

CATOLIC UNIVERSITY OF NEW SPAIN



TESIS DOCTORAL

**Estudio de los niveles de presión sonora
en un ambiente de aprendizaje utilizando
hardware de medición y técnicas de
machine learning como una herramienta
para predicción de niveles de sonido**

AUTOR: Miguel Giovanni Molina Villacís

Por optar al grado de:

Doctor of Philosophy in Global Christian Leadership
Concentration: Information Technology Management

DIRECTOR : Ing. Carlos Sarmiento Chugcho, Ph.D

ENERO 2025

MIAMI - UNITED STATES

Dedicatoria

A Dios que siempre guía mis pasos y fortalece mi Fé

A mi esposa y mis hijos que son mi vida

A mis padres que desde el cielo me cuidan y los llevo en mi corazón

A mis hermanos

Agradecimientos

Agradezco a Dios en primer lugar por permitirme llegar hasta acá

A mi familia por su apoyo incondicional

A mi tutor por sus importantes consejos , y guía en el desarrollo de la tesis

Resumen

El presente proyecto entrega una herramienta de predicción de niveles de sonido para ambientes de aprendizaje utilizando técnicas de machine learning y python y un elemento de hardware que sensa los niveles de sonido del ambiente. Según la Organización mundial de la salud la afectación por contaminación acústica genera problemas de concentración, rendimiento académico y salud auditiva. Este proyecto busca abordar este problema mediante la creación de un modelo predictivo que anticipe los niveles de ruido bajo diferentes condiciones, facilitando la toma de decisiones para la mejora del ambiente acústico. Se realizó un estudio de los niveles de presión sonora en un ambiente de aprendizaje tomando las mediciones en las aulas de clase en tiempo real, la toma de las mediciones se las realizó con el sonómetro SLM 25, el cual posee un sensor de alta fidelidad y precisión de ± 1.5 db, una gama de frecuencias de 31.5 h a 8.5 khz, con un rango de nivel de sonido que va entre 30 y 130 db, con una fuente de sonido de calibración de 94 db a 1 Khz. El sistema de predicción se lo construyó con un algoritmo de aprendizaje supervisado utilizando técnicas de machine learning y python. Los resultados demuestran que la herramienta tiene la capacidad de predecir diferentes niveles de sonido que van a existir en un aula de aprendizaje que puede ser un aula de clases de cualquier institución educativa, centros de capacitación ó auditorios de conferencias.

Palabras clave: Presión sonora, Hardware de medición, sonido ambiental, algoritmos de aprendizaje, decibelios

Abstract

This project provides a sound level prediction tool for learning environments using machine learning and Python techniques and a hardware element that senses the sound levels of the environment. According to the World Health Organization, noise pollution causes problems with concentration, academic performance and hearing health. This project seeks to address this problem by creating a predictive model that anticipates noise levels under different conditions, facilitating decision making to improve the acoustic environment. A study of sound pressure levels in a learning environment was carried out by taking measurements in classrooms in real time. The measurements were taken with the SLM 25 sound level meter, which has a high fidelity sensor and accuracy of ± 1.5 db, a frequency range of 31.5 h to 8.5 khz, with a sound level range that goes between 30 and 130 db, with a calibration sound source of 94 dB at 1 Khz. The prediction system was built with a supervised learning algorithm using machine learning and Python techniques. The results show that the tool has the ability to predict different sound levels that will exist in a learning classroom that can be a classroom of any educational institution, training centers or conference auditoriums.

Keywords: Sound pressure, measurement hardware, ambient sound, learning algorithms, decibels.

ÍNDICE DE CONTENIDO

Resumen	iii
CAPÍTULO 1 . INTRODUCCIÓN.....	1
1.1 OBJETO DEL ESTUDIO.....	2
1.2 PROBLEMA DE LA INVESTIGACIÓN	2
1.3 HIPÓTESIS	3
1.4 OBJETIVO GENERAL	3
1.5 OBJETIVOS ESPECÍFICOS	3
CAPITULO 2. MARCO TEÓRICO	5
2.1 SONIDO.....	5
2.1 Características del sonido:	6
• 2.1.1 Frecuencia.....	6
• 2.1.2 Amplitud:.....	6
• 2.1.3 Longitud de onda.....	6
• 2.1.4 Período	6
• 2.1.5 Timbre:	6
• 2.1.6 Tono:.....	6
2.2 Tipos de sonido:	6
• 2.2.1 Sonido puro	6
• 2.2.2 Sonido complejo:.....	6
• 2.2.3 Ruido.....	6
• 2.2.4 Ultrasonido:.....	6
• 2.2.5 Infrasonido:	6
2.3 Rango audible humano:	7
2.4 Frecuencia:.....	7
2.5 Amplitud:.....	8
2.6. Longitud de onda:	8
2.7 Período:	8
2.8 Decibelio (dB):	9
2.9 Intensidad:.....	10
2.10 Timbre:.....	10
2.11 Tono:.....	10
2.9 La transformada de Fourier:.....	10
2.10 Alteración del sonido:	11

2.11 Representación del sonido:.....	11
2.12. Análisis espectral:.....	11
2.13 Transformada Discreta de Fourier (TDF):.....	12
2.14 Digitalización del sonido:	13
• 2.14.1 Muestreo:	13
• 2.14.2 Cuantización:	13
• 2.14.3 Codificación:	13
2.15 Proceso del sonido durante el aprendizaje:.....	13
• 2.15.1 Percepción:	13
• 2.15.2 Procesamiento:.....	13
• 2.15.3 Reconocimiento:.....	14
• 2.15.4 Almacenamiento:	14
2.16 Ruido:.....	14
2.17 Características del ruido:.....	14
• 2.17.1 Frecuencia:	14
• 2.17.2 Amplitud:.....	14
2.18 Tipos de ruido:.....	14
• 2.18.1 Ruido blanco:.....	14
• 2.18.2 Ruido rosa:.....	14
• 2.18.3 Ruido de impulso:.....	15
• 2.18.4 Ruido continuo:	15
• 2.18.5 Ruido intermitente:	15
2.19 Propiedades del ruido:	15
2.20 El ser humano frente al ruido:.....	15
2.21 El oído:.....	15
2.22 Oído externo:.....	16
• 2.22.1 Pabellón auricular.....	16
• 2.22.2 Canal auditivo:.....	16
• 2.22.3 Tímpano:.....	16
2.23 Oído medio:	17
• 2.23.1 Cadena de huesecillos:	17
• 2.23.2 Trompa de Eustaquio:	17
2.24 Oído interno:	17
• 2.24.1 Cóclea:	17
• 2.24.2 Vestíbulo y canales semicirculares:.....	17

2.25 Efectos auditivos del ruido:	17
• 2.25.1 Pérdida auditiva inducida por ruido:	17
• 2.25.2 Tinnitus:	17
• 2.25.3 Fatiga auditiva:	17
2.26 Influencia de la contaminación acústica en los ambientes de aprendizaje	18
2.26.1 Efectos en la concentración y el rendimiento académico:	18
2.27 Impacto en la comunicación y el entendimiento:	18
• 2.27.1 Dificultad para escuchar instrucciones:	19
• 2.27.2 Falta de interacción efectiva:	19
• 2.27.3 Aumento del estrés en la comunicación:	19
2.28 Efectos en la salud mental y emocional:	19
• 2.28.1 Estrés y ansiedad	19
• 2.28.2 Fatiga mental:.....	19
• 2.28.3 Irritabilidad:.....	19
2.29 Efectos fisiológicos del ruido:	19
• 2.29.1 Aumento de la presión arterial:	19
• 2.29.2 Alteración del sueño:.....	20
• 2.29.3 Dolores de cabeza y fatiga:	20
2.30 Alteraciones debidas al ruido ambiente:	20
• 2.30.1 Interferencias cognitivas:	20
• 2.30.2 Reducción de la calidad del aprendizaje:	20
• 2.30.3 Bajo rendimiento en tareas verbales:.....	20
2.31 Ejemplos de fuentes comunes de ruido en ambientes de aprendizaje:	20
• 2.31.1 Tráfico vehicular:	20
• 2.31.2 Construcción cercana:	20
• 2.31.3 Ruido dentro del aula:	21
2.32 Efectos en diferentes etapas del aprendizaje:	21
• 2.232.1 Educación infantil y primaria:	21
• 2.32.2 Educación secundaria:	21
• 2.32.3 Educación superior:	21
2.33 Medidas de mitigación:	21
• 2.33.1 Mejor aislamiento acústico	21
• 2.33.2 Uso de cortinas o paneles acústicos.....	21
• 2.33.3 Disposición adecuada del mobiliario	21
• 2.33.4 Educación sobre el respeto al ambiente sonoro.....	21

2.34	La contaminación acústica	22
2.35	Machine Learning (ML)	22
2.36	Modelos de Machine Learning	22
2.36.1	Aprendizaje Supervisado:	22
2.36.2	Aprendizaje No Supervisado:	23
2.36.3	Aprendizaje por Refuerzo:	23
2.37	Técnicas Comunes de Machine Learning	24
2.37.1	Regresión:	24
2.37.2	Clasificación:	24
2.37.3	Clustering (Agrupamiento):	25
2.37.4	Reducción de la dimensionalidad:	25
2.37.5	Redes Neuronales Artificiales (ANNs):	26
2.37.6	Ensamblado de Modelos (Model Ensemble):	26
2.38	Python en Machine Learning	26
2.38.1	NumPy y Pandas:	27
2.38.2	Scikit-learn:	27
2.38.3	TensorFlow y PyTorch:	27
2.38.4	Matplotlib y Seaborn:	27
2.39	MODELOS	28
2.39.1	Modelos de Regresión Lineal	28
2.39.2	Modelos de Series Temporales (ARIMA)	28
2.39.3	Modelos de Aprendizaje Supervisado (Clasificación)	29
2.39.4	Modelos de Regresión Logística (Predicción Binaria)	29
2.39.5	Redes Neuronales Artificiales (RNA)	30
2.39.6	Modelos de Deep Learning para Reconocimiento de Sonido	30
2.39.7	Modelos de Predicción de Reverberación (Ecuación de sonido)	31
2.39.8	Modelos de Monte Carlo	31
2.39.9	Modelos de Redes Neuronales Recurrentes (RNN)	31
2.40	MÉTODO DE LA INVESTIGACIÓN	32
2.40.1	Requisitos -	32
2.40.2	Diseño -	32
2.40.3	Implementación –	33
2.40.4	Verificación -	33
2.40.5	Mantenimiento –	33
2.41	NOVEDAD CIENTÍFICA E IMPORTANCIA DE LA INVESTIGACIÓN	33
2.42	SITUACIÓN ACTUAL DE SONIDO EN LOS AMBIENTES DE APRENDIZAJE	34

2.43 CONTAMINACIÓN ACÚSTICA EN LA ACTUALIDAD.....	35
2. 44 CONSIDERACIONES DE LA CONTAMINACIÓN ACÚSTICA	36
2.45 ANTECEDENTES	38
2.46 MARCO LEGAL.....	41
CAPÍTULO 3: MATERIALES Y MÉTODOS.....	50
3.1 IMPLEMENTACIÓN DEL SISTEMA DE PREDICCIÓN.....	50
3.1.1 Selección de los ambientes de prueba:.....	50
3.1.2 Selección de hardware de medición para niveles de presión sonora :.....	51
3.1.3 Selección del lenguaje de programación y la herramienta para predicción.....	54
3.1.4 Implementación del Mecanismo.....	54
3.1.5 Diagrama de fases del estudio	57
3.1.6 Estudio de los niveles de presión sonora en un ambiente de aprendizaje utilizando hardware de medición y técnicas de machine learning como una herramienta para predicción de niveles de sonido.....	58
ESTUDIO DE LOS NIVELES DE PRESIÓN SONORA EN UN AMBIENTE DE APRENDIZAJE UTILIZANDO HARDWARE DE MEDICIÓN Y TÉCNICAS DE MACHINE LEARNING COMO UNA HERRAMIENTA PARA PREDICCIÓN DE NIVELES DE SONIDO	58
3.1.7 FASE 1.....	59
3.1.8 FASE 2.....	59
3.1.9 FASE 3	60
3.2 Construcción del modelo Machine Learning	60
3.3 Implementación del algoritmo predictivo	61
3.3.1. Importación de las librerías	61
3.3.2. Carga del DataSet al entorno de trabajo	61
3.3.3 Gráfico de las mediciones de prueba LAB1_S1	62
3.3.4 Gráfico de las mediciones de prueba LAB1_S2.....	63
3.3.5 Gráfico de las mediciones de prueba LAB1_S3.....	63
3.3.6 Devolución de los tipos de datos de cada columna en el Dataframe.....	64
3.3.7 Gráfico de las mediciones de prueba LAB1_S1, LAB1_S2, LAB1_S3	64
3.3.8 Primeras 3 filas del Dataframe.....	65
3.3.9 Métricas.....	65
3.3.10 Dimensiones del Dataframe.....	65
3.3.11 Creación de columna de predicción de n semanas en el futuro.....	66
3.3.12 Creación de conjunto de datos independientes	66
3.3.14 Evaluación de rendimiento del modelo predictivo.....	67
3.3.15 Entrenamiento un modelo de regresión con soporte vectorial (SVR).....	67
3.3.16 Técnica de regresión basada en SVM.....	67

3.3.17 Arreglo para predicción	67
3.3.18 Modelo de prueba	68
3.3.19 Imprimir el valor predicho	68
3.3.20 Predicción con el modelo SVR.....	68
3.3.21 Predicción	69
3.3.22 Gráfica de la predicción.....	69
3.3.23 Gráfica de mediciones y predicción	70
CAPÍTULO 4. RESULTADOS	70
4.1 VALORACIONES Y DISCUSIÓN.....	74
RETOS Y PERSPECTIVAS	77
CONCLUSIONES	78
RECOMENDACIONES	80
REFERENCIAS BIBLIOGRÁFICAS.....	82
Referencias	82

ÍNDICE DE ILUSTRACIONES

Ilustración 1 Onda Sonora.....	5
Ilustración 2 Análisis Espectral	12
Ilustración 3 Oído.....	16
Ilustración 4 Componentes del hardware de medición Sonómetro SML-25Componentes del hardware de medición	52
Ilustración 5 Software de medición del sonómetro SLM-25	53
Ilustración 6 Sonómetro SLM – 25	53
Ilustración 7 Sonómetro conectado a la recolección de datos	55
Ilustración 8 Sistema de medición SLM – 25	56
Ilustración 9 Mediciones LAB1_S1	62
Ilustración 10 Mediciones LAB1_S2	63
Ilustración 11 Mediciones LAB1_S3	63
Ilustración 12 Mediciones LAB1_S1, LAB1_S2, LAB1_S3	64
Ilustración 13 Gráfica de la predicción.....	69
Ilustración 14 Gráfica de mediciones y predicción.....	70

ÍNDICE DE TABLAS

Tabla 1 Causas y consecuencias de la contaminación acústica	37
Tabla 2 Tabla de mediciones	62
Tabla 3 Datos de cada columna en el Dataframe	64
Tabla 4 Filas del Dataframe.....	65
Tabla 5 Métricas.....	65
Tabla 6 Tabla de conjunto de datos independientes	66
Tabla 7 Tabla de arreglo para predicción	68
Tabla 8 Tabla de predicción	69

CAPÍTULO 1 . INTRODUCCIÓN

El presente proyecto realiza un análisis del nivel de sonido que existe en un ambiente de aprendizaje tomando en consideración que el ser humano puede soportar hasta cierto nivel de onda sonora sin tener una complicación auditiva, por lo cual se ha desarrollado un algoritmo de predicción de nivel de sonido para que pueda tomarse las debidas medidas necesarias y así obtener un ambiente adecuado de nivel de sonido que ayudará en el proceso de aprendizaje y mitigará el nivel de contaminación acústica en el lugar objetivo. El proyecto ha sido realizado de manera experimental en las aulas de clase de la Facultad de Ciencias Matemáticas y Física de la Universidad de Guayaquil.

En los entornos de aprendizaje, como aulas, el control del nivel de ruido es fundamental para el rendimiento y el bienestar de los estudiantes. Diversos estudios han demostrado que la contaminación acústica en estos espacios afecta negativamente la concentración, la comprensión y la retención de información, especialmente en contextos donde la interacción y la escucha son esenciales para el proceso educativo. Ante esta problemática, surge la necesidad de un sistema que no solo permita medir y monitorear los niveles de sonido en tiempo real, sino también predecir patrones de ruido para tomar decisiones informadas y proactivas.

En este contexto, el sistema de medición de sonidos basado en **machine learning** se presenta como una solución avanzada. Este sistema utiliza modelos de aprendizaje automático para analizar datos de sonido captados en tiempo real y así identificar patrones de ruido a lo largo del tiempo. Al entrenar estos modelos con datos históricos y condiciones acústicas de diferentes momentos, el sistema es capaz de realizar **predicciones de niveles de ruido**, anticipando momentos de posible interferencia o disturbio sonoro en el entorno. Mediante la implementación de este sistema, las instituciones educativas pueden actuar preventivamente: ajustar el diseño de los espacios, optimizar horarios de clases o planificar medidas de insonorización. De esta manera, se favorece un entorno acústico ideal que

potencia el aprendizaje, la concentración y el bienestar general de los estudiantes y docentes.
(Zheng et al., 2020)

1.1 OBJETO DEL ESTUDIO

El objeto de estudio es determinar el nivel de contaminación acústica en un aula de aprendizaje que puede ser un aula de clase, aula de capacitación ó aula de conferencias.

1.2 PROBLEMA DE LA INVESTIGACIÓN

Actualmente existe un nivel de sonido que se presume está superando los niveles de contaminación acústica máximo soportable para el oído de las personas que se encuentran en el aula de clases, debido a los diferentes sonidos internos y externos que acontecen dentro del aula.

1.3 HIPÓTESIS

Existe en el aula de aprendizaje un nivel de sonido que supera el umbral de lo que es permisible para tener un óptimo nivel de sonido en un ambiente de aprendizaje.

1.4 OBJETIVO GENERAL

Determinar el nivel de presión sonora que existirá en un aula de aprendizaje utilizando hardware de medición y técnicas de predicción con machine learning

1.5 OBJETIVOS ESPECÍFICOS

- Realizar un análisis de niveles de contaminación acústica en las aulas de clases
- Realizar las mediciones de los niveles de contaminación acústica con un equipo de precisión en el aula de clases
- Desarrollar utilizando técnicas de machine learning un algoritmo de predicción de niveles de sonido en un ambiente de aprendizaje.

El cuerpo de este trabajo se estructura en cuatro capítulos con los siguientes contenidos en cada uno de ellos:

Capítulo 1: Se tratará la situación actual de los niveles de sonido en los ambientes de aprendizaje. Se realiza un análisis de la situación de sonidos en el aula de aprendizaje, contiene la introducción, el objeto de estudio, el problema de la investigación, la hipótesis, el objetivo general y los objetivos específicos.

Capítulo 2: Se abordarán antecedentes que permitan conocer algunos elementos de hardware y software que han sido utilizados para propuestas de sistemas predictivos en entornos reales. Contiene el marco teórico, conceptos, método de la investigación, novedad científica e importancia de la investigación, situación actual de sonido en los ambientes de aprendizaje, contaminación acústica en la actualidad, consideraciones de la contaminación acústica.

Capítulo 3: Se detalla la metodología utilizada para la investigación y el esquema del proyecto. Contiene los materiales y métodos, la implementación del sistema de predicción, la selección de los ambientes de prueba, la selección del lenguaje de programación y la herramienta para la predicción, el diagrama de las fases del proyecto, la construcción del modelo de machine learning, la implementación del algoritmo predictivo.

