de entrenamiento (3540 datos), verificación y validación, estos dos últimos con aproximadamente un 10 % de datos, cada uno, del conjunto total (396 datos).

El grupo de entrenamiento se utiliza para estimar los parámetros de la red, el grupo de verificación para comprobar la generalización de la RNA (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, para comprobar la capacidad de la red en reproducir datos erróneos con buena aproximación, se introdujo en el conjunto de entrenamiento una pequeña componente aleatoria con distribución uniforme y que hará las veces de “ruido” de medición, correspondiente a una aumento del 5 y 10% sobre el nivel de propagación sonora  $SP$ .

La función considerada, en cada banda de octavas, para el entrenamiento de las RNA tipo MLP y GRNN se muestran a continuación:

$$SP_f = f(L, Secc, Rx, Ry, Fx, Fy, distFR, \alpha_{techo_f}, \alpha_{piso_f}, q_{fitt_f}). \quad (17)$$

donde  $f$  representa la banda de octava de 250, 500, 1000 y 2000 Hz.

#### 4.1.2 Validación de las RNA

La validación de los modelos 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 396 casos.

Para cuantificar el error entre los valores modelados del nivel  $SP$  y los estimados mediante los modelos de RNA, se utilizaron los siguientes estimadores estadísticos: la raíz del error cuadrático medio ( $RMSE$ ), el error máximo absoluto ( $MAE$ ) y el coeficiente de correlación ( $R$ ).

Las tablas 2 a 5, muestran el desempeño logrado de los modelos de RNA tipo perceptron multicapa (MLP) y de regresión generalizada (GRNN), mediante la comparación de los distintos índices estadísticos para cada banda de octava. Se considera, además, la eficacia de predicción con los distintos porcentajes de “ruidos” de medición introducidos en la etapa de entrenamiento.

Puede observarse que, cuando no se considera ruido de medición, ambos tipos de redes (MLP y GRNN) muestran buenos ajustes en la predicción, aunque la red tipo MLP presenta errores menores en función de los indicadores utilizados.

Los diferentes índices estadísticos no presentan grandes variaciones en función de las predicciones para las distintas bandas de octavas. Se observan, coeficientes de correlación  $R^2$  bastante altos, con valores que van desde 0.98 a 0.99 y desde 0.88 a 0.91 para los modelos de RNA tipo MLP y GRNN, respectivamente.

Los errores RMSE obtenidos son aceptables, con rangos entre 0.45 a 0.59 para la red tipo MLP y entre 1.01 a 1.45 para la red GRNN.

Por otra parte, al considerar “ruidos” de medición, la eficacia de predicción de ambas redes no disminuye considerablemente.

Modelos de Red Neuronal	Sin ruido de medición			Ruido adicional (5%)			Ruido adicional (10%)		
	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>
MLP	0.59	1.46	0.98	0.64	1.53	0.97	0.79	1.78	0.96
GRNN	1.01	4.39	0.88	1.03	4.95	0.87	1.05	5.04	0.87

Tabla 2: Eficacia en la predicción de los niveles SP de los modelos de RNA, considerando distintos “ruidos” de medición, en función de la raíz cuadrada del error medio (RMSE), del error medio absoluto (MAE) y del coeficiente de correlación (R<sup>2</sup>) para la banda de 250 Hz.

Modelos de Red Neuronal	Sin ruido de medición			Ruido adicional (5%)			Ruido adicional (10%)		
	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>
MLP	0.45	1.28	0.99	0.77	1.67	0.98	0.85	1.77	0.98
GRNN	1.35	5.64	0.89	1.37	6.24	0.89	1.42	6.55	0.89

Tabla 3: Eficacia en la predicción de los niveles SP de los modelos de RNA, considerando distintos “ruidos” de medición, en función de la raíz cuadrada del error medio (RMSE), del error medio absoluto (MAE) y del coeficiente de correlación (R<sup>2</sup>) para la banda de 500 Hz.

