

# Jornadas de Automática

## Detección y Estimación de Fugas de Aire Comprimido en Sistemas Industriales mediante Análisis de Audio

Torres, A.<sup>a,\*</sup>, Chicaiza, W. D.<sup>a</sup>, Bellucci, A.<sup>b</sup>, Escaño, Juan M.<sup>a</sup>

<sup>a</sup>Dpto. de Ingeniería de Sistemas y Automática. Universidad de Sevilla. Escuela Técnica Superior de Ingeniería. Camino de los Descubrimientos s/n, 41092, Sevilla, España

<sup>b</sup>Dpto. de Informática. Universidad Carlos III de Madrid. Avda. de la Universidad, 30, 28911, Leganés (Madrid), España

**To cite this article:** Torres, A., Chicaiza, W.D., Bellucci, A., Escaño, J.M. 2024. Compressed Air Leak Detection and Estimation in Industrial Systems by Audio Analysis. *Jornadas de Automática*, 45. <https://doi.org/10.17979/ja-cea.2024.45.10880>

### Resumen

El uso de aire comprimido es esencial en numerosos procesos industriales debido a su producción segura y manejo sencillo. Sin embargo, su generación es altamente costosa en términos energéticos, representando una fracción significativa de los costos operativos de las instalaciones industriales. Además, las fugas de aire comprimido pueden incrementar considerablemente estos costos, haciendo imperativo el desarrollo de técnicas precisas para su estimación y control. Este estudio se centra en la detección y cuantificación de fugas de aire en un sistema de aire comprimido mediante el análisis de muestras de audio, proponiendo y evaluando distintos modelos de clasificación y regresión para optimizar la eficiencia energética y operativa de la planta.

*Palabras clave:* Estimación, Detección de fallos, Garantía de calidad y mantenimiento.

### Compressed Air Leak Detection and Estimation in Industrial Systems by Audio Analysis

#### Abstract

The use of compressed air is essential in many industrial processes due to its safe production and easy handling. However, its generation is highly costly in energy terms, representing a significant fraction of the operating costs of industrial facilities. Furthermore, compressed air leakage can considerably increase these costs, making it imperative to develop accurate techniques for its estimation and control. This study focuses on the detection and quantification of air leakage in a compressed air system by analysing audio samples, proposing and evaluating different classification and regression models to optimise the energy and operational efficiency of the plant.

*Keywords:* Estimation, Fault detection, Quality assurance and maintenance

## 1. Introducción

El uso de aire comprimido es frecuente tanto en los sectores industrial como de servicios debido a su producción y manejo seguros y sencillos. En la mayoría de las instalaciones industriales, el aire comprimido es indispensable para varios procesos de fabricación (U.S. Department of Energy, 2003, 2023a).

La producción de aire comprimido requiere una cantidad significativa de energía y, en muchas operaciones industria-

les, el costo energético asociado al aire comprimido constituye una parte sustancial de los gastos energéticos totales. Los costos operativos anuales de los compresores de aire, secadores y equipos auxiliares pueden representar entre el 70 % y el 90 % de la factura total de electricidad. Además, el aire comprimido suele ser la forma de energía más cara en una planta, ya que solo el 19 % de su potencia es efectivamente utilizable (U.S. Department of Energy, 2003; Initiative, 2023).

En la Unión Europea, el aire comprimido puede represen-

tar hasta el 10 % del consumo industrial de electricidad (Initiative, 2023). Sin embargo, existe una notable falta de información fiable sobre la eficiencia energética de los sistemas típicos de aire comprimido (U.S. Department of Energy, 2023b). El desarrollo de técnicas de estimación de pérdidas por fugas de aire comprimido es importante, debido a los significativos costos asociados con dichas pérdidas. La implementación de técnicas precisas para estimar las pérdidas por fugas no solo permite identificar y reparar las fugas existentes, sino que también ayuda a prevenir futuras pérdidas, optimizando el rendimiento del sistema y reduciendo los costos operativos.