Capítulo 4: Se muestran los resultados obtenidos de la investigación y la discusión de los mismos. Contiene los resultados, las valoraciones, los retos y las perspectivas, las conclusiones y las recomendaciones.

CAPITULO 2. MARCO TEÓRICO

2.1 SONIDO

El sonido es una vibración que viaja a través de un medio , generalmente el aire en forma de ondas mecánicas. Estas ondas sonoras son percibidas por el oído humano cuando vibran en una frecuencia que está dentro del rango audible (entre 20 Hz y 20,000 Hz). El sonido requiere de un medio para propagarse, debido a que no puede viajar en el vacío. (Halliday et al., 2013)

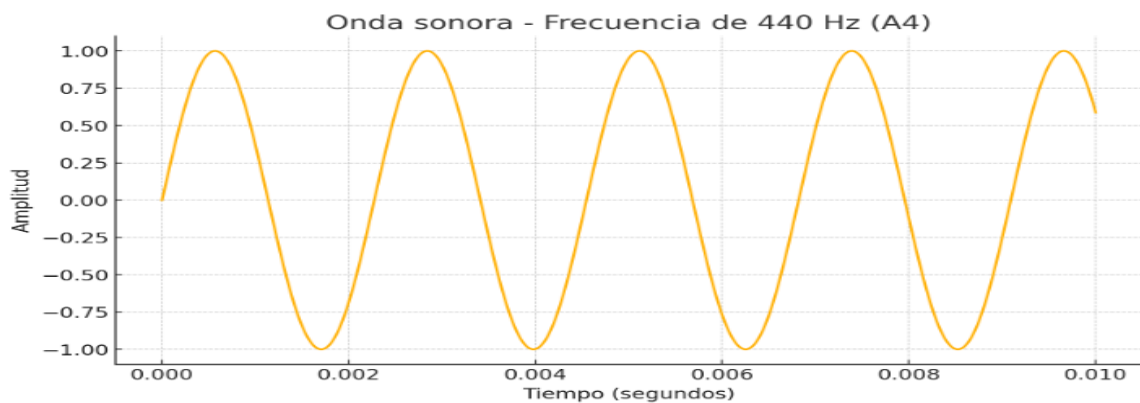


Ilustración 1 Onda Sonora

2.1 Características del sonido:

Las principales características del sonido son:

- 2.1.1 Frecuencia: Número de ciclos de una onda sonora por segundo, medido en Hertz (Hz).
- 2.1.2 Amplitud: Relacionada con la intensidad o el volumen del sonido.
- 2.1.3 Longitud de onda: Distancia entre dos puntos equivalentes en ciclos consecutivos de la onda.
- 2.1.4 Período: Tiempo que tarda una onda en completar un ciclo.
- 2.1.5 Timbre: Calidad del sonido que permite distinguir entre dos fuentes sonoras diferentes, aunque tengan la misma frecuencia e intensidad.
- 2.1.6 Tono: Sensación auditiva relacionada con la frecuencia de la onda sonora, percibida como “agudo” o “grave”. (Rossing y Fletcher, 2004)

2.2 Tipos de sonido:

- 2.2.1 Sonido puro: Tiene una sola frecuencia (onda sinusoidal simple).
- 2.2.2 Sonido complejo: Compuesto por múltiples frecuencias.
- 2.2.3 Ruido: Sonido sin una frecuencia clara o regular.
- 2.2.4 Ultrasonido: Sonido con frecuencia mayor al rango audible humano (por encima de 20,000 Hz).
- 2.2.5 Infrasonido: Sonido con frecuencia por debajo del rango audible humano (menos de 20 Hz). (Rossing y Fletcher, 2004)

2.3 Rango audible humano:

El rango audible humano se sitúa entre **20 Hz** y **20,000 Hz**. Fuera de este rango, el oído humano no puede percibir las vibraciones sonoras, aunque algunos animales sí pueden. (Digital Talent Agency, 2018)

2.4 Frecuencia:

La **frecuencia** de una onda sonora se refiere al número de ciclos por segundo que la onda completa. Se mide en **Hertz** (Hz). Una mayor frecuencia se percibe como un sonido más agudo, mientras que una frecuencia baja se percibe como un sonido grave. (Rossing y Fletcher, 2004)

$$f = \frac{1}{T}$$

Donde:

- f: Frecuencia (en hercios, Hz).
- T: Período (en segundos, s).

Para ondas como el sonido o la luz, la frecuencia también se puede calcular con la fórmula:

$$f = \frac{v}{\lambda}$$

Donde:

- v: Velocidad de la onda (en metros por segundo, m/s).

- λ : Longitud de onda (en metros).

2.5 Amplitud:

La **amplitud** de una onda es la altura máxima de la onda desde su punto de equilibrio. Está relacionada con la **intensidad** o el **volumen** del sonido, y se mide generalmente en **decibelios** (dB). (Rossing y Fletcher, 2004)

2.6. Longitud de onda:

Es la distancia entre dos puntos equivalentes en una onda sonora, como dos picos consecutivos o dos valles consecutivos. Se mide en metros y está inversamente relacionada con la frecuencia (una mayor frecuencia implica una longitud de onda más corta). (Halliday et al., 2013)

2.7 Período:

El **período** de una onda es el tiempo que tarda en completarse un ciclo de la onda. Se mide en segundos. Es el inverso de la frecuencia.

$$T = \frac{1}{f}$$

Para ondas periódicas, como las senoidales o las de sonido, el período también se puede relacionar con la velocidad y la longitud de onda (λ):

$$T = \frac{\lambda}{v}$$

2.8 Decibelio (dB):

El **decibelio** es una unidad de medida para expresar la intensidad del sonido. Es una escala logarítmica, lo que significa que un aumento de 10 dB representa un aumento de 10 veces la intensidad sonora. Un nivel de 0 dB es el umbral mínimo de audición para los humanos, mientras que niveles por encima de 120 dB pueden ser dolorosos. (Rossing y Fletcher, 2004)

Según la presión sonora:

$$L_p = 20 \cdot \log_{10} \left(\frac{P}{P_0} \right)$$

Donde:

- L_p : Nivel de presión sonora en decibelios (dB).
- P : Presión sonora medida (en pascales, Pa).
- P_0 : Presión de referencia, típicamente $P_0 = 20 \text{ uPa}$, que es el umbral de audición humana (el sonido más débil que un oído humano promedio puede detectar).

Según la intensidad sonora:

Si se mide la intensidad del sonido I (en W/m^2), el nivel de intensidad sonora se calcula como:

$$L_I = 10 \cdot \log_{10} \left(\frac{I}{I_0} \right)$$

Donde:

- LI : Nivel de intensidad sonora en decibelios (dB).
- I: Intensidad del sonido medida (en W/m²)
- I_o: Intensidad de referencia, típicamente (I_o= 10⁻¹² W/m²), el umbral de audición

2.9 Intensidad:

La **intensidad** del sonido es la cantidad de energía que una onda sonora transporta por unidad de área. Está relacionada con el volumen del sonido y se mide en **watts por metro cuadrado** (W/m²) o en decibelios (dB). (Halliday et al., 2013)

2.10 Timbre:

El **timbre** es la cualidad del sonido que nos permite distinguir entre dos fuentes sonoras diferentes, aunque tengan la misma frecuencia e intensidad. Está determinado por las características armónicas del sonido y su estructura de ondas. (Halliday et al., 2013)

2.11 Tono:

El **tono** se refiere a la percepción subjetiva de la altura de un sonido, que está relacionada con la frecuencia de la onda sonora. Sonidos con frecuencias altas se perciben como tonos agudos, mientras que frecuencias bajas se perciben como tonos graves. (Halliday et al., 2013)

2.9 La transformada de Fourier:

La **transformada de Fourier** es una técnica matemática que permite descomponer una señal compleja (como un sonido) en una serie de ondas sinusoidales simples de diferentes frecuencias. Esta herramienta es crucial para el análisis del espectro de frecuencia del sonido. (Openheim y Schafer, 2010)

La Transformada de Fourier de una función $x(t)$ se define como:

$$X(\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt$$

En ondas sonoras con una señal continua se utiliza la fórmula:

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt$$

En señal discreta, se aplica la **Transformada de Fourier Discreta (DFT)**:

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j2\pi kn/N}$$

2.10 Alteración del sonido:

La **alteración del sonido** se refiere a cualquier cambio o distorsión en la forma de la onda sonora original. Esto puede ocurrir debido a la interferencia, eco, reverberación, o cambios en el medio por el que viaja el sonido, o mediante manipulación digital intencionada. (Openheim y Schaffer, 2010)

2.11 Representación del sonido:

El sonido se puede representar de varias maneras, como a través de una **onda de tiempo** (amplitud frente a tiempo) o de un **espectrograma**, que muestra cómo la intensidad del sonido varía con la frecuencia y el tiempo. (Halliday et al., 2013)

2.12. Análisis espectral:

El **análisis espectral** es el estudio de la distribución de las diferentes frecuencias que componen un sonido. Utilizando herramientas como la **transformada de Fourier**, se puede visualizar

cómo se distribuyen las frecuencias en una señal y qué componentes predominan. (Newman, 2023)




Ilustración 2 Análisis Espectral

2.13 Transformada Discreta de Fourier (TDF):

La **Transformada Discreta de Fourier (TDF)** es una versión de la Transformada de Fourier que se aplica a señales **discretas** (muestreadas). Se utiliza para descomponer una señal en sus componentes de frecuencia, lo que es útil para analizar señales digitales, como el sonido digitalizado. La TDF convierte una señal discreta en el tiempo (una secuencia de valores) en una representación discreta en frecuencia (espectro de frecuencias). Es fundamental en el procesamiento digital de señales, como en la **compresión de audio** y **filtros digitales**. (Newman, 2023)

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j2\pi kn/N}$$

2.14 Digitalización del sonido:

La **digitalización del sonido** es el proceso mediante el cual una señal de sonido **analógica** (continua en el tiempo) se convierte en una señal **digital** (discreta). Este proceso involucra:

- **2.14.1 Muestreo:** Se toman muestras de la amplitud de la señal en intervalos de tiempo regulares (medidos en Hz o muestras por segundo). La **frecuencia de muestreo** debe ser al menos el doble de la frecuencia máxima de la señal, según el **Teorema de Nyquist**.
- **2.14.2 Cuantización:** Cada muestra se asigna a un valor discreto dentro de un rango de niveles predeterminados.
- **2.14.3 Codificación:** Los valores cuantizados se convierten en una secuencia de bits que representa la señal digital.

Este proceso permite almacenar y procesar el sonido en computadoras y dispositivos electrónicos. (Newman, 2023)

2.15 Proceso del sonido durante el aprendizaje:

Durante el proceso de **aprendizaje** (tanto en humanos como en sistemas de aprendizaje automático), el sonido pasa por varias etapas:

- **2.15.1 Percepción:** El sonido es captado por los receptores auditivos (como el oído humano o un micrófono).
- **2.15.2 Procesamiento:** El sonido se procesa en el cerebro (en humanos) o en un sistema de inteligencia artificial mediante algoritmos que analizan las características del sonido, como el tono, el timbre, y la frecuencia. (Newman, 2023)

- **2.15.3 Reconocimiento:** El cerebro o el sistema analiza patrones en el sonido para asociarlos con experiencias previas o categorías conocidas (como el reconocimiento de palabras, tonos o instrumentos musicales).
- **2.15.4 Almacenamiento:** La información aprendida se guarda en la memoria para ser usada posteriormente en nuevas situaciones.

2.16 Ruido:

El **ruido** es cualquier sonido no deseado que interfiere con la percepción o transmisión de un sonido deseado. A nivel físico, el ruido es una mezcla de diferentes frecuencias sin un patrón regular o armónico. A nivel subjetivo, es percibido como molesto o perturbador. (Rossing y Fletcher, 2004)

2.17 Características del ruido:

- **2.17.1 Frecuencia:** El ruido puede abarcar un amplio rango de frecuencias.
- **2.17.2 Amplitud:** El nivel de amplitud del ruido afecta cuán perturbador es.
- **2.17.3 Duración:** El ruido puede ser continuo o intermitente.
- **2.17.4 Naturaleza aleatoria:** A diferencia de los sonidos armónicos, el ruido tiene una distribución de frecuencias desordenada y no predecible. (Rossing y Fletcher, 2004)

2.18 Tipos de ruido:

- **2.18.1 Ruido blanco:** Contiene todas las frecuencias en igual intensidad, es similar al "silbido" de una radio mal sintonizada.
- **2.18.2 Ruido rosa:** Tiene más energía en las frecuencias bajas, disminuyendo en las altas.

- 2.18.3 Ruido de impulso: Ruidos repentinos y breves, como explosiones o golpes.
- 2.18.4 Ruido continuo: Sonido constante sin interrupción, como el zumbido de un ventilador.
- 2.18.5 Ruido intermitente: Ruido que va y viene, como el tráfico en una carretera. (Rossing y Fletcher, 2004)

2.19 Propiedades del ruido:


- **Intensidad:** Se mide en **decibelios (dB)** y puede variar ampliamente.
- **Frecuencia:** El ruido puede tener frecuencias bajas (graves), medias o altas (agudas), o una combinación de estas.
- **Direccionalidad:** El ruido puede provenir de una fuente fija o moverse en el espacio.
- **Interferencia:** El ruido puede afectar la claridad de la comunicación o la percepción auditiva, interfiriendo con sonidos importantes. (Rossing y Fletcher, 2004)

2.20 El ser humano frente al ruido:

El ser humano puede percibir el ruido como molesto o incluso dañino, dependiendo de la intensidad y duración. La exposición prolongada a niveles altos de ruido puede provocar efectos negativos en la **salud física** (pérdida auditiva, hipertensión) y en la **salud mental** (estrés, ansiedad, trastornos del sueño). (Rossing y Fletcher, 2004)

2.21 El oído:

El **oído** es el órgano encargado de captar las ondas sonoras y convertirlas en señales eléctricas que el cerebro interpreta como sonido. Está dividido en tres partes: **oído externo**, **oído medio** y **oído interno**. (Marieb y Hoehn, 2013) (Tórtora y Derrickson, 2012)



Fuente: National Institute on Deafness and other communications disorder NIH/NIDCD

Ilustración 3 Oído

2.22 Oído externo:

El **oído externo** incluye:

- 2.22.1 Pabellón auricular (oreja): Recoge las ondas sonoras y las dirige hacia el canal auditivo.
- 2.22.2 Canal auditivo: Conduce las ondas sonoras hacia el tímpano.
- 2.22.3 Tímpano: Una membrana que vibra en respuesta a las ondas sonoras. (Tórtora y Derrickson, 2012)

2.23 Oído medio:

El **oído medio** contiene:

- 2.23.1 Cadena de huesecillos: Martillo, yunque y estribo, que amplifican y transmiten las vibraciones del tímpano al oído interno.
- 2.23.2 Trompa de Eustaquio: Equilibra la presión entre el oído medio y la atmósfera. (Tórtora y Derrickson, 2012)

2.24 Oído interno:

El **oído interno** contiene:

- 2.24.1 Cóclea: Un órgano en espiral que convierte las vibraciones en señales eléctricas. Contiene células ciliadas que responden a diferentes frecuencias.
- 2.24.2 Vestíbulo y canales semicirculares: Responsables del equilibrio (Tórtora y Derrickson, 2012)

2.25 Efectos auditivos del ruido:

La exposición prolongada o intensa al ruido puede tener efectos negativos sobre la audición:

- 2.25.1 Pérdida auditiva inducida por ruido: Daño irreversible a las células ciliadas de la cóclea por exposición a niveles altos de ruido.
- 2.25.2 Tinnitus: Zumbido o pitido en los oídos que puede ser temporal o permanente.
- 2.25.3 Fatiga auditiva: Pérdida temporal de la sensibilidad auditiva después de la exposición a ruidos fuertes. (Tórtora y Derrickson, 2012)

2.26 Influencia de la contaminación acústica en los ambientes de aprendizaje

La **contaminación acústica** en los ambientes de aprendizaje tiene un impacto significativo en la **calidad del proceso educativo** y en la **salud física y mental** de los estudiantes y docentes. El ruido ambiental excesivo interfiere con la capacidad de concentración, la comunicación efectiva, y el procesamiento de la información. A continuación, se describen los principales efectos de la contaminación acústica en estos entornos

2.26.1 Efectos en la concentración y el rendimiento académico:

El ruido ambiental en un aula puede distraer a los estudiantes, dificultando su concentración y afectando negativamente su rendimiento académico. Algunos efectos específicos incluyen:

- 2.26.1.1 Reducción de la atención: Los estudiantes tienen más dificultad para enfocarse en las tareas, lo que reduce su capacidad de retener y procesar la información.
- 2.26.1.2 Aumento de los errores: El ruido genera distracciones que aumentan la probabilidad de cometer errores en la resolución de problemas y durante los exámenes.
- 2.26.1.3 Alteración de la memoria a corto plazo: El ruido interfiere con la retención de información nueva, lo que perjudica el aprendizaje a largo plazo. (Gheller et al., 2024)

2.27 Impacto en la comunicación y el entendimiento:

El ruido alto dificulta la **comunicación verbal** entre los docentes y los estudiantes, lo que puede tener varias consecuencias:

- **2.27.1 Dificultad para escuchar instrucciones:** Los estudiantes no pueden escuchar claramente las instrucciones del docente, lo que afecta la comprensión de las actividades y tareas.
- **2.27.2 Falta de interacción efectiva:** Los niveles altos de ruido inhiben la interacción entre estudiantes y docentes, reduciendo la participación activa en discusiones o preguntas.
- **2.27.3 Aumento del estrés en la comunicación:** Los docentes deben elevar su voz para ser escuchados, lo que provoca fatiga vocal y estrés. (Gheller et al., 2024)

2.28 Efectos en la salud mental y emocional:

La exposición constante a niveles elevados de ruido en los ambientes de aprendizaje puede generar alteraciones emocionales y psicológicas, tales como:

- **2.28.1 Estrés y ansiedad:** El ruido constante puede generar una sensación de sobrecarga sensorial, lo que aumenta los niveles de estrés en los estudiantes y docentes.
- **2.28.2 Fatiga mental:** Los estudiantes pueden experimentar una mayor fatiga mental debido a los esfuerzos adicionales que deben realizar para concentrarse en ambientes ruidosos.
- **2.28.3 Irritabilidad:** El ruido puede hacer que las personas se sientan frustradas o irritables, lo que afecta el clima de convivencia en el aula. (Gheller et al., 2024)

2.29 Efectos fisiológicos del ruido:

Además de los efectos mentales y emocionales, el ruido puede tener un impacto directo en la salud física:

- **2.29.1 Aumento de la presión arterial:** La exposición prolongada al ruido puede desencadenar una respuesta de estrés fisiológico que aumenta la presión arterial.