Modelos de Red Neuronal	Sin ruido de medición			Ruido adicional (5%)			Ruido adicional (10%)		
	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>
MLP	0.51	1.27	0.99	0.8	1.68	0.98	0.85	1.76	0.98
GRNN	1.44	6.11	0.91	1.52	6.66	0.90	1.56	7.55	0.90

Tabla 4: Eficacia en la predicción de los niveles SP de los modelos de RNA, considerando distintos “ruidos” de medición, en función de la raíz cuadrada del error medio (RMSE), del error medio absoluto (MAE) y del coeficiente de correlación (R<sup>2</sup>) para la banda de 1000 Hz.

Modelos de Red Neuronal	Sin ruido de medición			Ruido adicional (5%)			Ruido adicional (10%)		
	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>	RMSE	MAE	R <sup>2</sup>
MLP	0.54	1.34	0.99	0.71	1.60	0.98	0.87	1.81	0.98
GRNN	1.45	6.25	0.91	1.57	6.85	0.90	1.87	7.67	0.90

Tabla 5: Eficacia en la predicción de los niveles SP de los modelos de RNA, considerando distintos “ruidos” de medición, en función de la raíz cuadrada del error medio (RMSE), del error medio absoluto (MAE) y del coeficiente de correlación (R<sup>2</sup>) para la banda de 2000 Hz.

En la figura 2, se presentan las correlaciones entre las predicciones del nivel de propagación sonora *SP* (sin “ruido” de medición) y los valores *SP* modelados, considerando los dos modelos de RNA, para la banda de octavas de 1000 Hz.

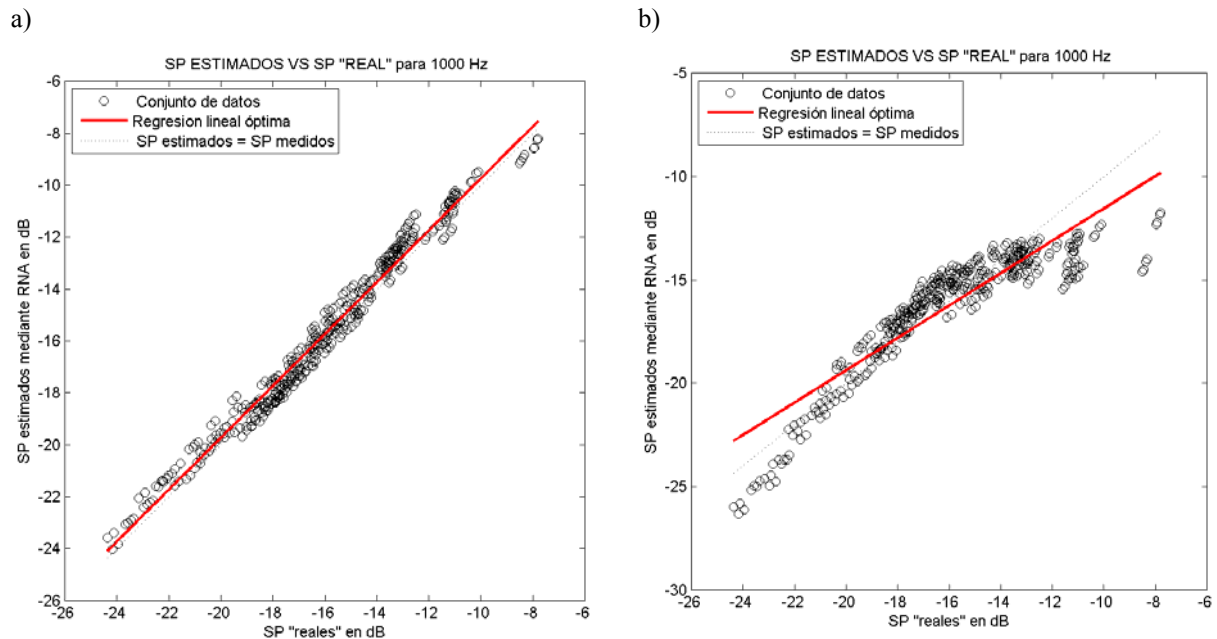


Figura 2: Eficacia en la estimación del nivel SP utilizando el conjunto de datos de validación considerando: el modelo de RNA tipo MLP (figura a) y GRNN (figura b), para la frecuencia de 1000 Hz.