La detección temprana de fugas de aire constituye un desafío. El principal objetivo de este estudio ha sido la estimación de la fuga del aire provocado dentro de un sistema de aire comprimido a través de muestras de audio. Han sido varios los estudios previos realizados que han intentado estimar fugas de fluido en sistemas industriales a través del sonido. Sin embargo, ha destacado especialmente el estudio realizado por Yan et al. (2018) para la localización de fugas a través del uso de la transformada de Wavelet para posteriormente realizar una selección de características extraídas.

En Ullah et al. (2023) se extrayeron características del dominio temporal y frecuencial para la clasificación entre 4 tipos de fugas localizadas sobre una tubería, para distinguir entre tipo de fluido y presión a la que se encuentra.

Y en Zhu et al. (2018) plantearon un algoritmo de aprendizaje no supervisado de clusterización de distintos niveles de fuga, empleando *Fuzzy C Means* para la detección de outliers, destacando especialmente el análisis de la distribución de muestras en las dimensiones conformadas por las características extraídas.

## 2. Descripción de la planta

El laboratorio del departamento de sistemas y automática de la Escuela Técnica Superior de Ingeniería de la Universidad de Sevilla cuenta con una célula de fabricación flexible dedicada a la educación. Dicha célula consta de una serie de estaciones de trabajo automatizadas, como máquinas de perforación y dispositivos de inspección de calidad, todas ellas interconectadas mediante un sistema de transporte automatizado, como se puede apreciar en la Figura 1. Un circuito compuesto por cuatro cintas transportadoras forma la estructura principal de la célula, facilitando el transporte de materiales y productos a lo largo de la planta. Además, la célula está equipada con pistones de cambio y una variedad de dispositivos de control, como sensores inductivos y sensores de fuerza, que garantizan un funcionamiento eficiente y seguro.

La planta tiene instalada una red de aire comprimido que acciona los diversos pistones del sistema. Sin embargo, es común que se produzcan fugas en los conductos que conectan las válvulas con este sistema. Estas fugas de aire pueden resultar en pérdidas significativas de energía a largo plazo, lo que incrementa el consumo energético de manera indebida y afecta la eficiencia general de la planta.



Figura 1: Célula de fabricación flexible, ubicada en los laboratorios de la escuela de la Universidad de Sevilla.

El objetivo principal de este trabajo es detectar y estimar las fugas de aire en la planta piloto mencionada anteriormente, para la cual también se está desarrollando un Gemelo Digital. Este Gemelo Digital se encuentra en fase de mejora e incluye módulos funcionales dedicados a la detección de fallos. Uno de estos módulos se centra en identificar con precisión las fugas en el sistema de aire comprimido que acciona los pistones de la planta. A través del análisis de muestras de audio, se busca detectar y cuantificar estas fugas, con el fin de reducir el consumo de energía y mejorar la eficiencia operativa de la planta.

Dentro de la planta piloto, se ha elegido un punto específico donde se ha provocado una fuga de aire a diferentes niveles de presión, y se ha registrado el sonido desde tres ubicaciones distintas. Tanto el punto seleccionado para la fuga como los puntos de registro del sonido se muestran marcados en la Figura 2.

## 3. Procesamiento de datos, extracción y selección de características

En una primera etapa, los audios registrados son sometidos a un proceso inicial de preprocesamiento. Esta fase implica la conversión de las muestras de audio de formato estéreo a mono. Este procedimiento se lleva a cabo con el propósito de simplificar los cálculos y análisis, al trabajar exclusivamente con un canal de audio único. Este enfoque unicanal facilita la posterior extracción de características. Se extraen características tanto en el dominio temporal como en el frecuencial, discretizando las muestras de audio en ventanas temporales de 0.1 segundos. La combinación de estas características proporciona una representación detallada y completa de los audios, lo que facilita el análisis y la elección de las características más representativas para su posterior uso en la detección de fugas de aire en la planta piloto. Las características obtenidas en el dominio del tiempo y frecuencia se describen brevemente a continuación.