- **2.29.2 Alteración del sueño:** Aunque el ruido puede estar presente principalmente en el aula, los niveles elevados de estrés inducidos por este pueden afectar la calidad del sueño de los estudiantes.
- **2.29.3 Dolores de cabeza y fatiga:** El ruido ambiental también puede contribuir a dolores de cabeza, mareos y sensación de agotamiento. (Evangelos et al., 2022)

2.30 Alteraciones debidas al ruido ambiente:

Las alteraciones que el ruido ambiente puede causar en el entorno educativo incluyen:

- **2.30.1 Interferencias cognitivas:** El ruido reduce la capacidad del cerebro para procesar información de manera eficiente, lo que lleva a dificultades en el razonamiento y la resolución de problemas.
- **2.30.2 Reducción de la calidad del aprendizaje:** A largo plazo, los estudiantes expuestos regularmente a ambientes ruidosos pueden experimentar un menor desarrollo académico, especialmente en áreas como la lectura, la escritura y las matemáticas.
- **2.30.3 Bajo rendimiento en tareas verbales:** El ruido afecta particularmente el procesamiento del lenguaje, lo que hace que las tareas que dependen de la comprensión lectora o la expresión verbal sean más difíciles. (Shield & Dockrell, 2003)

2.31 Ejemplos de fuentes comunes de ruido en ambientes de aprendizaje:

- **2.31.1 Tráfico vehicular:** El ruido del tráfico es común en escuelas ubicadas cerca de carreteras transitadas o avenidas principales.
- **2.31.2 Construcción cercana:** Las obras de construcción cerca de las instituciones educativas generan ruidos constantes que interfieren con el aprendizaje.

- **2.31.3 Ruido dentro del aula:** Conversaciones entre estudiantes, el movimiento de sillas y mesas, y equipos electrónicos mal aislados también contribuyen a la contaminación acústica en el aula.

2.32 Efectos en diferentes etapas del aprendizaje:

- **2.232.1 Educación infantil y primaria:** Los niños en edades tempranas son más sensibles a los efectos del ruido, ya que su capacidad de atención y concentración está aún en desarrollo. El ruido puede afectar su desarrollo cognitivo y su habilidad para aprender nuevas palabras y conceptos. (Shield & Dockrell, 2003)
- **2.32.2 Educación secundaria:** Los adolescentes pueden experimentar mayores niveles de estrés y ansiedad debido al ruido, lo que afecta su motivación y rendimiento académico.
- **2.32.3 Educación superior:** En universidades y centros de formación, el ruido interfiere con la comprensión de conceptos complejos y la realización de actividades que requieren un enfoque profundo, como la lectura, la investigación y la escritura. (Evangelos et al., 2022)

2.33 Medidas de mitigación:

Algunas medidas para reducir la contaminación acústica en los ambientes de aprendizaje incluyen:

- **2.33.1 Mejor aislamiento acústico** en las aulas, con ventanas y puertas adecuadas.
- **2.33.2 Uso de cortinas o paneles acústicos** que absorban el ruido.
- **2.33.3 Disposición adecuada del mobiliario** para evitar el eco.
- **2.33.4 Educación sobre el respeto al ambiente sonoro** dentro del aula, para reducir ruidos internos.

2.34 La contaminación acústica tiene efectos perjudiciales tanto en el rendimiento académico como en el bienestar físico y emocional de estudiantes y docentes. Afecta la concentración, la comunicación, el estrés y puede causar efectos fisiológicos adversos como fatiga auditiva y dolores de cabeza. La implementación de estrategias para reducir el ruido es fundamental para optimizar los ambientes de aprendizaje y proteger la salud de todos los participantes. (Shield & Dockrell, 2003)

2.35 Machine Learning (ML) es una rama de la inteligencia artificial que permite a los sistemas aprender y mejorar automáticamente a partir de la experiencia sin ser explícitamente programados. En lugar de seguir reglas predefinidas, los modelos de ML utilizan datos para identificar patrones, tomar decisiones y hacer predicciones. (Géron, 2022)

2.36 Modelos de Machine Learning

Los modelos de **machine learning** se agrupan en tres tipos principales, dependiendo de cómo aprenden y cómo se utilizan los datos:

2.36.1 Aprendizaje Supervisado:

En este tipo de aprendizaje, el modelo es entrenado con un conjunto de datos etiquetados, es decir, que contienen las respuestas correctas (o etiquetas) para cada entrada de datos. El objetivo del modelo es aprender una relación entre las entradas y las salidas. (Géron, 2022)

- **Ejemplos de modelos supervisados:**

2.36.1.1 Regresión lineal: Utilizado para predecir valores continuos.

2.36.1.2 Regresión logística: Utilizado para problemas de clasificación binaria

2.36.1.3 Máquinas de soporte vectorial (SVM): Para problemas de clasificación y regresión.

2.36.1.4 Árboles de decisión y bosques aleatorios: Estructuras en forma de árbol para clasificar o predecir valores.

2.36.1.5 Redes Neuronales: Simulan el comportamiento de las neuronas del cerebro para resolver problemas complejos.

2.36.2 Aprendizaje No Supervisado:

Aquí, el modelo trabaja con datos que **no están etiquetados**, y su tarea es identificar patrones, agrupamientos o estructuras ocultas dentro de los datos. (Géron, 2022)

- **Ejemplos de modelos no supervisados:**

2.36.2.1 K-means: Algoritmo de agrupamiento (clustering) que divide los datos en grupos (clusters) basados en similitudes.

2.36.2.2 Análisis de componentes principales (PCA): Utilizado para la reducción de la dimensionalidad, reduciendo el número de características en un conjunto de datos sin perder mucha información.

2.36.2.3 Autoencoders: Redes neuronales utilizadas para compresión de datos y generación de características.

2.36.3 Aprendizaje por Refuerzo:

En el aprendizaje por refuerzo, un **agente** interactúa con un entorno y aprende a tomar decisiones mediante la maximización de una recompensa acumulada a lo largo del tiempo. Este enfoque es ideal para tareas como juegos, donde las decisiones en cada paso afectan los resultados futuros. (Géron, 2022)

- **Ejemplos: Q-learning y Deep Q-Networks (DQN)**, aplicados en juegos, robótica, y sistemas autónomos.

2.37 Técnicas Comunes de Machine Learning

Existen diversas técnicas en ML que se aplican a distintos tipos de problemas:

2.37.1 Regresión:

La regresión se utiliza para predecir un valor continuo. El algoritmo más simple es la **regresión lineal**, que busca la mejor línea que explique la relación entre las características de entrada y la salida.

- **Regresión lineal y regresión polinómica** son ejemplos de esta técnica.

2.37.2 Clasificación:

Los problemas de clasificación implican asignar una etiqueta o categoría a una instancia dada.

Los algoritmos de clasificación más utilizados incluyen:

2.37.2.1 Regresión logística.

La regresión logística es un modelo estadístico utilizado para predecir una variable dependiente categórica (binaria o multinomial) basada en una o más variables independientes, que pueden ser continuas o categóricas. (Hastie et al., 2009) (Pedregosa et al., 2011)

2.37.2.2 Máquinas de soporte vectorial (SVM).

Son un conjunto de algoritmos supervisados de aprendizaje automático utilizados para tareas de clasificación y regresión. Su principal objetivo es encontrar un hiperplano óptimo que separe los datos en diferentes clases, maximizando el margen entre las clases para una mejor generalización. (Ghosh et al., 2019)

2.37.2.4 Árboles de decisión.

Un árbol de decisión es un modelo de aprendizaje supervisado utilizado para tareas de clasificación y regresión. Se representa como una estructura jerárquica en forma de árbol, donde cada nodo interno corresponde a una prueba sobre un atributo, cada rama representa un resultado posible de esa prueba, y cada nodo hoja representa una etiqueta de clase o un valor de predicción. (Testas, 2023)

2.37.2.5 Redes neuronales.

Las redes neuronales son un modelo matemático inspirado en el funcionamiento del cerebro humano, diseñado para procesar información y aprender patrones complejos. Son un pilar fundamental de la inteligencia artificial (IA) y el aprendizaje automático (Machine Learning), especialmente en tareas donde los datos tienen alta dimensionalidad, como el reconocimiento de imágenes, el procesamiento de texto y el análisis de sonidos. (Fausett, 1993)

2.37.3 Clustering (Agrupamiento):

El **clustering** es una técnica de aprendizaje no supervisado que agrupa datos similares entre sí. El algoritmo **K-means** es uno de los métodos más comunes para el clustering, mientras que el **DBSCAN** es útil para identificar grupos de formas arbitrarias. (Géron, 2022)

2.37.4 Reducción de la dimensionalidad:

Cuando los datos tienen demasiadas variables (características), la **reducción de dimensionalidad** puede ser crucial para mejorar la eficiencia y la precisión del modelo. El **Análisis de Componentes Principales (PCA)** y **t-SNE** son populares en este campo.

2.37.5 Redes Neuronales Artificiales (ANNs):

Las **redes neuronales** están inspiradas en la estructura del cerebro humano. Son capaces de modelar funciones complejas y no lineales. Variantes avanzadas incluyen:

2.37.5.1 Redes neuronales convolucionales (CNNs): Ideales para problemas de visión por computadora, como el reconocimiento de imágenes.

2.37.5.2 Redes neuronales recurrentes (RNNs): Útiles para problemas de series temporales y procesamiento de lenguaje natural (NLP). (Géron, 2022)

2.37.6 Ensamblado de Modelos (Model Ensemble):

Las técnicas de ensamblado combinan varios modelos para mejorar el rendimiento. Los métodos más conocidos incluyen:

2.37.6.1 Bagging: Usa múltiples versiones del mismo algoritmo, como en los **bosques aleatorios**.

2.37.6.2 Boosting: Mejora progresivamente los errores de los modelos anteriores, como en **XGBoost** y **Gradient Boosting**.

2.38 Python en Machine Learning

Python es uno de los lenguajes más populares para el desarrollo de modelos de machine learning gracias a su sintaxis sencilla y a la abundancia de bibliotecas especializadas. Algunas de las bibliotecas más importantes incluyen: (Géron, 2022)

2.38.1 NumPy y Pandas:

Estas bibliotecas se utilizan para la manipulación y análisis de datos. **NumPy** proporciona soporte para matrices y operaciones matemáticas, mientras que **Pandas** permite manejar y analizar estructuras de datos más complejas como tablas.

2.38.2 Scikit-learn:

Scikit-learn es una biblioteca de machine learning que ofrece herramientas sencillas para la construcción de modelos de clasificación, regresión, clustering, reducción de dimensionalidad, y selección de características. Sus ventajas son la facilidad de uso y la robustez de sus algoritmos.

- **Ejemplos:** `LogisticRegression`, `RandomForestClassifier`, `KMeans`.

2.38.3 TensorFlow y PyTorch:

TensorFlow (de Google) y **PyTorch** (de Facebook) son bibliotecas de deep learning que permiten construir y entrenar redes neuronales complejas. Ofrecen funcionalidades avanzadas como el uso de GPUs y permiten manejar grandes volúmenes de datos de forma eficiente.

2.38.3.1 TensorFlow tiene una API de alto nivel llamada **Keras** que facilita la creación de redes neuronales.

2.38.3.2 PyTorch es preferido en el ámbito académico y de investigación debido a su flexibilidad y facilidad para depurar código.

2.38.4 Matplotlib y Seaborn:

Estas bibliotecas son utilizadas para la visualización de datos. **Matplotlib** es más versátil, mientras que **Seaborn** se especializa en gráficos estadísticos.

2.39 MODELOS

En los ambientes de aprendizaje, los modelos predictivos de sonido pueden ser utilizados para analizar, prever y mitigar el impacto de la **contaminación acústica** y el **nivel de ruido**. Estos modelos pueden ayudar a mejorar la calidad del entorno acústico en las aulas, optimizando la enseñanza y el aprendizaje. (Murphy & King, 2022)

Algunos modelos que pueden aplicarse en este caso :

2.39.1 Modelos de Regresión Lineal

2.39.1.1 Uso: Este modelo puede predecir los niveles de ruido en función de ciertas variables, como la ocupación del aula, el tamaño del espacio, las características acústicas del entorno (reverberación, materiales de las paredes) y la presencia de fuentes de ruido externas.

2.39.1.2 Funcionamiento: La regresión lineal se utiliza para encontrar la relación entre los niveles de ruido medidos y las características del ambiente. Esto permite predecir cómo se comportará el nivel de ruido bajo diferentes condiciones.

2.39.1.3 Aplicación en aulas: Predecir el impacto de las conversaciones de los estudiantes, los movimientos, o el uso de dispositivos electrónicos sobre los niveles generales de ruido. (Murphy & King, 2022)

2.39.2 Modelos de Series Temporales (ARIMA)

- **Uso:** Los modelos de series temporales son útiles para predecir el ruido en función de los datos históricos de sonido recogidos en un aula a lo largo del tiempo.

- **Funcionamiento:** El modelo ARIMA (Autoregressive Integrated Moving Average) analiza patrones de ruido en datos temporales, lo que ayuda a predecir cómo variarán los niveles de sonido en el futuro en diferentes horarios de clase.
- **Aplicación en aulas:** Se puede usar para predecir los picos de ruido en momentos específicos del día, como al inicio o al final de la clase, o durante pausas y descansos. (Géron, 2022)

2.39.3 Modelos de Aprendizaje Supervisado (Clasificación)

2.39.3.1 Uso: En ambientes de aprendizaje, modelos como **árboles de decisión**, **máquinas de soporte vectorial (SVM)** y **redes neuronales** se utilizan para clasificar los diferentes tipos de ruido (conversaciones, ruido ambiental, tráfico exterior) y predecir su impacto en la atención o rendimiento de los estudiantes. (Géron, 2022)

2.39.3.2 Funcionamiento: Estos modelos son entrenados con datos etiquetados de sonidos del ambiente de aprendizaje para clasificar el tipo de ruido presente y prever su impacto en la acústica del aula. (Géron, 2022)

2.39.3.3 Aplicación en aulas: Identificar cuándo el ruido es lo suficientemente alto como para requerir una intervención, como el uso de micrófonos o paneles acústicos.

2.39.4 Modelos de Regresión Logística (Predicción Binaria)

2.39.4.1 Uso: Este modelo puede predecir la probabilidad de que el nivel de ruido en un aula supere un umbral aceptable para la enseñanza eficaz.

2.39.4.2 Funcionamiento: Basado en variables acústicas y ambientales, la regresión logística puede predecir si el ruido en un momento específico será "aceptable" o "inaceptable" para el aprendizaje.

2.39.4.3 Aplicación en aulas: Identificar si un aula será demasiado ruidosa para realizar ciertas actividades, como lecturas o exámenes, y sugerir acciones correctivas. (Géron, 2022)

2.39.5 Redes Neuronales Artificiales (RNA)

2.39.5.1 Uso: Las redes neuronales son capaces de capturar relaciones no lineales complejas entre las características acústicas del entorno y los niveles de ruido. Pueden ser utilizadas para predecir el impacto del ruido en el rendimiento académico.

2.39.5.2 Funcionamiento: Se alimenta el modelo con datos de sonido en el aula (frecuencia, amplitud, duración, tipo de ruido) junto con datos de rendimiento de los estudiantes, lo que permite a la red neuronal aprender la relación entre el ruido y el desempeño.

2.39.5.3 Aplicación en aulas: Predecir el efecto que diferentes niveles de ruido pueden tener en la concentración y el aprendizaje, y recomendar mejoras en la acústica del aula. (Géron, 2022)

2.39.6 Modelos de Deep Learning para Reconocimiento de Sonido

2.39.6.1 Uso: Los modelos de deep learning, como las redes neuronales convolucionales (CNN), pueden procesar datos acústicos para identificar patrones complejos en el ruido del aula.

2.39.6.2 Funcionamiento: Se entrenan con grabaciones de diferentes tipos de sonidos (conversaciones, ventiladores, ruido externo) y pueden predecir cuándo el ruido alcanzará niveles perturbadores.

2.39.6.3 Aplicación en aulas: Pueden ser utilizados para desarrollar sistemas de monitoreo que avisen automáticamente cuando el ruido en el aula exceda niveles aceptables. (Géron, 2022)

2.39.7 Modelos de Predicción de Reverberación (Ecuación de sonido)

2.39.7.1 Uso: Estos modelos predicen la cantidad de reverberación en un aula en función de su diseño arquitectónico, materiales de construcción y disposición del mobiliario.

2.39.7.2 Funcionamiento: Utilizan algoritmos basados en la geometría de la sala y las propiedades de los materiales para predecir la cantidad de reflexión del sonido. Esto es crucial para predecir cómo se propaga el sonido en el aula y su efecto en la comprensión del discurso.

2.39.7.3 Aplicación en aulas: Ayuda a optimizar la acústica del aula mediante el ajuste de materiales absorbentes o el rediseño del espacio. (Géron, 2022)

2.39.8 Modelos de Monte Carlo

2.39.8.1 Uso: Los métodos de simulación de Monte Carlo se utilizan para simular múltiples escenarios de ruido en un aula, permitiendo a los diseñadores de espacios y educadores prever diferentes niveles de ruido bajo distintas condiciones.

2.39.8.2 Funcionamiento: Basado en la probabilidad y simulaciones aleatorias, este modelo puede predecir cómo ciertos factores (cantidad de estudiantes, uso de tecnología, ruido externo) afectan los niveles de ruido dentro del aula.

2.39.8.3 Aplicación en aulas: Planificación de mejoras acústicas o distribución de los estudiantes para reducir el impacto del ruido en actividades educativas clave. (Géron, 2022)

2.39.9 Modelos de Redes Neuronales Recurrentes (RNN)

2.39.9.1 Uso: Las RNN son adecuadas para predecir el comportamiento temporal del ruido en el aula, como el cambio en los niveles de sonido a lo largo de una clase o un evento.

2.39.9.2 Funcionamiento: Estos modelos utilizan datos secuenciales (niveles de ruido a lo largo del tiempo) para predecir cómo se desarrollarán los niveles de ruido en diferentes puntos del día.

2.39.9.3 Aplicación en aulas: Anticipar el mejor momento para actividades ruidosas o silenciosas durante la jornada escolar (Géron, 2022)

2.40 MÉTODO DE LA INVESTIGACIÓN

El método utilizado en la investigación es el método experimental , el cual ha tenido fases de recolección de datos , toma de mediciones para luego entender el comportamiento de las señales de audio en los ambientes de aprendizaje.

La metodología a utilizarse se refiere a un sistema que mida señales de ruido en zonas de contaminación acústica, el cual utiliza herramientas open para la de gestión de proyectos en cascada, el mismo que valida el trabajo en un conjunto de etapas que se ejecutan paso a paso. La metodología en cascada o Waterfall impulsa la filosofía paso a paso, o por bloques de tareas. (Digital Talent Agency, 2018).

Las etapas son:

2.40.1 Requisitos - Determinar las necesidades y objetivos del proyecto para luego desarrollar la investigación correspondiente.

2.40.2 Diseño - Describir cómo se relacionan cada uno de los elementos entre sí para que funcionen de manera correcta.

2.40.3 Implementación – Trabajar en el desarrollo del sistema de medición de señales.

2.40.4 Verificación - Realizar pruebas para detección de errores dentro del sistema implementado.

2.40.5 Mantenimiento – Presentación del producto final desarrollado, en el cual se realizará un mantenimiento dado el requerimiento necesario.

2.41 NOVEDAD CIENTÍFICA E IMPORTANCIA DE LA INVESTIGACIÓN

El proyecto propone un algoritmo de predicción de ambientes ruidosos en un entorno de aprendizaje utilizando herramientas de machine learning para sistemas predictivos

El modelo propuesto es un modelo de aprendizaje supervisado debido a que es un modelo entrenado con datos etiquetados de sonidos tomados en ambientes de aprendizaje

Este modelo va a permitir predecir niveles de sonido en un ambiente de aprendizaje de tal manera que los estudiantes y docentes que estén expuestos a altos niveles de sonido no se expongan a estos niveles tan altos y exista una intervención para que se pueda trabajar en el uso de micrófono ó utilizar paneles acústicos.