En la figura 3, se muestra una comparación entre los niveles SP modelados y aquellos estimados, sin “ruido” de medición, mediante la RNA tipo MLP, considerando los 2 recintos utilizados para la validación, con configuraciones geométricas y acústicas particulares acotadas al conjunto de datos.

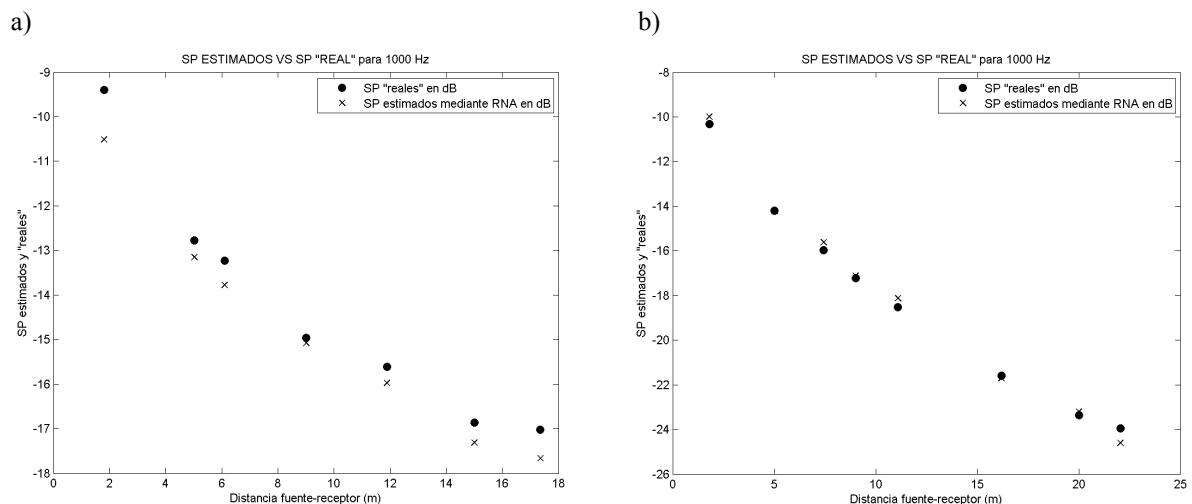


Figura 3: Comparación entre el nivel SP aproximado por la RNA tipo MLP durante la etapa de validación VS el nivel SP modelado mediante SoundPlan para la banda de octava de 1000 Hz, considerando dos recintos con diferentes características geométricas y acústicas: a) Recinto 1: 20x8x4.5 m<sup>3</sup>, densidad de objetos: 0.05 1/m,  $\alpha_{\text{pared}}$ :0.08 y  $\alpha_{\text{techo}}$ :0.69; b) Recinto 2: 25x5x6.5 m<sup>3</sup>, densidad de objetos: 0.15 1/m,  $\alpha_{\text{pared}}$ :0.45 y  $\alpha_{\text{techo}}$ :0.57.



#### 4.2 Rediseño acústico óptimo en un recinto industrial: Estudio de caso

Una vez obtenidos los modelos de redes neuronales y constatada su eficacia y rapidez en la predicción de los niveles de propagación sonora  $SP$ , se procedió a desarrollar un método de diseño acústico óptimo en un recinto industrial, previa identificación de las fuentes sonoras y de los características acústicas de los materiales interiores.

Para ello, se consideró un recinto industrial multi-fuente, de dimensiones  $20 \times 8 \times 4.5 \text{ m}^3$ , con un máximo de 6 fuentes sonoras y 20 receptores distribuidos en su interior, ambos a una altura de 1.5 metros. En la figura 4 se muestra un esquema del recinto considerado junto a las ubicaciones de las fuentes y los receptores.

Los niveles de potencia acústica de las fuentes se consideraron en bandas de octavas en el rango de 250 a 2000 Hz de igual manera que los coeficientes de absorción de las superficies interiores y de los objetos distribuidos en el interior del recinto.

Se utilizó una densidad de objetos de 0.05 1/m (la cual corresponde a un camino libre medio entre obstáculos interiores de 20 metros).