Figura 2: Vista de la zona de pruebas

### 3.1. Características temporales

Las características temporales obtenidas de los vectores de audio incluyen el valor medio, la varianza, la energía y el RMS (Root Mean Square, Raíz Cuadrática Media), cada una de las cuales se define con su representación matemática en (1).

$$\bar{y} = \frac{\sum_{t=1}^N y_t}{N} \quad (1a)$$

$$\sigma^2 = \frac{1}{N-1} \sum_{t=1}^N (y_t - \bar{y})^2 \quad (1b)$$

$$E = \frac{1}{N} \sum_{t=1}^N |y_t|^2 \quad (1c)$$

$$RMS = \sqrt{\frac{1}{N} \sum_{t=1}^N y_t^2} \quad (1d)$$

donde  $y \in \mathbb{R}$ , representa la señal de audio y  $N$  su número de muestra.

El valor medio (1a) de las muestras de audio representa la amplitud promedio de la señal y sirve como una medida de su tendencia central, viene dado por (1). Por otro lado, la varianza (1b) indica la dispersión de las amplitudes con respecto al valor medio, ofreciendo una medida de la variación presente en la señal de audio. La energía de la señal (1c) se define como la suma de los cuadrados de las amplitudes, normalizada por el número de muestras, lo que proporciona una medida de la potencia total de la señal. Además, el valor RMS (1d), que es la raíz cuadrada de la media de los cuadrados de las amplitudes, se utiliza comúnmente en ingeniería de audio como una medida del valor efectivo de la señal. En conjunto, estas características ofrecen información esencial sobre las propiedades temporales de las señales de audio, incluyendo su nivel medio, dispersión, energía total y amplitud media cuadrática.

### 3.2. Características frecuenciales

Las características frecuenciales se obtienen al aplicar la Transformada Rápida de Fourier (FFT) sobre un cierto número

de muestras (ventanas temporales) de la señal de audio, como se puede ver en la Figura 3. A partir de esta transformación, se genera un histograma en frecuencia. Dada una ventana temporal de  $N$  muestras con una frecuencia de muestreo  $f_s$ , la FFT produce una representación compleja de  $M$  elementos, de la cual se extraen las características frecuenciales.

$$X_k = \sum_{n=0}^{N-1} y_n e^{-i2\pi kn/N} \quad \text{para } k = 0, 1, \dots, M-1$$

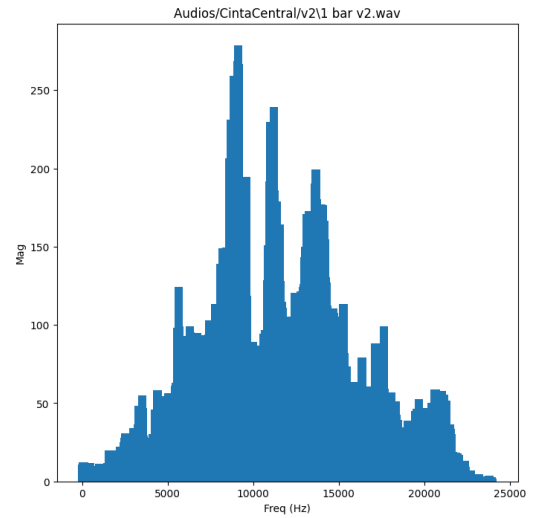


Figura 3: Ejemplo de descomposición en frecuencia sobre un histograma

De dicho array  $X$  de  $M$  elementos, se puede calcular el valor de magnitud ( $|X_k|$ ) y frecuencia ( $f_k$ ) de cada  $X_k$ , dado por (2) :

$$|X_k| = \sqrt{\text{Re}(X_k)^2 + \text{Im}(X_k)^2} \quad (2a)$$

$$f_k = \frac{k * f_s}{M} \quad (2b)$$

Por lo tanto, se obtiene un vector con los valores en frecuencia, donde cada frecuencia tiene una magnitud asociada. La frecuencia máxima es  $f_s/2$ , y la separación entre cada  $f_k$  es  $f_s/M$ . De este modo, se tienen un total de  $M$  valores de frecuencia y magnitud. Con estos valores se obtiene una serie de características, las cuales se describen a continuación:

- **Centroide del espectro** : El centroide del espectro, (3), es una medida que indica la “media ponderada” de las frecuencias presentes en la señal. Este indicador muestra dónde se concentra la mayor parte de la energía espectral.

$$\bar{F} = \frac{\sum_{k=1}^M f_k X_k}{\sum X_k} \quad (3)$$

- **Desviación estándar** : La desviación estándar en frecuencia, (4), mide la dispersión de las frecuencias alrededor del centroide del espectro, proporcionando una idea de la anchura del espectro de la señal.