2.42 SITUACIÓN ACTUAL DE SONIDO EN LOS AMBIENTES DE APRENDIZAJE

El mundo actual con su rápido crecimiento a nivel productivo, crecimiento empresarial, construcción de inmuebles y propiedades, comercio electrónico, ciudades inteligentes, teléfonos inteligentes, pequeñas y medianas empresas ha desarrollado una cultura dinámica de movimiento de personas ha provocado que el ruido sea preconcebido como algo natural inherente al mundo actual, cuando la realidad es que ninguna persona en el mundo debería acostumbrarse a vivir con niveles de presión sonora que superen el umbral permitido por la OMS, lo que causaría daños irreversibles a cualquier ser humano. estar en su salud, como auditivo, cardiovascular, estrés y afectan su normal desarrollo en el trabajo.

El mundo actual que aprendió a vivir su aprendizaje de manera virtual debido a la emergencia sanitaria global del covid - 19 se encuentra inmerso en los componentes que deben considerarse para el aprendizaje virtual a través de herramientas telemáticas y los factores que pueden afectar su aprendizaje normal en su clase virtual. -Aula lo que repercutirá en los resultados del proceso de enseñanza-aprendizaje.

El proyecto propone el desarrollo de un sistema predictivo de niveles de presión sonora en ambientes de aprendizaje, apoyado en herramientas de aprendizaje automático que proporcione a los ciudadanos del mundo una herramienta que les permita medir los niveles de presión sonora en ambientes de aprendizaje.

Guayaquil como ciudad metropolitana se ha convertido en la actualidad en una ciudad con un alto grado de ruido, en el cual el proceso educativo se está viendo afectado por la contaminación acústica sobre todo aquellas que están ubicadas cerca a las vías principales, a los aeropuertos, mercados, entre otros, donde tanto los docentes como estudiantes son los

afectados en el proceso de enseñanza aprendizaje, debido al alto nivel de ruido en el ambiente (contaminación auditiva). (Alvarez et al., 2017)

La Organización Mundial de la Salud (OMS) considera que el ruido es uno de los principales riesgos tanto para la salud mental como la física y el bienestar. En 2018 esta entidad emitió recomendaciones para fijar niveles que no se deberían exceder para minimizar el impacto sobre la salud derivado de la exposición de los humanos al ruido según diferentes fuentes de emisión. (EL UNIVERSO, 2020) .El ruido produce efectos directos y acumulativos que no solo afectan la salud sino también la calidad de vida en general: degrada el ambiente residencial, los lugares de trabajo y de socialización, afecta la economía y, como se verá en seguida, los ambientes de aprendizaje, obligando a los estudiantes a hacer mayor esfuerzo para concentrarse y lograr generar cognición, por lo que el ruido es un factor determinante en los resultados del proceso educativo. (Páramo & Burbano, 2021)

Este proyecto se trabaja de manera experimental en la Universidad de Guayaquil.

2.43 CONTAMINACIÓN ACÚSTICA EN LA ACTUALIDAD

“La contaminación acústica en la actualidad es la tercera más peligrosa en el mundo, atrás de la contaminación del aire y del agua”. (Organización Mundial de la Salud, 2021) (Jokel y otros, 2019)

La investigación propuesta tiene una relevancia importante, debido a que el ruido es una problemática creciente, consecuencia del aumento poblacional. La contaminación sonora tiene implicancias en los aprendizajes de los estudiantes y causa efecto muy nocivo en ambientes ruidosos sobre todo en el rendimiento académico; es que el ruido tiene la capacidad de atraer

involuntariamente nuestra atención y, por lo tanto, es disruptivo en relación con las tareas que se pueden realizar en determinado momento. (Organización Mundial de la Salud, 2021)

Uno de los efectos que ocurre es el déficit de atención, aumento de la tasa de errores, imprecisión y falta de calidad en las respuestas emitidas, estados generales de ansiedad y sensación global de cansancio, que les causa inquietudes y altera la comunicación, tal factor son los ruidos de impacto tales como claxon, escapes de transportes, propaganda callejera. La productividad se da en función inversa al ruido que haya alrededor, es decir, a mayor ruido menor será el rendimiento de una persona. (Barcelona, 2022)

El proceso de aprendizaje puede ser complejo dependiendo de cada una de las situaciones que se presenten, estas pueden ser por parte del estudiante, la captación que tenga el mismo o el ambiente en el que se relaciona, es ahí donde un ambiente tranquilo es favorable para dicho proceso, ya que mejora la concentración y genera eficacia en el nivel de aprendizaje del estudiantado.

2. 44 CONSIDERACIONES DE LA CONTAMINACIÓN ACÚSTICA

En la actualidad se tiene una consideración importante a nivel mundial por los daños que produce el ruido, sin embargo el desconocimiento sobre el tema es crítico. Esta falta de visibilidad directa no solo provoca desconocimiento, sino también costumbre (Chavez, 2020). Es importante ser conscientes de que el ruido que generamos puede dañar a las personas de nuestro alrededor.

Por ello, con el fin de conocer las causas y consecuencias que el ruido provoca, se detallará a continuación en la tabla 1, mostrando datos de lo antes mencionado.

CAUSAS Y CONSECUENCIAS DE LA CONTAMINACIÓN ACÚSTICA

Tabla 1 Causas y consecuencias de la contaminación acústica

CAUSAS	CONSECUENCIAS
Tráfico vehicular	Este es al común lo cual produce la pérdida total de concentración que tiene el estudiantado frente a su área de aprendizaje debido a que su capacidad cognitiva es afectada por dicha causa.
Comercio ambulante	Al ofrecer sus productos los vendedores elevan el tono de la voz, propiciando que la acumulación de sonido empiece a incrementar y aumentar su volumen. por lo cual, los docentes se ven afectados por la interrupción ocasionada y deben esperar a

	que el ruido disminuya para proseguir con las actividades académicas.
Obras en construcción	Los alumnos y docentes están expuestos a padecer elevados niveles de estrés, y agotamiento mental producidos por la irritación que les causa el ruido emitido por las maquinarias, por ende, están obligados a subir el tono de voz dificultando el desarrollo normal de las clases.
Actividades industriales	La falta de un sistema auditivo óptimo se puede propiciar que exista una interferencia comunicativa. Al no poder discernir unos sonidos de otros, puede ser complicado la comunicación en un espacio abierto y congestionado.

2.45 ANTECEDENTES

El ruido acústico es un fenómeno estocástico que afecta físicamente a una determinada señal provocando diferentes tipos de perturbaciones en la misma, tales como distorsión (Wang et al., 2019), interferencias (Kothinki et al., 2019) y contaminación y polución acústica (Roussel et al., 2020) . La contaminación acústica es generalmente el principal problema en la degradación de la señal, ya sea analógica o digital, y puede ser causada

por diferentes ambientes entre los que podemos mencionar el ruido del tráfico urbano (Minea y Dumitrescu, 2023), el ruido de actividades externas (Jokel et al., 2019), ruidos continuos e intermitentes (Blom et al., 2019), y ambientes de ruido espontáneo (Trouvain et al., 2020) y controlado (Cohen y Berdugo, 2001) . Entre los entornos de ruido no controlado, podemos mencionar los ruidos atípicos, que han sido modelados con un método robusto de aprendizaje disperso bayesiano (SBL) (Zheng et al., 2020). El ruido del tráfico vehicular también se puede clasificar como ruido incontrolado, que se puede modelar de múltiples maneras, incluido el modelado predictivo (Ahmed et al., 2021) . En el caso del ruido controlado, se pueden mencionar los ruidos del entorno de aprendizaje, donde se pueden encontrar los mismos componentes estocásticos de igual similitud durante el aula. (Paakonen et al., 2015)

A pesar de que en el ambiente laboral los ruidos pueden ser comunes y generalmente repetitivos durante el aula, identificar correctamente cada tipo de ruido y medir el porcentaje de degradación de la señal debido a un tipo específico de ruido es un desafío (Fernandez Grande et al., 2023). En este sentido, se han desarrollado diferentes modelos computacionales con el fin de estudiar las fuentes de ruido que afectan a una señal sonora, ha desarrollado un método computacionalmente eficiente para la predicción del ruido producido por la hincada de pilotes en grandes distancias horizontales en alta mar. (Alvarez et al., 2017). El equipo de Chin (Chin C. S. et al., 2017) también ha desarrollado una. Asimismo, los ambientes de aprendizaje están limitados a un nivel de presión sonora de 82 dB y 92 dB (El Universo, 2020) para evitar síntomas perjudiciales en la salud de los individuos, en consecuencia, son necesarios estudios para mitigar el ruido en este tipo de ambientes.

Una solución para el estudio y análisis del ruido ambiental de aprendizaje es el uso de métodos de aprendizaje automático para monitorear y procesar la señal acústica.

(Páramo & Burbano, 2021).

De la misma manera, el equipo de Zheng (Zheng et al., 2020) propuso un nuevo método de aprendizaje profundo para resolver problemas de retroalimentación acústica, llamado DeepMFC, que fue diseñado como un módulo de posprocesamiento que genera el espectro complejo de la señal deseada en el receptor. (Grumiaux et al., 2022) también han presentado una descripción general completa de las técnicas de localización de fuentes de sonido (SSL), centrándose en la localización de fuentes de sonido en ambientes interiores, donde se presentan reverberación y ruido difuso. Otra alternativa para el estudio del ruido ambiental de aprendizaje es el uso del sonómetro (Sanchez Garcia et al., 2021) , que permite medir con precisión el nivel sonoro de un ambiente según estándares internacionales. Sin embargo, este tipo de dispositivos son precisos para medir el nivel sonoro de una señal incluyendo el ruido, pero no permiten determinar la causa del ruido ni la fuente que lo provoca [20]. Aunque estos estudios demuestran la viabilidad de detectar ruido en entornos de aprendizaje, así como diversos métodos implementados para el análisis del nivel de ruido, todavía existe una brecha en cuanto a los niveles de ruido recurrentes y los métodos de predicción del tipo de ruido en entornos controlados como un aula. , lo que aporta la motivación a este trabajo de investigación. (Rojas Manrique, 2020)

2.46 MARCO LEGAL

CONSTITUCIÓN DE LA REPÚBLICA DEL ECUADOR 2008 TITULO II

Capitulo segundo Derechos del buen vivir Sección segunda

Ambiente sano

Art. 14.- Se reconoce el derecho de la población a vivir en un ambiente sano y ecológicamente equilibrado, que garantice la sostenibilidad y el buen vivir, *sumak kawsay*. Se declara de interés público la preservación del ambiente, la conservación de los ecosistemas, la biodiversidad y la integridad del patrimonio genético del país, la prevención del daño ambiental y la recuperación de los espacios naturales degradados.

Sección tercera Comunicación e Información

Art. 16.- Todas las personas, en forma individual o colectiva, tienen derecho a:

1. Una comunicación libre, intercultural, incluyente, diversa y participativa, en todos los ámbitos de la interacción social, por cualquier medio y forma, en su propia lengua y con sus propios símbolos.
2. El acceso universal a las tecnologías de información y comunicación.

3. La creación de medios de comunicación social, y al acceso en igualdad de condiciones al uso de las frecuencias del espectro radioeléctrico para la gestión de estaciones de radio y televisión públicas, privadas y comunitarias, y a bandas libres para la explotación de redes inalámbricas.

4. El acceso y uso de todas las formas de comunicación visual, auditiva, sensorial y a otras que permitan la inclusión de personas con discapacidad.

5. Integrar los espacios de participación previstos en la Constitución en el campo de la comunicación.

Art. 17.- El Estado fomentará la pluralidad y la diversidad en la comunicación, y al efecto:

1. Garantizará la asignación, a través de métodos transparentes y en igualdad de condiciones, de las frecuencias del espectro radioeléctrico, para la gestión de estaciones de radio y televisión públicas, privadas y comunitarias, así como el acceso a bandas libres para la explotación de redes inalámbricas, y precautelará que en su utilización prevalezca el interés colectivo.

Sección-cuarta HÁBITAT Y VIVIENDA

Art. 31.- Las personas tienen derecho al disfrute pleno de la ciudad y de sus espacios públicos, bajo los principios de sustentabilidad, justicia social, respeto a las diferentes culturas urbanas y equilibrio entre lo urbano y lo rural. El ejercicio del derecho a la ciudad se basa en la gestión democrática de ésta, en la función social y ambiental de la propiedad y de la ciudad, y en el ejercicio pleno de la ciudadanía.

Título VII RÉGIMEN DEL BUEN VIVIR

Capítulo 1

Sección VIII

CIENCIA, TECNOLOGÍA, INNOVACIÓN Y SABERES ANCESTRALES

Art. 385.- El sistema nacional de ciencia, tecnología, innovación y saberes ancestrales, en el marco del respeto al ambiente, la naturaleza, la vida, las culturas y la

soberanía, tendrá como finalidad:

1. Generar, adaptar y difundir conocimientos científicos y tecnológicos.
2. Recuperar, fortalecer y potenciar los saberes ancestrales.
3. Desarrollar tecnologías e innovaciones que impulsen la producción nacional, eleven la eficiencia y productividad, mejoren la calidad de vida y contribuyan a la realización del buen vivir.

Art. 388.- El Estado destinará los recursos necesarios para la investigación científica, el desarrollo tecnológico, la innovación, la formación científica, la recuperación y desarrollo de saberes ancestrales y la difusión del conocimiento. Un porcentaje de estos recursos se destinará a financiar proyectos mediante fondos concursables. Las organizaciones que reciban fondos públicos estarán sujetas a la rendición de cuentas y al control estatal respectivo.

Capítulo II

BIODIVERSIDAD Y RECURSOS NATURALES

Sección I NATURALEZA Y AMBIENTE

Art. 395.- La Constitución reconoce los siguientes principios ambientales:

1. El Estado garantizará un modelo sustentable de desarrollo, ambientalmente equilibrado y respetuoso de la diversidad cultural, que conserve la biodiversidad y la capacidad de regeneración natural de los ecosistemas, y asegure la satisfacción de las necesidades de las generaciones presentes y futuras.

2. Las políticas de gestión ambiental se aplicarán de manera transversal y serán de obligatorio cumplimiento por parte del Estado en todos sus niveles y por todas las personas naturales o jurídicas.

3. El Estado garantizará la participación y permanente de las personas, comunidades, pueblos y nacionalidades afectadas, en la planificación, ejecución y control de toda actividad que genere impactos ambientales.

4. En caso de duda sobre el alcance de las disposiciones legales en materia ambiental, éstas se aplicarán en el sentido más favorable a la protección de la naturaleza.

Art. 396.- El Estado adoptará las políticas y medidas oportunas que eviten los impactos ambientales negativos, cuando exista certidumbre de daño. En caso de duda sobre el impacto ambiental de alguna acción u omisión, aunque no exista evidencia científica del daño, el Estado adoptará medidas protectoras eficaces y oportunas.

Cada uno de los actores de los procesos de producción, distribución, comercialización y uso de bienes o servicios asumirá la responsabilidad directa de prevenir cualquier impacto ambiental, de mitigar y reparar los daños que ha causado, y de mantener un sistema de control ambiental permanente. (CONSTITUCIÓN DE LA REPÚBLICA DEL ECUADOR, 2008)

REGLAMENTO DEL CÓDIGO ORGÁNICO DEL AMBIENTE

Capítulo III

INSTRUMENTOS DEL SISTEMA NACIONAL DESCENTRALIZADO DE GESTIÓN AMBIENTAL

Sección 2a Investigación ambiental

Art. 28.- Fines de la investigación ambiental. - La investigación ambiental, como instrumento del Sistema Nacional Descentralizado de Gestión Ambiental, tendrá los siguientes fines:

- a) Desarrollar y adquirir nuevos conocimientos e información ambiental;

- b) Contar con datos científicos y técnicos sobre el medio ambiente, con el objeto de construir políticas y estrategias ambientales nacionales; y,
- c) Contar con una base de información científica y técnica que fundamente la toma de decisiones sobre la gestión ambiental, orientadas a prevenir y solucionar problemas ambientales, promover el desarrollo sostenible, garantizar la tutela de los derechos de naturaleza y de las personas.

Art. 29.- Lineamientos Estratégicos Nacionales de Investigación Ambiental.- La Autoridad Ambiental Nacional elaborará, en coordinación con el ente rector del Sistema Nacional de Ciencia, Tecnología, Innovación y Saberes Ancestrales, y expedirá los Lineamientos Estratégicos Nacionales de Investigación Ambiental, mismos que deberán ser concordantes con el Plan Nacional de la Economía Social de los Conocimientos, Creatividad, Innovación y Saberes Ancestrales y los lineamientos técnicos establecidos por el ente rector del Sistema Nacional de Ciencia, Tecnología y Saberes Ancestrales, mismos que deberán actualizarse periódicamente.

Sección 4a

MANEJO DE LA INFORMACION AMBIENTAL

Art. 42.- Información Ambiental. - La información ambiental servirá para la toma de decisiones, políticas y estrategias y otras acciones necesarias para la ejecución de los objetivos de la política ambiental nacional y su interacción con las políticas

económicas y sociales y se gestionará conforme a lo establecido en la Ley Orgánica de Transparencia y Acceso a la Información Pública.

Art. 43.- Recopilación de información ambiental.- La Autoridad Ambiental Nacional deberá coordinar con las instituciones de educación superior, instituciones de investigación, entidades del Sistema Nacional Descentralizado de Gestión Ambiental y del Estado en general, así como las personas naturales o jurídicas, lo relativo a la contribución de información ambiental, y datos científicos en materia ambiental, con el objeto de recopilar y compilar dichos datos en el Sistema Único de Información Ambiental a fin de fundamentar la toma de decisiones administrativas y el desarrollo de políticas ambientales.

El manejo de la información que provenga de las investigaciones realizadas sobre los recursos genéticos se registrará por su normativa específica y deberá coordinarse con el Instituto Público de Investigación sobre Biodiversidad. (CÓDIGO ORGÁNICO DEL AMBIENTE, 2017)

LA ORDENANZA PARA PREVENIR Y MITIGAR EL RUIDO EN EL CANTON DE GUAYAQUIL

Ordenanza que regula la aplicación del subsistema de manejo ambiental, control y seguimiento ambiental en el cantón Guayaquil. La ordenanza para prevenir y mitigar el ruido en el cantón Guayaquil

Art 1.- Ámbito: Las disposiciones de la presente ordenanza se aplicarán a las personas naturales y jurídicas, públicas y privadas, cuyas actividades produzcan y originen emisiones contaminantes de ruido y vibraciones, que provengan de fuentes emisoras de ruido fijas y móviles con potencial de producir impactos ambientales negativos que

afecten a la salud o bienestar de las personas que habitan en el cantón Guayaquil, así como a la fauna silvestre.

Art 7.- Del ruido en la vía pública: En la vía pública no se podrá usar, salvo autorización expresa, altoparlantes, equipos amplificadores de sonidos, instrumentos musicales, megáfonos cualquier otro aparato o dispositivo similar cuyas emisiones sonoras superen los niveles permisibles según la legislación ambiental aplicable.

Art. 11.- Quienes transgredan las disposiciones del presente título serán sancionados conforme lo establece la “Ordenanza que regula la aplicación del subsistema de manejo, control y seguimiento ambiental en el cantón Guayaquil”, en el título de las infracciones y sanciones, por exceder los límites permisibles establecidos en las normas técnicas aplicables.

Art 14.- Cuando por cualquier circunstancia, los vehículos automotores rebasen los niveles máximos permisibles de emisión de ruido definidos en la normativa ambiental aplicable, el responsable deberá adoptar, en un tiempo no mayor de treinta (30) días calendario, las medidas necesarias con el objeto de que el vehículo se ajuste a los niveles adecuados.

Para efectos de prevenir y controlar la contaminación por la emisión de ruido ocasionada por motocicletas, automóviles, camiones, autobuses, y similares, estos deberán sujetarse a los niveles permisibles expresados en la normativa ambiental aplicable.”