Los valores de las potencias y ubicaciones de las fuentes y de las características acústicas de los materiales empleados se presentan en las tablas 6 y 7.

Tanto los niveles de potencia sonora de las fuentes como así también los coeficientes de absorción de los materiales empleados se eligieron considerando valores que se pueden encontrar en ámbitos industriales.

Para resolver tanto problema de identificación como el de optimización, se consideró el modelo de red tipo MLP (debido a su mejor performance en cuanto a la predicción del nivel de propagación sonora  $SP$ ) con la formulación presentada en la sección 2.1, conformando, de esta manera, el modelo acústico híbrido. Finalmente se utilizó el método de recocido simulado conjuntamente con este modelo.

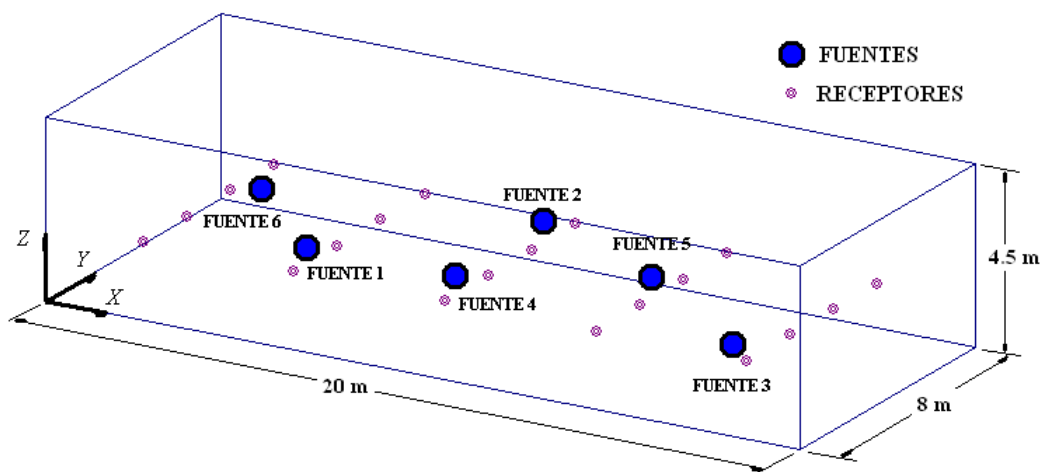


Figura 4: Esquema del recinto modelado ( $20 \times 8 \times 4.5 \text{ m}^3$ ), considerando 20 receptores y un máximo de 6 fuentes sonoras.

Nivel de potencia acústica (dB)	Ubicación (m)		Frecuencias (Hz)			
	x	y	250	500	1000	2000
Fuente 1	5.5	2.5	93	104	95	91
Fuente 2	9.5	6.5	90	91	90	87
Fuente 3	17.5	1.5	95	93	98	98
Fuente 4	9.5	2.5	98	93	88	83
Fuente 5	13.5	4.5	81	100	102	101
Fuente 6	2.5	5.5	76	92	91	90

Tabla 6: Niveles de potencia sonora, en bandas de octava, y ubicaciones de las 6 fuentes consideradas.

Material	Superficie	Frecuencias (Hz)			
		$\alpha_{250}$	$\alpha_{500}$	$\alpha_{1000}$	$\alpha_{2000}$
Sin tratamiento acústico	Paredes y piso	0.07	0.08	0.08	0.09
Lana de vidrio	Techo	0.24	0.59	0.69	0.67
Superficies metálicas	Objetos interiores	0.04	0.04	0.045	0.05

Tabla 7. Coeficientes de absorción, en bandas de octavas, de los materiales utilizados en el recinto propuesto.

#### 4.2.1 Etapa I: Identificación

Como se comentó previamente, con el propósito de evaluar el efecto de estrategias de mitigación, se deben identificar en forma previa las fuentes que originan el campo sonoro y sus ubicaciones.

Por lo tanto, en esta etapa, se identificaron las potencias y ubicaciones de 1, 3 y 6 fuentes y el coeficiente de absorción del material acústico ubicado en el techo, a los efectos de conocer las características locales de absorción de esta superficie y posteriormente calificar al material para una futura optimización.