$$\sigma_f = \sqrt{\frac{\sum_{k=1}^M (f_k - \bar{F})^2 * X_k}{M}} \quad (4)$$

- **Curtosis** : La curtosis, (5), mide la “apuntamiento” del espectro, es decir, cuán concentradas están las frecuencias alrededor del centroide. Un valor positivo indica una distribución con picos más altos y colas más gruesas, mientras que un valor negativo indica una distribución más plana.

$$\kappa = \frac{\sum_{k=1}^M \left(\frac{f_k - \bar{F}}{\sigma_f}\right)^4 * X_k}{M} - 3 \quad (5)$$

- **Skewness** : La skewness o asimetría, (6), mide la simetría del espectro en relación al centroide. Un valor positivo indica que el espectro tiene una cola más larga hacia las frecuencias altas, mientras que un valor negativo indica una cola más larga hacia las frecuencias bajas.

$$\gamma = \frac{\sum_{k=1}^M \left(\frac{f_k - \bar{F}}{\sigma_f}\right)^3 * X_k}{M} - 3 \quad (6)$$

- **Cuarto momento en frecuencia** : El cuarto momento en frecuencia, (7), es una medida de las variaciones extremas en el espectro, similar a la curtosis pero enfocada más específicamente en los valores extremos de frecuencia.

$$\mu_4 = \sqrt{\frac{\sum_{k=1}^M f_k^4 X_k}{\sum_{k=1}^M f_k^2 X_k}} \quad (7)$$

- **Coefficiente de achatamiento** : El coeficiente de achatamiento, (8), es una medida que describe la forma general del espectro, indicando si está más “aplanado” o “picudo”.

$$f = \frac{\sum_{k=1}^M f_k^2 X_k}{\sqrt{\sum_{k=1}^M X_k \sum_{k=1}^M f_k^4 X_k}} \quad (8)$$

- **Entropía** : La entropía del espectro, (9), mide la cantidad de desorden o aleatoriedad en la distribución de frecuencias. Un valor alto de entropía indica una distribución de frecuencia más uniforme, mientras que un valor bajo indica una distribución más concentrada.

$$H = - \sum_{k=1}^M X_k \log_2(X_k) \quad (9)$$

### 3.3. Evaluación de características

Se extrajeron un total de 11 características de cada una de las ventanas temporales de las muestras de audio. Posteriormente, se llevó a cabo una selección de características con el fin de reducir la complejidad del problema. Para este propósito, se emplearon dos índices:

1. **Índice de silueta** : El índice de silueta, es un indicador empleado en los problemas de clusterización que nos indica cuánto de cerca se encuentra una muestra al centroide del clúster que le ha sido asignado (Rousseeuw, 1987).
2. **Índice de Dunn** : El índice de Dunn, trata de evaluar la separación entre grupos y la compacidad de los mismos (Dunn, 1973).

Sin embargo, es importante destacar que ambos índices no consideran la magnitud de las dimensiones. Por lo tanto, se ha ajustado la escala de las muestras en cada una de las características extraídas. Los nuevos índices resultantes son los siguientes:

$$Silueta_{mod} = Silueta \cdot \min_{i \neq j} (d(C_i, C_j)) \quad (10a)$$

$$Dunn_{mod} = Dunn \cdot \min_{i \neq j} (d(C_i, C_j)) \quad (10b)$$

donde  $d(C_i, C_j)$  es la distancia entre los centroides  $C_i$  y  $C_j$  de los clústers  $i$  y  $j$ .