Art. 18.- Quienes transgredan las disposiciones de la presente Ordenanza serán sancionados con una multa de 1 a 5 salarios básicos unificados, en caso de reincidencia serán sancionados con la suspensión de actividades y/o clausura de ser el caso,

además del cobro de una multa que oscila entre los 5 y 10 salarios básicos unificados, por exceder los límites permisibles establecidos en las normas técnicas aplicables. (LA ORDENANZA PARA PREVENIR Y MITIGAR EL RUIDO EN EL CANTÓN DE GUAYAQUIL , 2014)

CAPÍTULO 3: MATERIALES Y MÉTODOS

3.1 IMPLEMENTACIÓN DEL SISTEMA DE PREDICCIÓN

La propuesta consiste en medir los niveles de presión sonora que existe en un ambiente de aprendizaje utilizando hardware de medición y luego mediante técnicas de machine learning utilizando python predecir niveles de presión sonora en estos ambientes de aprendizaje.

Para lograr esto se ha procedido de la siguiente manera:

3.1.1 Selección de los ambientes de prueba:

Para los ambientes de prueba se han seleccionado 3 laboratorios de la carrera Ingeniería en Tecnologías de la Información de la Facultad de Ciencias Matemáticas y Física de la Universidad de Guayaquil, en los cuales se imparten clases en horario matutino y vespertino.

Una vez seleccionado los ambientes de prueba experimental se procede a seleccionar el hardware que va a realizar las mediciones de presión sonora en los ambientes de aprendizaje

3.1.2 Selección de hardware de medición para niveles de presión sonora :

Para las mediciones se ha seleccionado el sonómetro SML- 25 que tiene las siguientes características :

- Bola de esponja
- USB socket
- Micrófono de condensador
- Pantalla LCD con iluminación
- Interruptor de encendido/apagado
- Botón de selección de ponderación de frecuencia A/C
- Botón de lectura MAX
- Botón Rápido / lento
- Botón de iluminación
- Botón del tiempo para grabación
- Rosca de montaje del trípode
- Tapa de la batería
- Socket de salida AC
- Socket de salida DC




Ilustración 4 Componentes del hardware de medición Sonómetro SML-25

predecir niveles de sonido en ambientes de aprendizaje, para lograrlo se ha utilizado equipos de medición de presión sonora y ruido de alta precisión, El equipo utilizado es el sonómetro SLM-25

El sonómetro utiliza un micrófono ambiental que capta todos los sonidos provenientes en el aula de aprendizaje.

Sensa el nivel de sonidos y utiliza un software que graba y almacena las mediciones que se configuran en el sonómetro. El software permite exportar las mediciones realizadas por el sonómetro y transmitidas al ordenador a través de un cable USB.

El software de medición puede parametrizarse en relación al tiempo que se desea medir y el número de mediciones que se desea obtener.

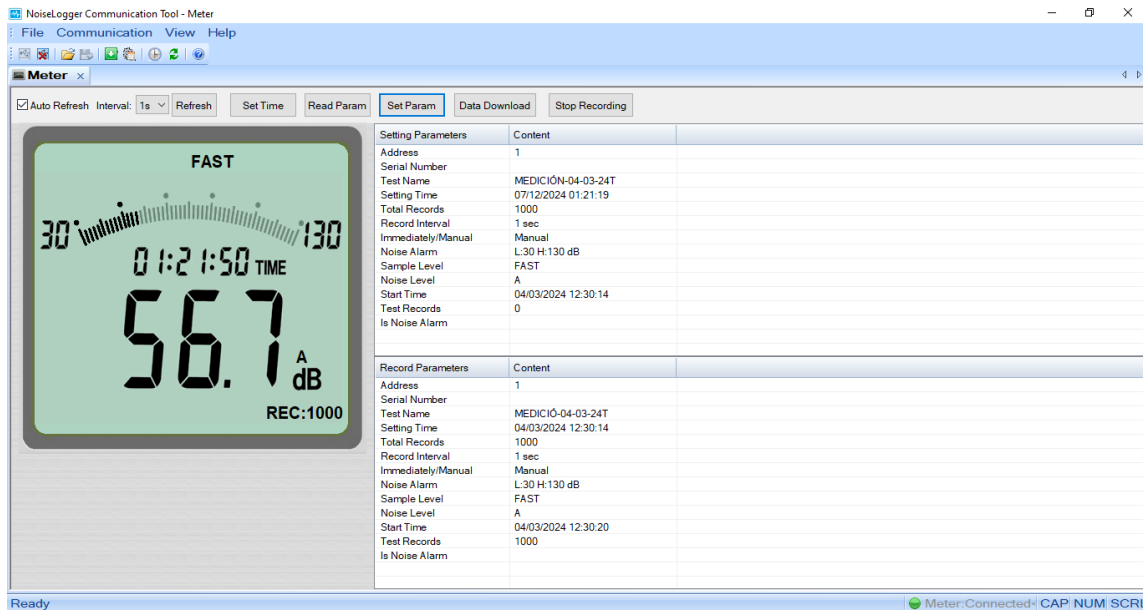


Ilustración 5 Software de medición del sonómetro SLM-25

El sonómetro SML – 25 ha sido utilizado experimentalmente para realizar las siguientes actividades:

- Recopilar los registros de los diferentes niveles de ruido en diferentes ambientes de aprendizaje en este caso la Universidad de Guayaquil, en la Carrera de Tecnologías de la Información.
- Exportar las mediciones con toda la data y poder construir el DataSet para construir un esquema predictivo en ambientes de aprendizaje



Ilustración 6 Sonómetro SLM – 25

3.1.3 Selección del lenguaje de programación y la herramienta para predicción

El lenguaje de programación utilizado para desarrollar el algoritmo predictivo que permita evaluar presión sonora en ambientes de aprendizaje es Python y las técnicas para lograr la predicción Machine learning

El objetivo del proyecto es realizar un estudio sobre los niveles de sonido que existen en los ambientes de aprendizaje y aportar un esquema de predicción de sonidos en un entorno de aprendizaje.

3.1.4 Implementación del Mecanismo

La implementación inicia con la recolección de información, la cual se realizará a través de la toma de mediciones en las clases de la carrera de tecnologías de la información de la Universidad de Guayaquil, con equipos de precisión (sonómetro digital).



Ilustración 7 Sonómetro conectado a la recolección de datos

En esta etapa se detalla la fase, ya que a través de un instrumento de precisión llamado sonómetro digital SLM-25, se realizan las mediciones con precisión, es fundamental considerar cada uno de los aspectos y parámetros para el correcto uso de este dispositivo, ya que existe una gran variedad de ruidos y ambientes sonoros, de igual manera es posible que se obtengan varios de los indicadores que determinan las fuentes sonoras, realizaremos las mediciones de tal manera poder visualizar en nuestro ordenador , descargar y generar reportes de los datos de medición de ruido que nos permitirán exportar a través del Dataset, todo lo anterior nos permitirá realizar la Evaluación de Ruido. herramienta de comunicación logger, que es un software compatible con el sonómetro SLM – 25 .

Las mediciones que se realizarán estarán determinadas en decibelios, los mismos que son muy utilizados ya que está adaptado a la percepción del oído humano, donde se suprime parte de las frecuencias altas y bajas.



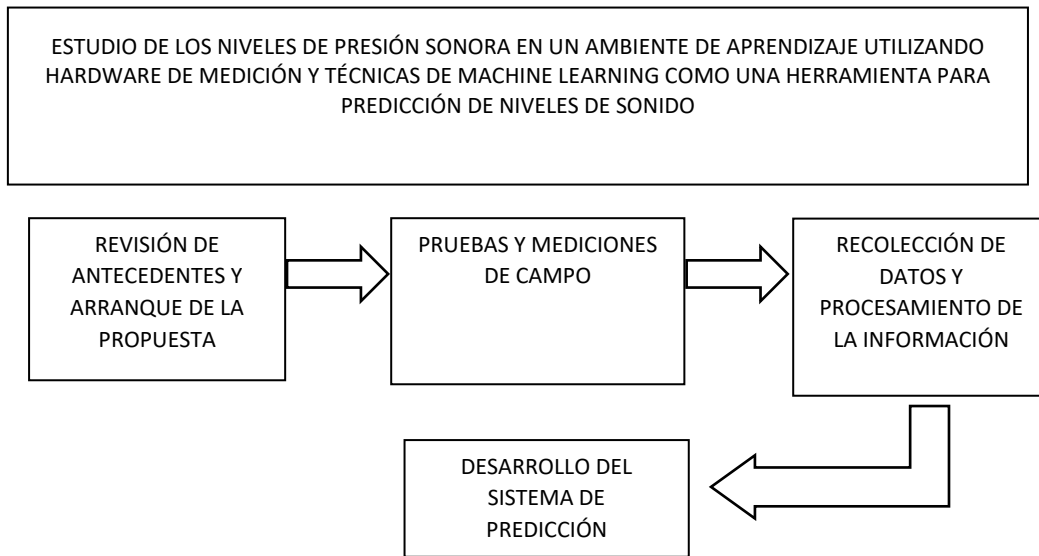
Ilustración 8 Sistema de medición SLM – 25

Para determinar los niveles de ruido en cada una de las clases , se establecieron periodos de monitoreo de 20 minutos aproximadamente, donde se recopiló información de ruido mediante el uso de el sonómetro SLM-25 junto con el software del mismo

Con los datos recolectados, la información obtenida se construyó el Dataset donde se consideran los niveles máximos y mínimos obtenidos de cada periodo de lectura. Para este proceso se recolectaron un total de 1000 muestras para cada clase donde se aplicó una media aritmética para obtener el valor promedio de cada sesión de clase.

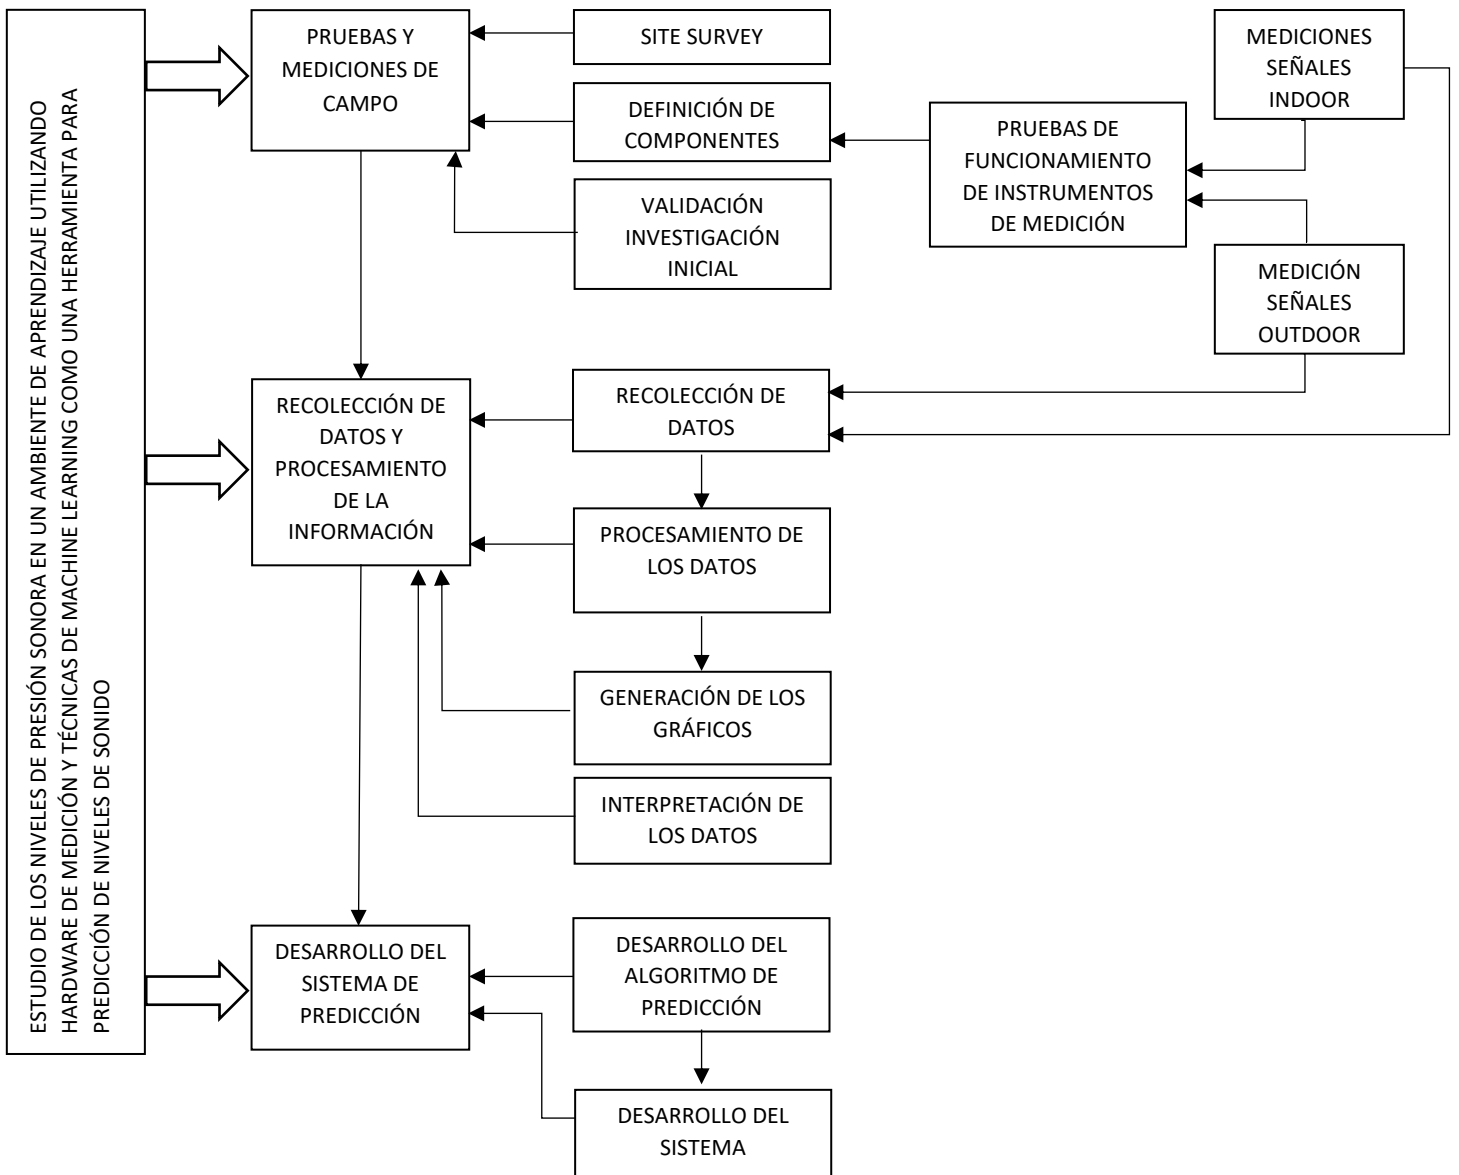
A continuación el diagrama de flujo por fases de la ejecución del proyecto

3.1.5 Diagrama de fases del estudio



Fuente: Autor

3.1.6 Estudio de los niveles de presión sonora en un ambiente de aprendizaje utilizando hardware de medición y técnicas de machine learning como una herramienta para predicción de niveles de sonido



Fuente: Autor

El proyecto se realiza en 3 fases:

3.1.7 FASE 1

La primera Fase se enfoca en el trabajo de campo , en esta etapa es donde se realiza la recolección de la data, se inicia con el site survey para identificar cada lugar en el cual se van a realizar las mediciones de los diferentes niveles de sonido los cuales van a ser tomados con muestras en número de mil seteadas a 1 segundo por muestra.

El escenario para las tomas de las muestras serán las aulas de la carrera Tecnologías de la Información de la Facultad de Ciencias Matemáticas y Física de la Universidad de Guayaquil

En esta fase se realiza la validación inicial de la investigación entendiendo la problemática y proponiendo el estudio para la respectiva solución.

Para realizar una correcta recolección de la data se debe evaluar los instrumentos adecuados para la recolección de la data por lo cual una vez seleccionados se realizan rigurosas pruebas de funcionamiento a los instrumentos de medición y se define trabajar con el sonómetro SLM – 25 con su respectivo software de recolección de la data.

Las señales que van a tomarse para la generación de la data son las señales indoor y outdoor de esta manera se consigue una toma adecuada de la realidad de los sonidos presentes en el aula de aprendizaje.

3.1.8 FASE 2

La segunda Fase se enfoca en la recolección de la data y el procesamiento de la información .

En esta fase se procede a tomar toda la data recolectada para un adecuado procesamiento de los datos, se procede a armar el dataset con la información recolectada en las aulas de aprendizaje.

La recolección de la data está en función de las muestras tomadas con el dispositivo de medición sonómetro SLM – 25.

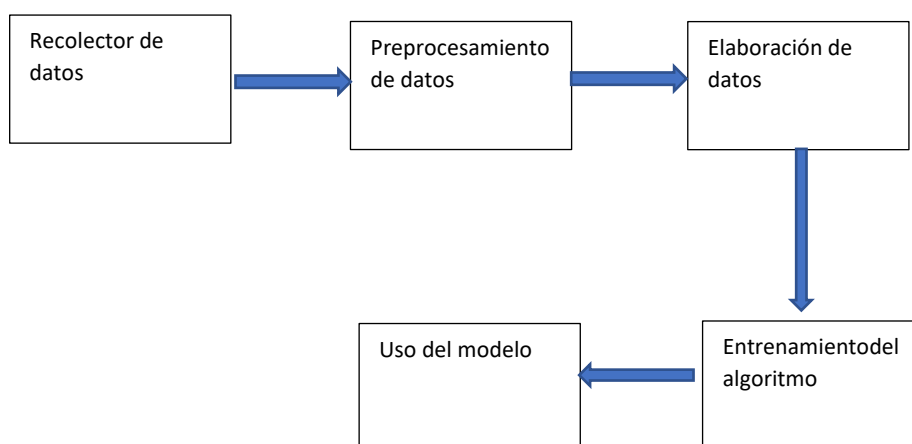
Para la recolección de la data se utiliza el softwar del sonómetro y se importan los datos a una tabla Excel que pemite comparar los datos

3.1.9 FASE 3

La tercera Fase se enfoca en facilitar una solución para poder medir y predecir niveles de ambientes sonoros construyendo un algoritmo predictivo utilizando Python y herramientas de Machine Learning.

En esta fase se utiliza código libre y lenguajde de programación de alto nivel Python.

3.2 Construcción del modelo Machine Learning



Fuente: Autor

3.3 Implementación del algoritmo predictivo

Para la implementación del sistema se utiliza el algoritmo predictivo.

El proceso de la implementación del algoritmo realiza la siguiente operación:

3.3.1. Importación de las librerías

La importación de las librerías se realiza para el análisis de datos, visualización y cálculos científicos en Python

```
import matplotlib as mpl
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
import seaborn as sns
```

3.3.2. Carga del DataSet al entorno de trabajo

Se carga el DataSet en el entorno de trabajo.

El dataset se lo realiza con la información de toda la Data recopilada del proceso de medición tomando en el lugar de experimentación.