Cabe aclarar que se podría identificar cualquier material acústico ubicado sobre cualquier superficie interior, pero en el presente trabajo solo se consideró el material absorbente existente sobre el techo.

La identificación de las potencias de las fuentes como así también del coeficiente de absorción del material en el techo se realizó considerando únicamente la banda de octavas de 1000 Hz.

Los resultados obtenidos revelan una aceptable eficacia en el proceso de identificación de las variables consideradas, como se muestra en las tablas 8 a 10.

Resultados	Variables			
	x1 (m)	y1 (m)	NWS <sub>1</sub> (dB)	$\alpha_{techo}$
Valores modelados	5.5	2.5	95	0.69
Valores estimados	5.4	2.1	95	0.69
Diferencia	0.1	0.4	0	0

Tabla 8: Identificación de la fuente 1 y el coeficiente de absorción del techo ( $\alpha_{techo}$ ). Valor de la función objetivo, F=0.02; Tiempo CPU =1.59 minutos.

Resultados	Variables									
	x1 (m)	y1 (m)	NWS <sub>1</sub> (dB)	x2 (m)	y2 (m)	NWS <sub>2</sub> (dB)	x3 (m)	y3 (m)	NWS <sub>3</sub> (dB)	$\alpha_{techo}$
Valores modelados	5.5	2.5	95	9.5	6.5	90	17.5	1.5	98	0.69
Valores estimados	6.2	1.3	95.3	10.7	6.7	90.1	18.9	1.4	97.7	0.67
Diferencia	0.7	1.2	0.3	1.2	0.2	0.1	1.4	0.1	0.3	0.02

Tabla 9: Identificación de las fuentes 1,2 y 3 y el coeficiente de absorción del techo ( $\alpha_{techo}$ ). Valor de la función objetivo, F =0.16; Tiempo CPU =2.01 minutos.

Resultados	Variables									
	x1 (m)	y1 (m)	NWS <sub>1</sub> (dB)	x2 (m)	y2 (m)	NWS <sub>2</sub> (dB)	x3 (m)	y3 (m)	NWS <sub>3</sub> (dB)	$\alpha_{techo}$
Valores modelados	5.5	2.5	95	9.5	6.5	90	17.5	1.5	98	
Valores estimados	5.4	4	95	9.7	7.8	89.8	14.8	2.9	98.1	
Diferencia	0.1	1.5	0	0.2	1.3	0.2	2.7	1.4	0.1	
Resultados	x4 (m)	y4 (m)	NWS <sub>4</sub> (dB)	x5 (m)	y5 (m)	NWS <sub>5</sub> (dB)	x6 (m)	y6 (m)	NWS <sub>6</sub> (dB)	$\alpha_{techo}$
	Valores modelados	9.5	2.5	88	13.5	4.5	102	2.5	5.5	
Valores estimados	7.6	3.1	88.4	11.8	3.5	101.6	1.2	5.9	89.2	0.66
Diferencia	1.9	0.6	0.4	1.7	1	0.4	1.3	0.4	1.8	0.03

Tabla 10: Identificación de las fuentes 1 a 6 y el coeficiente de absorción del techo ( $\alpha_{techo}$ ). Valor de la función objetivo, F =0.36; Tiempo CPU =2.56 minutos.

En la figura 5 se presentan los valores de la función objetivo a medida que el algoritmo avanza. Se observa que, en un comienzo se aceptan soluciones factibles que no mejoran el valor de la función objetivo, siendo éstas cada vez menos probables. Finalmente, alrededor de las 250 iteraciones alcanza su valor mínimo.




Figura 5: Convergencia de la función objetivo para el problema de identificación.

#### 4.2.2 Etapa II: Rediseño óptimo

En este caso, la situación considerada corresponde al mismo recinto industrial analizado previamente, donde se han detectado niveles de presión sonora mayores a los admisibles.