### 3.4. Selección de características

La selección de características ha sido realizada a través de dos metodologías : **analizando los índices de Silueta y Dunn para distintas presiones en una misma ubicación**; así como los mismos índices **para una misma presión desde distintas posiciones**. Los resultados obtenidos se recogen en la Tabla 1 y la Tabla 2 como sigue:

Tabla 1: Índices para una ubicación fija

Variable	Silueta	Dunn
Valor medio	$-1,234 \times 10^{-6}$	$8,360 \times 10^{-8}$
Varianza	$1,356 \times 10^{-2}$	$2,741 \times 10^{-2}$
Energía	$3,255 \times 10^2$	$6,578 \times 10^2$
RMS	$2,310 \times 10^{-2}$	$3,898 \times 10^{-2}$
Centroide espectral	$2,464 \times 10^0$	$1,687 \times 10^{-1}$
Desviación estándar	$1,564 \times 10^3$	$1,604 \times 10^3$
Curtosis	$1,048 \times 10^{-2}$	$3,364 \times 10^{-3}$
Skewness	$1,352 \times 10^{-2}$	$3,269 \times 10^{-4}$
Cuarto momento	$6,844 \times 10^1$	$2,441 \times 10^1$
Coefficiente achatamiento	$3,639 \times 10^{-13}$	$1,888 \times 10^{-13}$
Entropía	$4,216 \times 10^{-2}$	$3,494 \times 10^{-2}$

En base a los resultados recogidos en dicha tabla, se seleccionan la **Energía** y **Desviación estándar** como las características a considerar.

Tabla 2: Índices para una presión fija

Variable	Silueta	Dunn
Valor medio	$4,379 \times 10^{-6}$	$8,060 \times 10^{-6}$
Varianza	$2,069 \times 10^{-2}$	$3,968 \times 10^{-2}$
Energía	$4,966 \times 10^2$	$9,522 \times 10^2$
RMS	$3,844 \times 10^{-2}$	$7,849 \times 10^{-2}$
Centroide espectral	$4,022 \times 10^2$	$5,429 \times 10^2$
Desviación estándar	$3,081 \times 10^3$	$5,618 \times 10^3$
Curtosis	$4,908 \times 10^{-2}$	$6,111 \times 10^{-2}$
Skewness	$1,723 \times 10^{-4}$	$5,321 \times 10^{-6}$
Cuarto momento	$6,237 \times 10^1$	$2,670 \times 10^1$
Coefficiente achatamiento	$1,386 \times 10^{-12}$	$2,372 \times 10^{-12}$
Entropía	$1,311 \times 10^{-2}$	$1,128 \times 10^{-2}$

Por otro lado, las variables que muestran mayor dependencia de la posición desde la que son tomadas son : **Energía**, **Centroide espectral** y **Desviación Estándar**. Los datos extraídos ha sido divididos en un 80 % de entrenamiento y 20 % de test.

#### 4. Modelos aplicados

El problema planteado se ha dividido en dos tareas principales: la **clasificación** de la presión a la que se produce la fuga y la **regresión** para determinar el caudal de la fuga utilizando los datos recogidos desde la posición 2 (Fig. 2). Con base en estas dos tareas, se ha seleccionado el siguiente conjunto de modelos:

1. Perceptrón multicapa
2. Máquina de vectores de soporte (SVC/SVR)
3. Random Forest
4. Gradient Boosting
5. Regresión lineal
6. Regresión polinómica
7. Regresión logística

#### 5. Resultados

Los resultados obtenidos sobre cada uno de los modelos desarrollados se muestran en la Tabla 3.

Tabla 3: Resultados de los modelos empleados

Modelo	F1-Clasificación	MSE-Regresión
Perceptrón Multicapa	1	17,53/s
SVC/SVR	0,55	37,68
Random Forest	1	0,04/s
Gradient Boosting	1	0,05/s
Regresión Lineal	–	0,47/s
Regresión Polinómica	–	0,3/s
Regresión Logística	1	–

Como se puede observar en la tabla anterior, se ha determinado que el problema de clasificación resultó trivial tras la correcta selección de características. Debido a ello, se consideró

el número de parámetros de cada uno de los modelos anteriores para poder determinar cuál de ellos desarrollaría su tarea de manera más efectiva con el menor número de recursos posibles. Así, al seleccionar los modelos con mejores métricas, se muestra en la Tabla 4 el número de parámetros por modelo.

Tabla 4: Número de parámetros de los mejores modelos

Modelo	Número de parámetros
Perceptrón multicapa	501
Random Forest	350 nodos
Regresión Logística	4 parámetros
Gradient Boosting	140 nodos

Debido a la complejidad en la estimación de la cantidad de parámetros para modelos de árboles como el Random Forest y el Gradient Boosting, dado que implica analizar la complejidad de cada árbol individualmente, resulta lógico elegir la Regresión Logística como el modelo más adecuado.