La carga de datos se realiza desde un archivo Excel en un DataFrame de pandas en Python.

```
data=pd.read_excel("DATASET_TI_UG.xlsx")
data
```

3.3.2.1 Tabla de mediciones

La tabla de mediciones muestra los valores de presión sonora que han sido tomado de las mediciones de campo en el entorno de aprendizaje que fue utilizado como laboratorio experimental

Tabla 2 Tabla de mediciones

Mediciones	LAB1_S1	LAB1_S2	LAB1_S3	
0	1	68.7	64.5	73.4
1	2	69.6	67.2	65.0
2	3	75.9	66.5	61.6
3	4	65.4	70.3	63.4
4	5	69.9	77.8	79.5
...
995	996	68.3	74.1	77.8
996	997	79.4	71.8	71.1
997	998	67.8	67.4	63.6
998	999	68.4	66.8	69.9
999	1000	67.2	68.0	82.5

1000 rows × 4 columns

3.3.3 Gráfico de las mediciones de prueba LAB1_S1

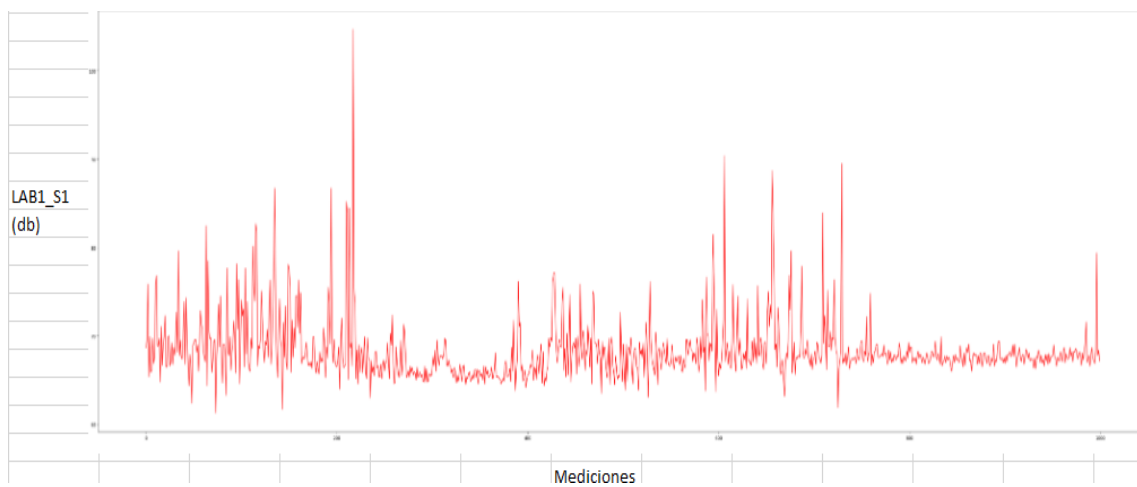


Ilustración 9 Mediciones LAB1_S1

3.3.4 Gráfico de las mediciones de prueba LAB1_S2

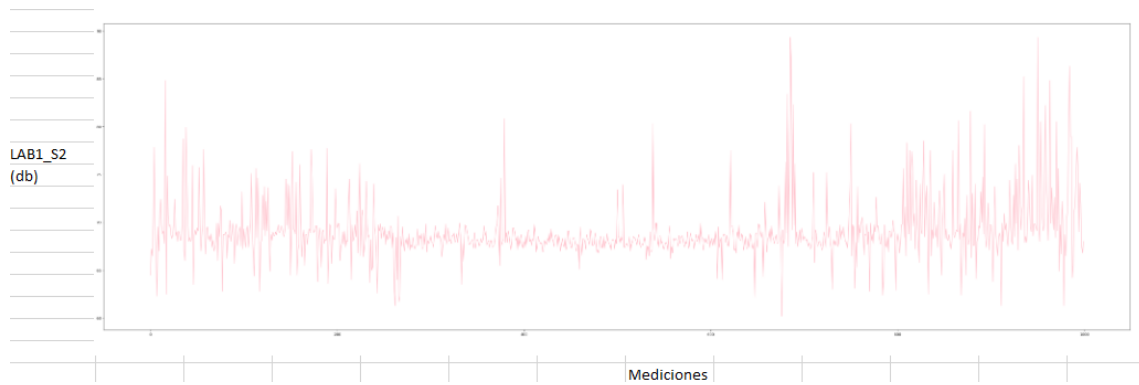


Ilustración 10 Mediciones LAB1_S2

3.3.5 Gráfico de las mediciones de prueba LAB1_S3




Ilustración 11 Mediciones LAB1_S3

3.3.6 Devolución de los tipos de datos de cada columna en el Dataframe

Tabla 3 Datos de cada columna en el Dataframe

	0
Mediciones	int64
LAB1_S1	float64
LAB1_S2	float64
LAB1_S3	float64

dtype: object

3.3.7 Gráfico de las mediciones de prueba LAB1_S1, LAB1_S2, LAB1_S3




Ilustración 12 Mediciones LAB1_S1, LAB1_S2, LAB1_S3

3.3.8 Primeras 3 filas del Dataframe

Tabla 4 Filas del Dataframe

	Mediciones	LAB1_S1	LAB1_S2	LAB1_S3
0	1	68.7	64.5	73.4
1	2	69.6	67.2	65.0
2	3	75.9	66.5	61.6

3.3.9 Métricas

Tabla 5 Métricas

	Mediciones	LAB1_S1	LAB1_S2	LAB1_S3
count	1000.000000	1000.000000	1000.000000	1000.000000
mean	500.500000	68.35770	69.046900	69.89480
std	288.819436	3.51937	3.185291	4.22594
min	1.000000	61.30000	60.200000	60.70000
25%	250.750000	66.60000	67.700000	66.70000
50%	500.500000	67.60000	68.400000	69.80000
75%	750.250000	69.00000	69.500000	72.70000
max	1000.000000	104.70000	89.300000	85.40000

3.3.10 Dimensiones del Dataframe

(1000, 4)

1000 Filas

4 Columnas

3.3.11 Creación de columna de predicción de n semanas en el futuro

```
#Una variable para predecir n semanas en el futuro
import numpy as np
prediction_semanas=3

data['Prediction']= data[['LAB1_S1']].shift(-prediction_semanas)
data['Prediction']= data[['LAB1_S2']].shift(-prediction_semanas)
data['Prediction'] = data[['LAB1_S3']].shift(-prediction_semanas) # Use LAB1_S3 for Prediction column
```

3.3.12 Creación de conjunto de datos independientes

```
#crea un conjunto de datos independientes
X = np.array(data.drop(['Prediction'], axis=1)) # Now this should work because 'Prediction' column exists.
X = X[:len(data) - prediction_semanas]
print(X)
```

Tabla 6 Tabla de conjunto de datos independientes

```
[[ 1.  68.7  64.5  73.4]
 [ 2.  69.6  67.2  65. ]
 [ 3.  75.9  66.5  61.6]
 ...
 [995.  66.9  69.  65.9]
 [996.  68.3  74.1  77.8]
 [997.  79.4  71.8  71.1]]
```

3.3.13 Creación de la variable para predicción

```
Y=np.array(data['Prediction'])
Y= Y[:-prediction_semanas]
print (Y)
```

3.3.14 Evaluación de rendimiento del modelo predictivo

```
from sklearn.model_selection import train_test_split
X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size=0.2)
```

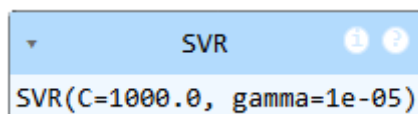
3.3.15 Entrenamiento un modelo de regresión con soporte vectorial (SVR)

```
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.svm import SVR

# Split data into training and testing sets
X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size=0.2)

# Create and train the Support Vector Regression model
svr_rbf = SVR(kernel='rbf', C=1e3, gamma=0.00001)
svr_rbf.fit(X_train, Y_train)
```

3.3.16 Técnica de regresión basada en SVM



The screenshot shows a Jupyter Notebook cell with a blue header containing a dropdown arrow, the text "SVR", and two circular icons (one with an 'i' and one with a '?'). Below the header, the cell content displays the text "SVR(C=1000.0, gamma=1e-05)".

3.3.17 Arreglo para predicción

```
prediction_semanas_array = np.array(data.drop(['Prediction'], axis=1))[-predi]
print(prediction_semanas_array)
```

```
[ [ 998.    67.8   67.4   63.6]
  [ 999.    68.4   66.8   69.9]
  [1000.    67.2   68.    82.5]]
```

Tabla 7 Tabla de arreglo para predicción

3.3.18 Modelo de prueba

```
#modelo de prueba
svr_rbf_confidence= svr_rbf.score(X_test, Y_test)
print('svr_rbf accuracy: ', svr_rbf_confidence)
```

```
svr_rbf accuracy: -0.014246833335805897
```

3.3.19 Imprimir el valor predicho

```
#imprime valor predicho
svm_prediction= svr_rbf.predict(X_test)
print(svm_prediction)
print()
#imprime valores reales
print(Y_test)
```

3.3.20 Predicción con el modelo SVR

```
svm_prediction= svr_rbf.predict(prediction_semanas_array)
print(svm_prediction)
```

```
data.tail(prediction_semanas)
```

```
[69.28657377 68.94864085 67.99559109]
```

3.3.21 Predicción

Tabla 8 Tabla de predicción

	Mediciones	LAB1_S1	LAB1_S2	LAB1_S3	Prediction
0	1	68.7	64.5	73.4	63.4
1	2	69.6	67.2	65.0	79.5
2	3	75.9	66.5	61.6	70.4

3.3.22 Gráfica de la predicción

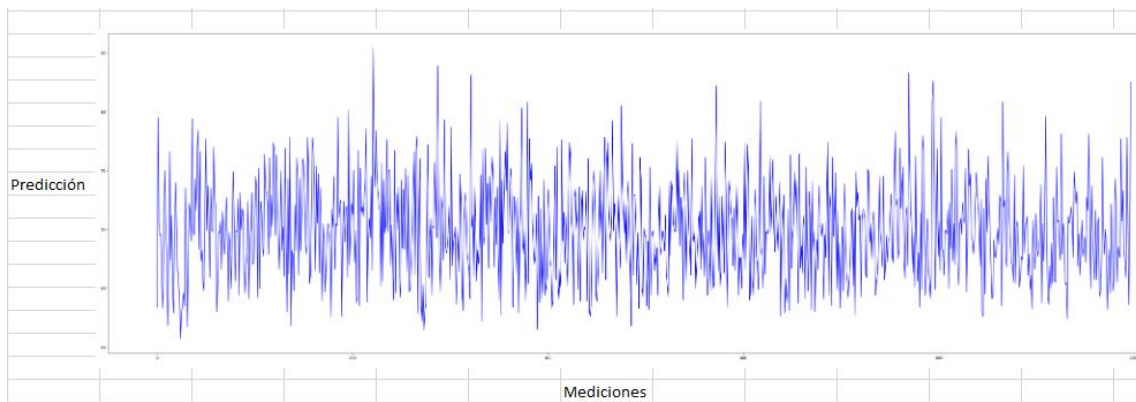


Ilustración 13 Gráfica de la predicción

3.3.23 Gráfica de mediciones y predicción




Ilustración 14 Gráfica de mediciones y predicción

CAPÍTULO 4. RESULTADOS

Los resultados obtenidos en esta investigación muestran que medir el nivel de contaminación acústica en un aula de aprendizaje es muy relevante dado las implicaciones que esta tiene.

Los objetivos planteado muestran los siguientes resultados:

Al realizar el análisis de las mediciones en el aula de clases para determinar el nivel de contaminación acústica que fueron tomadas en el aula de clase de Lab1 como entorno de experimentación y recolección de datos se observó que los valores en decibelios obtenidos en algunas ocasiones supera el nivel de umbral máximo permitido aceptable al oído humano.

El equipo de medición utilizado toma el nivel de presión sonora de toda el aula de clase que es el ambiente de aprendizaje y entorno del mismo toma muestras que han sido programadas 1000 tomas cada segundo , lo que implica 16.67 minutos de mediciones en distintos días obteniendo así medidas precisas en el entorno experimental de aprendizaje.

Se ha desarrollado un algoritmo predictivo automatizado utilizando técnicas de machine learning y python para ambientes de aprendizaje. El mismo que ha sido construido con un sistema de regresión lineal y un algoritmo de aprendizaje supervisado SVR . El grado de precisión del modelo divide los datos en conjuntos de entrenamiento y prueba.

	Mediciones	LAB1_S1	LAB1_S2	LAB1_S3	Prediction
0	1	68.7	64.5	73.4	63.4
1	2	69.6	67.2	65.0	79.5
2	3	75.9	66.5	61.6	70.4

Los valores de medición que el sistema predictivo genera utiliza un algoritmo de aprendizaje supervisado que es eficiente ya que se evalúa principalmente por su capacidad para predecir resultados con precisión, rapidez y uso adecuado de recursos, esta técnica SVR es una técnica de aprendizaje supervisado que se utiliza para resolver problemas de regresión

En el análisis de la señal en la sala experimental LAB1_S1 existen fluctuaciones en los valores de decibelios que supera el mínimo permitido indicando claramente que existen picos de señal auditiva que supera el umbral permitido para el normal desarrollo de la clase en el ambiente de aprendizaje.

En los resultados de las mediciones tenemos que en LAB1_S1 el valor máximo obtenido en la medición con el equipo de precisión de presión sonora es de 104,7 decibelios, lo cual indica que está por encima de los 70 decibelios que son considerados el máximo valor permitido para no afectación al oído humano, el valor mínimo es de 61, 3 decibelios lo cual es un valor aceptable dentro del rango permitido. El valor promedio obtenido en esta aula experimental de entorno de aprendizaje es de 68,35 decibelios lo cual indica que en términos generales el ambiente de aprendizaje proporciona un adecuado ambiente de aprendizaje ya que no supera el valor del umbral permitido.

En el análisis de la señal en la sala experimental LAB1_S2 existen fluctuaciones en los valores de decibelios que supera el umbral permitido para el normal desarrollo de la clase en el ambiente de aprendizaje.

En los resultados de las mediciones tenemos que en LAB1_S2 el valor máximo obtenido en la medición con el equipo de precisión de presión sonora es de 89,3 decibelios, lo cual indica que está por encima de los 70 decibelios que son considerados el máximo valor permitido para no afectación al oído humano, el valor mínimo es de 60,2 decibelios lo cual es un valor aceptable dentro del rango permitido. El valor promedio obtenido en esta aula experimental de entorno de aprendizaje es de 69,04 decibelios lo cual indica que en términos generales el ambiente de aprendizaje proporciona un adecuado ambiente de aprendizaje ya que no supera el valor del umbral permitido.

En el análisis de la señal en la sala experimental LAB1_S2 existen fluctuaciones en los valores de decibelios que supera el umbral permitido para el normal desarrollo de la clase en el ambiente de aprendizaje.

En los resultados de las mediciones tenemos que en LAB1_S3 el valor máximo obtenido en la medición con el equipo de precisión de presión sonora es de 85,4 decibelios, lo cual indica que está por encima de los 70 decibelios que son considerados el máximo valor permitido para no afectación al oído humano, el valor mínimo es de 60,7 decibelios lo cual es un valor aceptable dentro del rango permitido. El valor promedio obtenido en esta aula experimental de entorno de aprendizaje es de 69,89 decibelios lo cual indica que en términos generales el ambiente de aprendizaje proporciona un adecuado ambiente de aprendizaje ya que no supera el valor del umbral permitido.

El algoritmo muestra un SVR con un $C=1000.0$ el cual indica un alto nivel de precisión y un $\gamma=1e-05$ lo cual indica que tiene una influencia alta .

El modelo de entrenamiento utiliza un algoritmo de aprendizaje supervisado SVM

En los resultados de las mediciones que obtenemos para LAB1_PREDICTION el valor que predice el algoritmo de presión sonora es de 85,4 decibelios en su valor máximo, lo cual indica que está por encima de los 70 decibelios que son considerados el máximo valor permitido para no afectación al oído humano, el valor mínimo es de 60,7 decibelios lo cual es un valor aceptable dentro del rango permitido. El valor promedio obtenido en esta aula experimental de entorno de aprendizaje es de 69,90 decibelios lo cual indica que en términos generales el ambiente de aprendizaje proporciona un adecuado ambiente de aprendizaje ya que no supera el valor del umbral permitido.

De manera general podemos establecer que el aula seleccionada como ambiente de aprendizaje posee las características adecuadas como un ambiente de aprendizaje, sin embargo debido a los valores picos de elevación de sonido por encima del umbral permitido se sugiere que se haga una readecuación del aula de aprendizaje mejorando la acústica del mismo para mitigar y suprimir esos valores de presión sonora que sobrepase el umbral permitido al oído humano.

4.1 VALORACIONES Y DISCUSIÓN

El sistema de predicción propone una herramienta muy potente para evaluar niveles de contaminación acústica en un ambiente de aprendizaje el cual podría garantizar un óptimo rendimiento de las personas que laboran en la institución.

Los individuos que intervienen en el proceso educativo enseñanza – aprendizaje tendrán una opción de verificar y validar el entorno de contaminación acústica al que están expuestos , lo que les permitiría tomar las medidas adecuadas para la protección de su salud auditiva y el control de los niveles de contaminación acústica y estrés causado por el mismo.

Además, ofrece la posibilidad de monitorear y analizar de manera continua el nivel de exposición a ruido en el aula, permitiendo a los individuos involucrados en el proceso enseñanza-aprendizaje verificar y validar las condiciones acústicas del entorno. Este acceso a información detallada no solo facilita la toma de decisiones informadas, sino que también promueve la adopción de medidas preventivas para proteger la salud auditiva de los usuarios.

El sistema también podría contribuir al control efectivo de los niveles de ruido, reduciendo el estrés causado por la contaminación acústica y mejorando, en consecuencia, la calidad del ambiente educativo. Estas ventajas abren la puerta a nuevas estrategias para optimizar los espacios de aprendizaje y promover la salud física y mental de quienes los habitan.

La contaminación acústica en ambientes de aprendizaje no solo afecta la calidad educativa, sino que también tiene repercusiones significativas en la salud física y mental de las personas expuestas. Diversos estudios han demostrado que niveles elevados de ruido pueden provocar problemas como pérdida auditiva, estrés crónico, dificultades

para la concentración, fatiga y disminución del rendimiento cognitivo en estudiantes y docentes.

El sistema de predicción desarrollado representa una herramienta clave para mitigar estos efectos adversos al ofrecer la capacidad de monitorear y evaluar de manera continua los niveles de contaminación acústica. Esto permite identificar momentos y espacios donde el ruido excede los umbrales recomendados por organismos como la Organización Mundial de la Salud (OMS), que establece que los niveles de ruido en aulas no deberían superar los 70 dB durante actividades educativas.

Al contar con datos precisos y en tiempo real, los usuarios, como estudiantes, docentes y administradores de instituciones educativas, pueden tomar decisiones informadas para proteger su salud auditiva.

Algunas acciones que deben tomarse deben ser: Implementar soluciones de insonorización en aulas o espacios comunes, ajustar horarios o actividades que generen niveles de ruido altos, concienciar sobre la importancia de mantener niveles acústicos saludables.

Por otra parte, el estrés es otra consecuencia frecuente del ruido excesivo, también puede ser reducido mediante la intervención oportuna que el sistema facilita. El estrés acústico, asociado con una exposición prolongada a ruidos fuertes, puede desencadenar problemas cardiovasculares, aumento en los niveles de cortisol y dificultades para dormir, lo que impacta directamente en el bienestar de docentes y estudiantes.

Además, al abordar estas problemáticas, el sistema no solo protege la salud auditiva y mental, sino que también contribuye a mejorar el rendimiento académico y la calidad de vida en el entorno educativo. Esta herramienta destaca como una solución tecnológica avanzada para abordar un problema que, aunque intangible, tiene efectos tangibles y a menudo subestimados en la salud de las personas.