Se pretende disminuir estos niveles mediante la aplicación de diferentes calidades de material absorbente, asociados a los coeficientes de absorción considerados para las superficies de las paredes y el techo y/o implementación de cerramientos acústicos (encapsulamientos) sobre las fuentes sonoras, asociados a los coeficientes de atenuación  $\beta_{if}$  de la expresión (3).

En tal sentido, se consideraron 2 tipos diferentes de tratamientos acústicos sobre el techo y las paredes, a partir de coeficientes de absorción de materiales conocidos, y 2 tipos de encapsulamientos sobre las fuentes, a partir de valores de pérdida por transmisión de materiales utilizados comúnmente para estos casos. En ambas situaciones, se consideró también, como opción de diseño, no implementar ningún tratamiento acústico.

Las características de los materiales de absorción empleados así como también de las pérdidas de transmisión, se presentan en las tablas 11 y 12.

Material	Superficie	Frecuencias (Hz)			
		$\alpha$ 250	$\alpha$ 500	$\alpha$ 1000	$\alpha$ 2000
Sin tratamiento acústico		0.07	0.08	0.08	0.09
Lana de vidrio (absorción media)	Paredes	0.30	0.41	0.50	0.55
Lana de vidrio (absorción alta)		0.35	0.60	0.70	0.75
Sin tratamiento acústico		0.07	0.08	0.08	0.09
Lana de vidrio (absorción media)	Techo	0.24	0.59	0.69	0.67
Lana de vidrio (absorción alta)		0.28	0.66	0.82	0.82

Tabla 11. Coeficientes de absorción de los materiales considerados en el problema de rediseño.

Perdidas por inserción (PI) en dB	Frecuencias (Hz)			
	25 0	50 0	1000	2000
Sin PI	0	0	0	0
PI media	15	20	24	29
PI alta	22	30	34	35

Tabla 12. Perdidas por transmisión de los encapsulamientos considerados en el problema de rediseño.

A partir de los valores de pérdidas por inserción establecidos, quedan determinados los coeficientes de atenuación  $\beta_{if}$  correspondientes a la ecuación (3), como se muestra en la tabla 13.

Finalmente, los resultados obtenidos una vez aplicada la técnica de optimización, se presentan en la tabla 14. Se puede apreciar que (tabla 15), una vez implementados los tratamientos acústicos considerados, los niveles sonoros totales no superan, en ningún lugar, los 90 dB establecidos como límite.

Coeficientes $\beta_{jf}$ (dB)	Perdida por inserción (PI)	Frecuencias (Hz)			
		250	500	1000	2000
Fuente 1	Sin PI	1	1	1	1
	Media	0.84	0.78	0.74	0.69
	Alta	0.76	0.71	0.64	0.62
Fuente 2	Sin PI	1	1	1	1
	Media	0.83	0.78	0.73	0.67
	Alta	0.76	0.67	0.62	0.60
Fuente 3	Sin PI	1	1	1	1
	Media	0.84	0.78	0.76	0.70
	Alta	0.77	0.68	0.65	0.64
Fuente 4	Sin PI	1	1	1	1
	Media	0.85	0.78	0.73	0.65
	Alta	0.78	0.68	0.61	0.58
Fuente 5	Sin PI	1	1	1	1
	Media	0.81	0.80	0.76	0.71
	Alta	0.73	0.70	0.67	0.65
Fuente 6	Sin PI	1	1	1	1
	Media	0.80	0.78	0.74	0.68
	Alta	0.71	0.67	0.63	0.61

Tabla 13. Coeficientes de atenuación  $\beta_{jf}$ .

Resultados	Frecuencias (Hz)				Tipo de tratamiento acústico
	250	500	1000	2000	
$NWS_1$	0.84	0.78	0.74	0.69	atenuación media
$NWS_2$	1	1	1	1	sin encapsulamiento
$NWS_3$	0.84	0.78	0.76	0.7	atenuación media
$NWS_4$	0.85	0.78	0.73	0.65	atenuación media
$NWS_5$	0.81	0.8	0.76	0.71	atenuación media
$NWS_6$	1	1	1	1	sin encapsulamiento
$\alpha_{pared}$	0.3	0.41	0.5	0.55	atenuación media
$\alpha_{techo}$	0.07	0.08	0.08	0.09	sin tratamiento acústico

Tabla 14: Optimización de las características acústicas considerado 6 fuentes dentro del recinto. Valor de la función objetivo,  $C=707.32$ ; Tiempo CPU =7.50 minutos.