#### 6. Conclusiones

En este estudio, se ha abordado la problemática de las fugas de aire comprimido en sistemas industriales, centrándose en su detección y cuantificación mediante el análisis de muestras de audio. Los resultados obtenidos demuestran que el uso de técnicas de procesamiento de audio y extracción de características permite identificar con precisión las fugas de aire y estimar el caudal de dichas fugas.

Los modelos de clasificación y regresión implementados han mostrado un rendimiento satisfactorio, destacando especialmente el Random Forest y el Gradient Boosting en la tarea de regresión, así como la Regresión Logística en la tarea de clasificación. Estos modelos han permitido no solo detectar las fugas existentes, sino también cuantificar el impacto de las mismas en términos de caudal, proporcionando una herramienta eficaz para la optimización del sistema de aire comprimido.

La selección de características ha sido un paso crucial en el proceso, ya que ha permitido reducir la complejidad del problema y mejorar la precisión de los modelos. Las características más relevantes, como la energía y la desviación estándar, han demostrado ser indicadores efectivos de las fugas de aire.

#### Agradecimientos

This work has been funded by PID2022-142069OB-I00/ AEI/10.13039/501100011033/ FEDER, UE. The authors would also like to thank the European Commission for funding this work in the framework of the DENiM project. This project has received funding from the European Union's Horizon 2020 research and innovation programme under grant agreement No. 958339.

## Referencias

- Dunn, J. C., 1973. A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters. *Journal of Cybernetics* 3 (3), 32–57.  
URL: <https://doi.org/10.1080/01969727308546046>  
DOI: 10.1080/01969727308546046
- Initiative, B. B., 2023. Compressed air.  
URL: <https://betterbuildingssolutioncenter.energy.gov/compressed-air>
- Rousseeuw, P. J., 1987. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics* 20, 53–65.  
URL: <https://www.sciencedirect.com/science/article/pii/0377042787901257>  
DOI: [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- Ullah, N., Ahmed, Z., Kim, J.-M., 2023. Pipeline leakage detection using acoustic emission and machine learning algorithms. *Sensors* 23 (6).  
URL: <https://www.mdpi.com/1424-8220/23/6/3226>  
DOI: 10.3390/s23063226
- U.S. Department of Energy, 2003. Improving Compressed Air System Performance: A Sourcebook for Industry. Office of Energy Efficiency and Renewable Energy.  
URL: [https://www1.eere.energy.gov/manufacturing/tech\\_assistance/pdfs/compressed\\_air\\_sourcebook.pdf](https://www1.eere.energy.gov/manufacturing/tech_assistance/pdfs/compressed_air_sourcebook.pdf)
- U.S. Department of Energy, 2023a. Compressed air systems.  
URL: <https://www.energy.gov/eere/amo/compressed-air-systems>
- U.S. Department of Energy, 2023b. Technology strategy assessment - compressed air energy storage. Tech. rep., Office of Energy Efficiency and Renewable Energy.  
URL: [https://www.energy.gov/sites/default/files/2023-07/Technology%20Strategy%20Assessment%20-%20Compressed%20Air%20Energy%20Storage\\_0.pdf](https://www.energy.gov/sites/default/files/2023-07/Technology%20Strategy%20Assessment%20-%20Compressed%20Air%20Energy%20Storage_0.pdf)
- Yan, Y., Shen, Y., Cui, X., Hu, Y., 2018. Localization of multiple leak sources using acoustic emission sensors based on music algorithm and wavelet packet analysis. *IEEE Sensors Journal* 18 (23), 9812–9820.  
DOI: 10.1109/JSEN.2018.2871720
- Zhu, S.-B., Li, Z.-L., Zhang, S.-M., Liang, L.-L., Zhang, H.-F., 2018. Natural gas pipeline valve leakage rate estimation via factor and cluster analysis of acoustic emissions. *Measurement* 125, 48–55.  
URL: <https://www.sciencedirect.com/science/article/pii/S0263224118303579>  
DOI: <https://doi.org/10.1016/j.measurement.2018.04.076>