La exposición prolongada a niveles altos de ruido impacta directamente el rendimiento académico. Se ha documentado que el ruido interfiere con habilidades clave como la **memoria a corto plazo**, la **comprensión lectora** y la **resolución de problemas matemáticos**. Según un estudio de (Shield y Dockrell, 2008), los estudiantes que están expuestos a niveles de ruido superiores a **65 dB** muestran una disminución del rendimiento en pruebas cognitivas del 20% en comparación con aquellos en entornos acústicamente adecuados.

Además, los niveles de ruido elevados generan un aumento en los niveles de **estrés psicológico**, lo que se traduce en irritabilidad, pérdida de atención y fatiga mental, limitando la capacidad de los estudiantes para participar activamente en el aprendizaje.

Los docentes, al ser quienes pasan más tiempo en las aulas, también están expuestos a los efectos adversos del ruido. Niveles de ruido superiores a **50 dB** dificultan la comunicación oral, obligándolos a elevar el volumen de su voz, lo que incrementa el riesgo de desarrollar **trastornos de la voz**. Un estudio realizado por (Mealings et al., 2023) encontró que el 60% de los docentes que trabajan en entornos ruidosos reportaron síntomas relacionados con la disfonía crónica.

Asimismo, el estrés asociado con el ruido en el entorno laboral puede provocar problemas cardiovasculares, como hipertensión, así como un aumento de los niveles de cortisol, afectando su bienestar general y desempeño profesional.

El sistema predictivo desarrollado, basado en un modelo de aprendizaje supervisado como el **SVR (Support Vector Regression)**, proporciona una solución tecnológica avanzada para abordar estos desafíos. Al monitorear y evaluar los niveles de ruido de manera continua, el sistema puede identificar de forma precisa aquellos momentos y áreas en los que el ruido excede los umbrales aceptables

Al tener esta herramienta de predicción permitirá tomar decisiones adecuadas para mejorar el entorno de aprendizaje con lo cual se debería reorganizar las actividades que

general niveles altos de ruido en horarios específicos, insonorizar espacios con materiales acústicos adecuados, diseñar intervenciones educativas para concienciar a estudiantes y docentes sobre el impacto del ruido.

El sistema también facilita la creación de **mapas acústicos dinámicos**, lo que permite a las instituciones educativas visualizar los patrones de contaminación acústica en tiempo real y planificar intervenciones más efectivas

RETOS Y PERSPECTIVAS

El mayor reto que se puede tener en este tipo de proyectos es que este estudio sirva como el inicio de un proceso de concientización sobre los niveles de contaminación acústica que existe en los diferentes entornos de aprendizaje, que se vuelva una política pública que se establezcan normas y debido control de cumplimiento de esta normativa.

Que periódicamente se realicen estudios en todas las instituciones de Educación Superior, media y básica sobre el nivel de contaminación acústica al que están expuesto todos los involucrados en el proceso educativo, enseñanza – aprendizaje

Que este estudio sea el primero de muchos más que sigan aportando herramientas para el control de la contaminación acústica en ambientes de aprendizaje.

CONCLUSIONES

- Se logró recolectar los datos para el análisis de los niveles de presión sonora en los ambientes de aprendizaje determinados, para lo cual se observó que existe variación en la intensidad del ruido en los diferentes horarios establecidos para la toma de mediciones.
- El desarrollo del sistema de predicción se logró utilizando técnicas de aprendizaje automático, logrando entrenar el algoritmo y así crear un modelo de predicción automática, el cual tiene diversas funciones; para ver los datos recopilados y almacenados; mostrando los valores en decibeles, generar gráficas para estudiar el comportamiento de los niveles de ruido y además, que el sistema predictivo permita el ingreso desde cualquier equipo.
- En relación a los registros recopilados de cada una de las mediciones realizadas en los diferentes ambientes de aprendizaje, y a su vez en la investigación realizada en este proyecto, se validó que el porcentaje aproximado tomando un valor promedio del nivel de presión sonora es de 60 db y 70 db, considerando estos valores podemos determinar que son ambientes que tienen poca afectación sonora pero que con el tiempo pueden tener efectos considerables.

- Es posible que en determinadas horas del día puedan existir niveles de sonido que superan el umbral permitido por la Organización mundial de la salud, el cual puede ser mitigado con elementos que atenúen el nivel de sonido como por ejemplo paredes con acústica adecuada ó paredes con material para aislar acústicamente.
- El sistema de medición acústica ha sido realizado de manera experimental en ambientes de aprendizaje, sin embargo su aplicación puede realizarse en cualquier otro ambiente, como por ejemplo ambientes laborales, empresas, hoteles, restaurantes, centros comerciales, centros turísticos, industria.
- Los sistemas de predicción open source aportan un desarrollo importante en la búsqueda de soluciones a problemas reales en ambientes reales.
- Las mediciones realizadas en el aula Lab1 confirman que, en ciertas condiciones, los niveles de ruido exceden el límite aceptable, lo que subraya la necesidad de implementar medidas correctivas.
- El modelo predictivo desarrollado, basado en machine learning, proporciona una herramienta confiable para anticipar los niveles de ruido y tomar decisiones informadas.
- Este estudio sienta las bases para investigaciones futuras, como la implementación de soluciones prácticas para mitigar el ruido y mejorar el bienestar en entornos educativos.

RECOMENDACIONES

- Es recomendable que todos los ambientes de aprendizaje deben realizar un estudio sobre el nivel de contaminación acústica al que se encuentra el personal que trabaja en el mismo como normativa de seguridad ocupacional
- Utilizar los sistemas predictivos en los diferentes ambientes sea de aprendizaje, trabajo en industria, lugares turísticos, hoteles, restaurantes.
- Es recomendable también que cada individuo que considera que está expuesto a niveles de sonido superior al que está permitido por la Organización Mundial de la salud se realice un examen de audiometría.
- Utilizar el menor tiempo posible sistemas de audio directo a los oídos, como audífonos debido al nivel de exposición al sonido alto en conexión directa a sus oídos.
- Las personas que por la naturaleza de trabajo estén expuestos a altos niveles de sonido y ruido deben utilizar de manera permanente mientras dura su horario laboral utilizar protectores auditivos para evitar complicaciones en su salud.
- La contaminación acústica debe ser considerada como un tema relevante de impacto en la salud de la ciudadanía.
- Se recomienda que se establezcan políticas de control de contaminación acústica en ambientes de aprendizaje en los centros de Educación Superior ,

media y básica para lograr una mejor concentración y mejor rendimiento por parte de los estudiantes

- La contaminación acústica debe ser política de seguridad ambiental en cada organización para evitar también niveles de estrés y posibles problemas de salud en su personal de trabajo.

REFERENCIAS BIBLIOGRÁFICAS

Referencias

- Noriega Linares, J., Rodriguez Mayol, A., Cobos, M., Segura García, J., Felici Castel, S., & Navarro, J. (2017). A Wireless Acoustic Array System for Binaural Loudness Evaluation in Cities. *IEEE SENSORS JOURNAL*, 17(21).
- Aguado Borrajom, P. (2006). Environmental contamination: Noise.
- Ahmed, A., Pradman, B., Chakraborty, S., & Alamri, A. (2021). Developing vehicular traffic noise prediction model through ensemble machine learning algorithms with GIS. *14*, 1- 14.
- Aisharman, S., Al - Khaleel, O., & Al - Ayyoub, M. (2024). A Detailed Inspection of Machine Learning Based Intrusion Detection Systems for Software Defined Networks. *5(4)*, 756 - 784. <https://doi.org/https://doi.org/10.3390/iot5040034>
- Alvarez, A. J., Méndez Martínez, J., Delgado Pérez, L., Acebo Figueroa, F., De Armas Mestre, & Rivero Llop, M. (2017). Contaminación ambiental por ruido. *Revista Médica Electrónica*.
- Anderson, D., & Aanonsen, L. (2024). A method for comparing candidate materials in subjective tests of flat-panel loudspeakers. *55(1)*. <https://doi.org/http://doi.org/10.1121/2.0001992>
- Arabadzhi, V. (2009). Algorithm for Active Suppression of Radiation and Acoustical Scattering Fields by Some Physical Bodies in Liquids. *2(1)*, 361 - 397. <https://doi.org/https://doi.org/10.3390/a2010361>
- Barcelona, U. d. (2022). *Psicología Ambiental, elementos básicos*. Efectos del ruido sobre el rendimiento: http://www.ub.edu/psicologia_ambiental/unidad-4-tema-9-4
- Bastos, D., Fernández - Caballero, A., Pereira, A., & Pacheco Rocha, N. (2022). Smart City Applications to Promote Citizen Participation in City Management and Governance: A Systematic Review. *9(4)*, 89. <https://doi.org/https://doi.org/10.3390/informatics9040089>
- Berg, R., & Stork, D. (2024). *The Physics of Sound*. Pearson.
- Bevilacqua, A., Lannace, G., Gomez Agustina, L., & Trematerra, A. (2024). Racing in Kart Dromes: Laboratory and Site Assessment of Noise Levels from Competition and Rental Karts. *6(4)*, 1180 - 1192. <https://doi.org/https://doi.org/10.3390/acoustics6040064>
- Bianco, M., Gerstoft, P., & Traer, J. (2019). Machine learning in acoustics: Theory and applications. *Acoustical Society of America*, 146(3590). <https://doi.org/10.1121/1.5133944>
- Blanford, T. (2024). Summary of “Things that go boom: high amplitude acoustic sources”. *54*.

- Blom, E., Varnemo, K., Dekhla, I., Schold, S., Anderson, M., Svenson, O., & Amorim, M. (2019). Continuous but not intermittent noise has a negative impact on mating success in a marine fish with paternal care. *Scientific reports*. (5494), 9.
- Bouni, M., Hssina, B., Douzi, K., & Douzi, S. (2024). Integrated IoT Approaches for Crop Recommendation and Yield-Prediction Using Machine-Learning. *5*(4), 634 - 649. <https://doi.org/https://doi.org/10.3390/iot5040028>
- Butler, B., Pedersen, K., Maekawa, C., Gee, K., Transtrum, M., James, M., & Salton, A. (2018). K-Means clustering of inputs to a geospatial model for optimizing acoustic data collection. *35*(055008). <https://doi.org/http://doi.org/10.1121/2.0001299>
- Chavez, A. (9 de Abril de 2020). *CAUSAS Y CONSECUENCIAS DE LA CONTAMINACIÓN ACÚSTICA*. Gowin: <https://gowin.com/blogs/blog-fundacion/causas-y-consecuencias-de-la-contaminacion-acustica>
- Chen, Y., Kang, T., Zheng, J., Wan, Y., Hang Sim, K., Chau, E., & Chau, K. (2020). A real-time wavelet-based algorithm for improving speech intelligibility. *42*(060009). <https://doi.org/http://doi.org/10.1121/2.0001407>
- Cheng, L., Dou, Y., Zhou, J., Wang, H., & Tao, L. (2023). Speaker-Independent Spectral Enhancement for Bone-Conducted Speech. *16*(3), 153. <https://doi.org/https://doi.org/10.3390/a16030153>
- Chengshi, Z., Meihuang, W., & Xiaodong, L. (2022). A deep learning solution to the marginal stability problems of acoustic feedback systems for hearing aids. *152*, pág. 3616. <https://doi.org/10.1121/10.0016589>
- Chin, C. S., Ji, X., Woo, W. L., Kwee, T. J., & Yang, W. (2017). Modified multiple generalized regression neural network models using fuzzy C-means with principal component analysis for noise prediction of offshore platform. *Springer*.
- Chin, C., Ji, X., Lok, W., Joo, K., & Yang, W. (2017). Modified multiple generalized regression neural network models using fuzzy C-means with principal component analysis for noise prediction of offshore platform. <https://doi.org/10.1007/s00521-017-3143-0>
- Ciaburro, G., & Lannace, G. (2020). Improving Smart Cities Safety Using Sound Events Detection Based on Deep Neural Network Algorithms. *7*(3), 23. <https://doi.org/https://doi.org/10.3390/informatics7030023>
- Ciaburro, G., Padmanabhan, S., Maleh, Y., & Puyana - Romero, V. (2023). Fan Fault Diagnosis Using Acoustic Emission and Deep Learning Methods. *10*(1), 24. <https://doi.org/https://doi.org/10.3390/informatics10010024>
- Cohen, I., & Berdugo, B. (2001). SSpeech enhancement for non-stationary noise environments. *Signal processing* 2001, 81, 699. 2403 - 2418.
- Craun, M., Blubaugh, F., & Gustafson, K. (2020). Features for diagnosis of contaminated hydrophone sign. *40*(055001). <https://doi.org/http://doi.org/10.1121/2.0001329>
- Cuzzocrea, A., Mumolo, E., & Grasso, G. (2020). An Effective and Efficient Genetic-Fuzzy Algorithm for Supporting Advanced Human-Machine Interfaces in Big Data Settings. *13*(1), 13. <https://doi.org/https://doi.org/10.3390/a13010013>

- De Esteban Alonso, A. (2003). Noise pollution and health.
- Digital Talent Agency. (2018). *Metodologías de Gestión de Proyectos*.
https://www.dtagency.tech/cursos/metodologias_gestion_proyectos/tema_1-ModeloWaterfall.pdf
- El Universo. (2020). <https://www.eluniverso.com/guayaquil/2020/10/30/nota/8033047/zonas-guayaquil-contaminacion-acustica-ruido/>. Contaminación acústica.
- EL UNIVERSO. (5 de Noviembre de 2020).
<https://www.eluniverso.com/guayaquil/2020/10/30/nota/8033047/zonas-guayaquil-contaminacion-acustica-ruido/>. El Universo:
<https://www.eluniverso.com/guayaquil/2020/10/30/nota/8033047/zonas-guayaquil-contaminacion-acustica-ruido/>
- Estrada Solarte, L., & Deyanira, L. (2017). *El ruido: definición, tipos y efectos por la exposición en ambiente laboral*. <https://digitk.areandina.edu.co/entities/publication/b3504dba-98c9-4f29-a1fe-31fcd61d8c62>.
- Evangelos, M., Dohmen, M., Kamp, I., & Hornikx, M. (2022). Noise Indicators Relating to Non-Auditory Health Effects in Children—A Systematic Literature Review.
- Fausett, L. (1993). *Fundamentals of Neural Networks: Architectures, Algorithms and applications*. Pearson.
- Fernandez Grande, E., Karakons Tantis, X., Caviedes - Nozal, D., & Gerstoff, P. (2023). Generative models for sound field reconstruction. *The Journal of the Acoustical Society of America*, 153, 1179 - 1190.
- Fernandez Grande, E., Karakonstantis Xenofon, & Caviedes Nozal, D. (2023). Generative models for sound field reconstruction. *Acoustical Society of America*, 153(1179).
<https://doi.org/10.1121/10.0016896>
- Figueroa Montaña, A., Orozco Medina, M., & Preciado Caballero, N. (2012). Noise levels in connection with learning and perception in elementary schools of Guadalajara.
- Fletcher, M., Jones, S., & White, P. (2018). Effects of very high-frequency sound and ultrasound on humans. Part I: Adverse. *Acoustical Society of America*.
<https://doi.org/10.1121/1.5063819>
- Gantier Limiñani, N. A., & Gareca Apaza, M. L. (2017). EFFICIENT LEARNING ENVIRONMENTS. 6(1).
- George Rusu, A., Paleologu, C., Benesty, J., & Ciochina, S. (2022). A Variable Step Size Normalized Least-Mean-Square Algorithm Based on Data Reuse. 15(4), 111.
<https://doi.org/https://doi.org/10.3390/a15040111>
- Géron, A. (2022). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*.
- Gheller, F., Spicciarelli, G., & Arfé, B. (2024). The Effects of Noise on Children's Cognitive Performance: A Systematic Review. 55.
- Ghosh, S., Dasgupta, A., & Swetapadma, A. (2019). A Study on Support Vector Machine Based linear and Nonlinear Pattern Classification.

- Grumiaux, P. A., Kitic, S., Girin, L., & Guerin, A. (2022). A survey of sound source localization with deep learning methods. *The Journal of the Acoustical Society of America*, *152*, págs. 107 - 151. <https://doi.org/10.1121/10.0011809>
- Halliday, D., Resnick, R., & Walker, J. (2013). *Fundamentals of Physics*.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical learning*.
- Jara, J., Giral, D., & Martinez, F. (2016). Implementation of algoritms baesd on Support Vector Machine (SVM) for electric System: Topic Refiew. págs. 149 - 170. <https://doi.org/10.14483/udistrital.jour.tecnura.2016.2.a11>
- Jokel, C., Yankaskas, K., & Robinete, M. (2019). Noise of military weapons, ground vehicles, planes and ships. *Acoustical Society of America*, *146*(3832). <https://doi.org/10.1121/1.5134069>
- Jokel, C., Yankaskas, K., & Robinette, M. (2019). Noise of military weapons, ground vehicles, planes and ships. *The Journal of the acoustical society of America* , *146*(3832-3838).
- Kothinki, S., Imoto, K., Chakrabarty, D., Sell, G., Watanabe, S., y Elhiali, M. (2019). . Joint acoustic and class inference for weakly supervised sound event detection.
- Kotthaus , J. (2023). An Acoustoelectric Approach to Neuron Function. *5*(3), 601 - 618. <https://doi.org/https://doi.org/10.3390/acoustics5030037>
- Kshirasagar, S., Guntoro, A., & Mayr, C. (2024). Impact of Sliding Window Variation and Neuronal Time Constants on Acoustic Anomaly Detection Using Recurrent Spiking Neural Networks in Automotive Environment. *17*(10), 440. <https://doi.org/https://doi.org/10.3390/a17100440>
- Kumru, Y., Tasdelen, A., & Koymen, H. (2024). Generation of very wideband chip signals for coded underwater applications using parametric array. *55*(055001). <https://doi.org/http://doi.org/10.1121/2.0001985>
- Lamilla, E., Sacarelo, C., Alvarez Alvarado, M., Pazmiño, A., & Iza, P. (2023). Optical Encoding Model Based on Orbital Angular Momentum. *Sensors MDPI*.
- Lombardi, L., Matarrese, G., & Marzocca, C. (2024). Influence of the Gain–Bandwidth of the Front-End Amplifier on the Performance of a QEPAS Sensor. *6*(1), 240 - 256. <https://doi.org/https://doi.org/10.3390/acoustics6010013>
- López Ballester, J., Pastor Aparicio, A., Felici Castell, S., Segura Garcia, J., & Cobos, M. (2020). Enabling Real-Time Computation of Psycho-Acoustic Parameters in Acoustic Sensors Using Convolutional Neural Networks. *IEEE Sensors Journal*, *20*(19).
- Lopez Ballester, J., Pastor Aparicio, A., Segura García, J., Felici Castell, S., & Cobos, M. (2019). Computation of Psycho-Acoustic Annoyance Using.
- Malloy, C. (2019). Study of timbral variation of tenor steelpan mallets through spectral analysis. *39*(035009). <https://doi.org/http://doi.org/10.1121/2.0001399>
- Marieb, E., & Hoehn, K. (2013). *Human Anatomy & Physiology*. Pearson.
- McCullagh, P., & Nelder, J. (1989). *Generalized Linear Models*.