Receptor	NPS (dB)	Receptor	NPS (dB)
1	87.5	11	89.4
2	87.2	12	88.2
3	86.9	13	88.6
4	86.3	14	86.9
5	86	15	86.1
6	88.2	16	88.8
7	87.7	17	88.1
8	86.6	18	89.1
9	86	19	86.9
10	89.4	20	86.1

Tabla 15: Niveles de presión sonora (NPS) en cada uno de los receptores dentro del recinto analizado, una vez implementados los tratamientos acústicos.

Seguidamente, en la figura 6, se muestran los valores de la función objetivo Vs el n° de iteraciones. Se aprecia que alrededor de la iteración 400 se alcanza el valor óptimo deseado.




Figura 6: Convergencia de la función objetivo para el problema de rediseño.

## 5 CONCLUSIONES

A partir de la estructura teórica clásica, presente en la mayoría de los modelos acústicos empíricos, que relaciona linealmente los niveles de presión sonora con los niveles de potencia de las fuentes, se formuló, mediante un enfoque de redes neuronales, un método simple y efectivo para predecir la distribución de los niveles sonoros en recintos industriales.

Mediante esta técnica, se obtuvo el nivel de propagación sonora,  $SP$ , a partir de la simulación de numerosos escenarios empleando el software comercial SoundPlan.

Para ello se consideraron dos tipos diferentes de redes neuronales (RNA), el tipo *perceptron multicapa* (MLP) y de *regresión generalizada* (GRNN). En cada caso se utilizaron, como entradas en la fase de entrenamiento, tanto variables geométricas como acústicas, elegidas principalmente, en función de la simplicidad en la obtención de las mismas al considerar situaciones reales.

Ambos enfoques permiten predecir con gran eficacia el nivel  $SP$  y, de esta manera, considerar los efectos acústicos locales presente en esta clase de recintos, como ser objetos en su interior y diferentes materiales absorbentes en las superficies.

Además, al considerar errores en los valores de  $SP$  durante la etapa de entrenamiento, (inevitables en situaciones reales), ambos modelos aún mantienen una predicción tolerable.

A partir de esto, mediante el nivel  $SP$  estimado, se construyó un modelo analítico híbrido para predecir de manera eficiente y con bajo costo computacional, la distribución de los niveles sonoros dentro de una familia de recintos industriales.

En la etapa de validación de las RNA, los errores  $RMSE$  obtenidos sin “ruido” de medición y por bandas de octavas, fueron aceptables, con rangos entre 0.45 a 0.59 para la red tipo MLP y entre 1.01 a 1.45 para la red GRNN. Por otra parte, los coeficiente de correlación  $R^2$  presentaron valores altos, que van desde 0.98 a 0.99 y desde 0.88 a 0.91 para los modelos de RNA tipo MLP y GRNN, respectivamente.

Al incluir ruido de medición, la eficacia de predicción no disminuyó considerablemente. En todos los casos, se observó una mejor aproximación en la implementación del modelo de

red tipo MLP.

Posteriormente, se formuló un enfoque de optimización para realizar el rediseño óptimo de un recinto industrial, para minimizar los costos de implementación de soluciones técnicas, previa identificación de las potencias y ubicaciones de las fuentes sonoras y de las características acústicas interiores preexistentes.

Ambos problemas fueron resueltos en forma exitosa a través de la implementación del método de “recocido simulado” modificado. La modificación realizada consiste en un nuevo esquema de enfriamiento, que mejora la velocidad de convergencia con respecto al enfoque clásico.

A pesar de que solo se ha analizado un problema matemáticamente simple (en función de la cantidad de variables involucradas) y que el modelo de RNA es reducido (a partir de la cantidad de casos considerados), esta metodología puede ser aplicada a situaciones más generales, empleando modelos acústicos computacionales más precisos conjuntamente con la técnica de redes neuronales presentadas.

Los autores están trabajando actualmente en esta dirección.

**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. La participación de M. Sequeira en este trabajo se ha llevado a cabo gracias a una beca de posgrado otorgada por la UTN.

## REFERENCIAS

- Bishop, C.M., *Neural Network for pattern recognition*. Oxford, U.K.: Oxford Univ. Press, 1995.
- Braunstein + Berndt GmbH, *User's Manual for SoundPlan*, LLC, New York, 2004.
- Burkard, R. and Rendl, F., A thermodynamically Motivated Simulation Procedure for Combinatorial Optimization Problems. *European Journal of Operational Research*, 17:169-174, 1988.
- Cortínez, V., Vidal, M. y Girón, P., Optimización de las condiciones acústicas en recintos industriales. *Mecánica Computacional*, Vol. XXVI, 59-73, 2007a.
- Cortínez, V., Sequeira, M. y Vidal, M., Identificación de fuentes de ruido en ambientes urbanos industriales. *Contaminación Atmosférica en Argentina*. Eds: Enrique Puliafito y Nancy Quaranta. Publicación de la UTN, 2007b.
- Gardner, M.W. and Dorling, S.R., *Artificial Neural Networks (The Multi Layer Perceptron), A Review of Applications in the Atmospheric Sciences*. *Atmospheric Environment*, 32:2627-2636, 1998.
- Gerges, S. y Arenas, P., *Fundamentos y control del ruido y vibraciones*, NR Editora, Florianópolis, SC, Brasil, 2004.
- Giron, P., Sequeira, M., Azzurro, A. y Cortínez, V., Control de ruido industrial mediante un modelo computacional: estudio de caso. *Mecánica Computacional*, Vol. XXIV: 2325-2341, 2005.
- Hodgson, M., Ray-tracing evaluation of empirical models for predicting noise in industrial workshops. *Journal of Applied Acoustics*, 64:1033:1048, 2003.
- Lundy, M. and Mees, A., Convergence of an Annealing Algorithm. *Mathematical programming*, 34:111-124, 1986.
- Luzzato, E. and Lecointre, C., Some simple and effective methods for sound source identification with geometrical acoustic models. *Journal of Sound and Vibration*, 105:473-



- 496, 1986.
- Mungiole, M. and Wilson, D., Prediction of outdoor sound transmission loss with an artificial neural network. *Journal of Applied Acoustics*, 67:324-345, 2006.
- Nannariello, J. and Fricke, F., The prediction of reverberation time using neural network analysis. *Journal of Applied Acoustics*, 58:305-325, 1999.
- Nannariello, J., Hodgson, M. and Fricke, F., Neural network predictions of speech levels in university classrooms. *Journal of Applied Acoustics*, 62:749-767, 2001a.
- Nannariello, J. and Fricke, F., 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, 2001b.
- Nannariello, J. and Fricke, F., 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, 2001c.
- Nelles, O., *Nonlinear System Identification*, Springer, Berlin, 2001.
- Ondet, A. and Sueur, J., Development and validation of a criterion for assessing the acoustic performance of industrial rooms. *Journal of Acoustical Society of America*, 97:1727-1731, 1994.
- Reich, S.L., Gomez, D.R. and Dawidowski, L.E., Artificial neural network for the identification of unknown air pollution sources. *Journal of Atmospheric Environment*, 33:3045-3052, 1998.
- Sequeira, M. y Cortínez, V., El uso de redes neuronales para identificación de fuentes de ruido industrial, *Jornadas Argentinas de Informática*, 38:110-124, 2009.
- Shiva, S.M., Nagendra and Khare, M., Artificial neural network based line source models for vehicular exhaust emission predictions of an urban roadway. *Transportation Research Part D*, 9:199-208, 2004.
- Specht, D.F., *A General Regression Neural Network*, IEEE Trans. Neural Networks, Vol. 2, 1991.
- Vidal, M., Un procedimiento heurístico para un problema de asignación cuadrática. *Tesis de Magíster en Matemática*, Departamento de Matemática, Universidad Nacional del Sur, Bahía Blanca, Argentina, 2003.