- Mealings, K., Maggs, L., & Buchholz, J. (2023). The Effects of Classroom Acoustic Conditions on Teachers' Health and Well-Being: A Scoping Review. *67*(1), 346 - 367.
https://doi.org/https://doi.org/10.1044/2023_JSLHR-23-00256
- Minea, M., & Dumitrescu, C. (2023). Urban Traffic Noise Analysis Using UAV-Based Array of Microphones.
- Mobley, F., Wall, A., & Gallager, H. (2020). Curve-fit of spectral variations of noise in F-35A cockpit. *39*(045012). <https://doi.org/https://doi.org/10.1121/2.0001322>
- Moreau, D., Cazzolato, B., Zander, A., & Pettersen, C. (2008). A Review of Virtual Sensing Algorithms for Active Noise Contro. *1*(2), 69 - 99.
<https://doi.org/https://doi.org/10.3390/a1020069>
- Murphy, E., & King, E. A. (2022). *Environmental noise pollution*.
- Nayak, J., Naik, B., & Behera, H. (2015). A Comprehensive Survey on Support Vector Machine in Data Mining task Applications & Challenges. *International Journal of Database Theory and Application*, *8*. <https://doi.org/10.14257/ijdta.2015.9.1.18>
- Newman, M. H. (2023). *How the Fourier Transform Works*.
- Openheim, A., & Schaffer, R. (2010). *Discrete-Time Signal Processing*. Pearson.
- Organización Mundial de la Salud. (2021). <https://www.who.int/es>
- Paakonen, R., Vehvilainen, T., Jokitulpo, J., Niemi, O., Nenonen, S., & Vinha, J. (2015). Acoustics and new learning environment—A case study. *100*, 74-78.
- Páramo, P., & Burbano, A. (2021). El tercer maestro : la dimensión espacial del ambiente educativo y su influencia sobre el aprendizaje. *Universidad Pedagógica Nacional*, http://repositorio.pedagogica.edu.co/bitstream/handle/20.500.12209/12721/Repositorio_El%20tercer%20maestro.pdf?sequence=1&isAllowed=y.
- Pastor Aparicio, A., Segura García, J., López Ballester, J., Felici Castell, S., García Pineda, M., & Pérez Solano, J. (2019). Psycho-Acoustic Annoyance Implementation with Wireless Acoustic Sensor Networks for Monitoring in Smart Cities. *14*.
- Pedregosa, F., Varoquaux, G., Gramfort A, M., Thirion B, G., & Duchesnay, G. (2011). Scikit-Learn: Machine Learning in phyton. (12), 2825-2830.
- Peng, Y., Tsouvalas, A., & Stampoultzoglou, T. (2021). A fast computational model for near- and far-field noise prediction due to offshore pile. *149*, pág. 1772.
<https://doi.org/10.1121/10.0003752>
- Pettit, C., & Wilson, D. (2020). A physics-informed neural network for sound propagation in the atmospheric boundary layer. *42*(022002).
<https://doi.org/http://doi.org/10.1121/2.0001383>
- Philemon, R., Gael, L., Florent, B., Marie, P., Honguic, J., Zhang, S., . . . Philemon, R. (2020). Observation and assessment of acoustic contamination of electrophysiological brain signals during speech production and sound perception.
<https://doi.org/10.1088/1741-2552/abb25e>

- Pike, X., & Cheer, J. (20223). Dynamic neural network switching for active noise control of nonlinear systems . 52(055007). <https://doi.org/http://doi.org/10.1121/2.0001855>
- Pratico, G., Fedele, R., Naumov, V., & Sauer, T. (2020). Detection and Monitoring of Bottom-Up Cracks in Road Pavement Using a Machine-Learning Approach. 13(4), 81. <https://doi.org/https://doi.org/10.3390/a13040081>
- Proakis, J. G., & Manolakis, D. G. (1988). *Introduction to Digital Signal Processing*. Prentice Hall.
- Rahimi, M., Alghassi , A., Ahsan, M., & Haider, J. (2020). Deep Learning Model for Industrial Leakage Detection Using Acoustic Emission Signal. 7(4), 49. <https://doi.org/https://doi.org/10.3390/informatics7040049>
- Redgwell, R., Szewczak, J., Jones, G., & Parsons, S. (2009). Classification of Echolocation Calls from 14 Species of Bat by Support Vector Machines and Ensembles of Neural Networks. 2(3), 907 - 924. <https://doi.org/https://doi.org/10.3390/a2030907>
- Rojas Manrique, E. (2020). Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo. *Revista Ibérica de Sistemas e Tecnologías de Informação*, págs. 586-599.
- Rossing, T., & Fletcher, N. (2004). *Principles of Vibration and Sound*.
- Roussel , P., Legodais, G., Bocquelet, F., Palma, M., Honejje, J., Zhang, S., . . . Gehring, J. (2020). Observation and assessment of acoustic contamination of electrophysiological brain signals during speech production and sound perception.
- Sanchez Garcia, T., Sanchez Cortez, L., & Santos Jimenez, O. (2021). CONTAMINACIÓN SONORA Y PERCEPCIÓN DEL APRENDIZAJE. *Scientia*. <https://doi.org/10.31381/Scientia.v22i22.3584>
- Sarailidis, G., Wagener, T., & Pianosi, F. (2023). *Integrating scientific knowledge into machine learning using interactive decision trees* (Vol. 170). Computers & Geosciences. <https://doi.org/http://doi.org/10.1016/j.cageo.2022.105248>
- Schachar, E., Cohen, I., & Berdugo, B. (2023). Acoustic Echo Cancellation with the Normalized Sign-Error Least Mean Squares Algorithm and Deep Residual Echo Suppression. 16(3), 137. <https://doi.org/https://doi.org/10.3390/a16030137>
- Schiller, V., Klaus, S., Bilen, A., & Lanza, G. (2023). In-Process Monitoring of Hobbing Process Using an Acoustic Emission Sensor and Supervised Machine Learning. 16(4), 183. <https://doi.org/https://doi.org/10.3390/a16040183>
- Segura García , J., Navarro Ruiz, J., Pérez Solano, J., Montoya Belmonte, J., Felici Castel , S., Cobos, M., & Torres Granda, A. (2018). Spatio-Temporal Analysis of Urban Acoustic Environments with Binaural Psycho-Acoustical Considerations for IoT-Based Applications.
- Shield, B., & Dockrell, J. (2003). THE EFFECTS OF NOISE ON CHILDREN AT SCHOOL: A REVIEW.
- Shield, B., & Dockrell, J. (2008). The effects of environmental and classroom noise on the academic attainments of primary school children. 123, 133 - 144. <https://doi.org/https://doi.org/10.1121/1.2812596>

- Testas, A. (2023). *Decision Tree Regression with Pandas, Scikit-Learn, and PySpark*. In: *Distributed Machine Learning with PySpark*. Apress, Berkeley, CA.
- Tits, N., El Haddad, K., & Dutoit, T. (2021). Analysis and Assessment of Controllability of an Expressive Deep Learning-Based TTS System. *8*(4), 84.
<https://doi.org/https://doi.org/10.3390/informatics8040084>
- Tórtora, G. J., & Derrickson, B. H. (2012). *Principles of Anatomy & Physiology*. Wiley.
- Trouvain, J., Werner, R., & Mobius, B. (2020). An acoustic analysis of inbreath noises in read and spontaneous speech. . 789 - 793.
- Turov, A., Barkov, F., Konstantinov, Y., Korobko, D., Lopez Mercado, C., & Fotiadi, A. (2023). Activation Function Dynamic Averaging as a Technique for Nonlinear 2D Data Denoising in Distributed Acoustic Sensors. *16*(9), 440.
<https://doi.org/https://doi.org/10.3390/a16090440>
- Turov, A., Konstantinov, Y., Barkov, F., Korobko, D., Zolotovskii, I., Lopez Mercado, C., & Fotiadi, A. (2023). Enhancing the Distributed Acoustic Sensors' (DAS) Performance by the Simple Noise Reduction Algorithms Sequential Application. *16*(5), 217.
<https://doi.org/https://doi.org/10.3390/a16050217>
- Van Kamp, I., Gidlof Gunnarsson, A., & Persson Waye, K. (2013). The effects of noise disturbed sleep on children's health and cognitive development. *133*(3506).
<https://doi.org/http://doi.org/10.1121/1.4806243>
- Vaughn, A., & Christian, A. (2024). Individual response trends to Urban Air Mobility vehicle noise in a laboratory study. *54*. <https://doi.org/http://doi.org/10.1121/2.0001990>
- Wang, P., Tan, K., y Wang, D. (2019). . Bridging the gap between monaural speech enhancement and recognition with distortion-independent acoustic modeling. *IEEE ACM*.
- Xiao, X., & Huang, H. (2020). A Clustering Routing Algorithm Based on Improved Ant Colony Optimization Algorithms for Underwater Wireless Sensor Networks. *13*(10), 250.
<https://doi.org/https://doi.org/10.3390/a13100250>
- Zheng, R., Xu, X., Ye, Z., & Da, J. (2020). Robust sparse Bayesian learning for DOA estimation in impulsive noise environment. *171*, 107500.
- Zvarevashe, K., & Olugbara, O. (2020). Ensemble Learning of Hybrid Acoustic Features for Speech Emotion Recognition. *13*(3), 70.
<https://doi.org/https://doi.org/10.3390/a13030070>

ANEXOS

```
import matplotlib as mpl
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
import seaborn as sns
```

```
data=pd.read_excel("DATASET_TI_UG.xlsx")
data
```

Mediciones	LAB1_S1	LAB1_S2	LAB1_S3		
0	1	68.7	64.5	73.4	
1	2	69.6	67.2	65.0	
2	3	75.9	66.5	61.6	
3	4	65.4	70.3	63.4	
4	5	69.9	77.8	79.5	
...

Mediciones	LAB1_S1	LAB1_S2	LAB1_S3	
995	996	68.3	74.1	77.8
996	997	79.4	71.8	71.1
997	998	67.8	67.4	63.6
998	999	68.4	66.8	69.9
999	1000	67.2	68.0	82.5

1000 rows × 4 columns

```
data['LAB1_S1'].plot(x='MEDICIONES', y='DECIBELIOS',
figsize=(50,15), color='r')
```

```
data['LAB1_S2'].plot(x='MEDICIONES', y='DECIBELIOS',
figsize=(50,15), color='pink')
```

```
data['LAB1_S3'].plot(x='MEDICIONES', y='DECIBELIOS',
figsize=(50,15), color='y')
```

```
data.dtypes
```

0

Mediciones int64

LAB1_S1 float64

LAB1_S2 float64

LAB1_S3 float64

dtype: object

```
data['LAB1_S1'].plot(x='MEDICIONES', y='DECIBELIOS',  
figsize=(50,15))  
data['LAB1_S2'].plot(x='MEDICIONES', y='DECIBELIOS',  
figsize=(50,15))  
data['LAB1_S3'].plot(x='MEDICIONES', y='DECIBELIOS',  
figsize=(50,15))
```

```
data.head(3)
```

Mediciones	LAB1_S1	LAB1_S2	LAB1_S3		
0	1	68.7	64.5	73.4	
1	2	69.6	67.2	65.0	
2	3	75.9	66.5	61.6	

```
data.describe()
```

	Mediciones	LAB1_S1	LAB1_S2	LAB1_S3
count	1000.000000	1000.000000	1000.000000	1000.000000
mean	500.500000	68.35770	69.046900	69.89480
std	288.819436	3.51937	3.185291	4.22594
min	1.000000	61.30000	60.200000	60.70000
25%	250.750000	66.60000	67.700000	66.70000
50%	500.500000	67.60000	68.400000	69.80000
75%	750.250000	69.00000	69.500000	72.70000
max	1000.000000	104.70000	89.300000	85.40000

```
data.shape
```

```
(1000, 4)
```

```
#Una variable para predecir n semanas en el futuro
import numpy as np
prediction_semanas=3

data['Prediction']= data[['LAB1_S1']].shift(-prediction_semanas)
data['Prediction']= data[['LAB1_S2']].shift(-prediction_semanas)
```

```
data['Prediction'] = data[['LAB1_S3']].shift(-prediction_semanas) #  
Use LAB1_S3 for Prediction column
```

```
#crea un conjunto de datos independientes  
X = np.array(data.drop(['Prediction'], axis=1)) # Now this should  
work because 'Prediction' column exists.  
X = X[:len(data) - prediction_semanas]  
print(X)
```

```
[[ 1.  68.7  64.5  73.4]  
 [ 2.  69.6  67.2  65. ]  
 [ 3.  75.9  66.5  61.6]  
 ...  
 [995.  66.9  69.  65.9]  
 [996.  68.3  74.1  77.8]  
 [997.  79.4  71.8  71.1]]
```

```
Y=np.array(data['Prediction'])  
Y= Y[:-prediction_semanas]  
print (Y)
```

```
[63.4 79.5 70.4 69.5 69.6 65.2 63.3 70.9 75.  69.6 68.2 61.8 66.5  
76.6  
 67.4 71.2 64.5 62.9 69.5 74.  70.5 66.6 65.3 64.  60.7 63.  63.4  
64.6  
 63.5 73.5 67.7 61.7 68.4 72.2 71.4 69.  79.4 69.9 69.5 74.3 71.6  
76.6  
 78.4 68.3 76.6 67.3 68.2 65.5 64.8 71.9 77.7 69.9 73.7 69.7 65.9  
73.5  
 69.9 69.8 77.  72.6 71.9 63.  65.3 69.8 69.7 70.7 66.6 71.5 70.2  
67.9  
 70.1 72.7 69.3 63.9 69.7 68.1 65.  71.8 74.9 70.3 65.6 69.9 69.8  
72.6  
 64.4 73.1 70.  71.7 71.5 66.4 64.6 66.9 67.9 72.4 64.1 69.2 70.2  
73.1  
 67.  67.4 71.1 74.5 73.3 64.2 75.2 65.  72.4 71.4 68.4 67.7 76.4  
73.5  
 73.  72.2 67.9 76.1 69.3 72.9 70.3 77.4 76.7 69.5 76.3 72.  69.1  
66.6
```

70.2 75. 68.2 70.2 66. 76.9 68.5 63. 74.3 66.2 77.8 61.8 68.2
 67.8
 64.8 72.1 68.2 76.1 74.1 66.1 74.3 68.2 71.4 76. 75.5 72.9 68.6
 67.9
 77.8 75.4 65.4 66.1 71.1 77.8 76.5 72. 66.5 75.4 70.5 74.7 66.3
 73.5
 68.3 63.9 70.5 68.8 64.7 66.9 69.6 70.5 69.8 68.5 62.5 71.7 70.2
 74.5
 66.6 70.5 70.3 79.5 71. 72.2 72.5 62.6 69. 72.4 68.9 71.7 72.
 65.9
 80.1 67. 69.5 72.2 71.3 75. 67.2 69.9 63.7 64.3 76.7 63.5 75.2
 71.5
 71.9 71.1 72.7 74.3 78.6 63.8 69.2 70.9 69.3 74.5 66.5 85.4 77.3
 73.6
 78.4 74.1 73.1 71.9 71.5 65.2 75.7 65.6 74.2 69.7 70.3 77.6 69.8
 74.9
 75.1 66.9 70.4 67. 64. 76.7 64.6 73. 70. 73.6 65.7 64.2 74.2
 68.4
 73.4 68.3 75.2 70.5 66.4 74.6 64.7 64.9 67.2 69.7 73.4 76.6 66.1
 76.7
 77.9 62.9 72.3 76. 63.4 62.2 65.3 61.4 63.1 63.7 71.6 77.2 65.9
 69.4
 70.9 64.4 70.3 70.1 75.7 71.7 69.3 83.9 72.9 67.6 64.7 72.8 71.7
 67.4
 79.3 68.6 68. 68.4 69.7 72. 65.7 78.7 66.9 68.9 69.4 70.2 63.6
 67.3
 69.8 66.4 74.7 72.3 64.6 63.1 70.5 73.1 72.1 68.2 67.3 66.6 64.1
 83.1
 70.2 71.2 66. 73.6 69.9 65.6 68.2 67.1 69.1 74.6 62.2 76.8 68.6
 69.4
 76.9 70.4 73.9 66.7 74.5 70.6 74.4 76.2 74.1 66.8 72.7 68.7 73.6
 67.9
 64. 79.3 62.7 74.2 68.8 73.2 76.6 73.3 79. 69.8 69.7 74.1 75.2
 70.4
 63.4 72.8 72.4 69.9 66.2 72.7 62.9 69.4 71.5 80.3 68.8 67.9 69.9
 63.9
 67.5 80.8 65.4 77.7 74.2 75.6 70.8 68.6 67. 67.7 71.3 61.5 72.8
 63.8
 71.8 64.1 68.8 64.6 74.2 64.4 65.1 65.9 73.4 71.2 67.4 66.8 63.3
 63.9
 69.5 75.4 65.7 77. 65.2 64. 66.6 65.1 77.6 69. 71.4 67.1 71.1
 67.5
 65.1 73.3 77.4 76.2 70.6 69.4 63.6 72.7 73.5 69.9 71.5 64.9 73.6
 63.9
 72.2 73.3 69.1 70.3 69.9 73.2 63.9 76. 63. 62.6 63.5 70.1 73.6
 75.
 71.3 64.3 63.9 65.9 70.1 75. 69.6 72.5 66.3 73.5 77.8 65.7 75.7
 77.4
 72. 69.9 69. 71.3 79.2 69.9 72.2 69.8 62.6 69.7 73. 69.4 66.7
 80.5
 74.1 71.7 69.7 72.1 67. 72. 74.1 69.6 66.6 61.8 77.3 66.1 72.9
 72.9
 69.7 65.3 69.7 63.3 76.1 74.3 65.1 64.2 70.2 69.4 69.5 63.5 69.
 63.2
 75.3 64.4 69.3 69.9 69.8 66.5 67.5 68.4 64.4 70.7 73.7 67.7 68.5
 69.9
 69.7 68.2 71.2 66.3 65.3 64.2 74.1 67.7 74.1 73.5 70.5 69.9 69.8
 72.5

77.5 69.8 75. 68.6 72.7 71.5 64. 74.8 71.9 65.4 70.5 75. 70.2
 68.1
 66.1 77.7 69.5 68.8 69.8 65. 66.9 68.7 70.9 71.5 66.6 73.7 67.5
 69.7
 66. 76.1 67.5 64.4 69.9 68. 64.8 74.5 69. 65. 65.3 72.3 82.2
 71.7
 66.5 72.8 65.1 66.5 72.8 69.7 66.3 77.4 73. 63.4 68.7 74.2 73.2
 71.3
 70.8 66.9 71.8 66.5 69.9 73.7 70. 64.4 67.6 67.6 65. 69.6 67.5
 77.4
 66.6 73.3 77.2 75.1 64. 64.5 71.1 66. 64.3 70.9 73.4 67.7 67.2
 64.9
 69.3 80.9 68.5 67.7 65. 74.5 66.2 69.8 69.7 69.7 70.2 76.3 69.8
 72.
 75.9 70.3 68.1 72.8 69.8 68.2 70.9 74. 62.6 69. 71.3 72.9 62.9
 65.8
 63.8 65. 71.7 63.1 76.3 66.7 69.4 70.4 74.9 71.9 74.2 70.6 63.7
 76.4
 66.7 68.6 66.3 71.2 70.1 64.1 75.3 68.5 64.8 73.2 71.2 63.2 74.1
 68.1
 69.8 63. 66.7 69.1 66.6 73.7 70.3 70.2 69.4 70.5 64.1 69.5 67.6
 72.9
 77.4 64.4 73.1 71.8 63.5 76.1 69.4 71.3 74.8 65. 71.6 64.7 68.8
 63.3
 66.7 70.2 64.8 73.9 69.7 66.4 65.5 64.2 65.7 67.1 71.4 71.8 65.2
 71.5
 62.7 74.9 71.9 73.1 70.8 71.2 64.3 70.7 71.7 71.6 70.9 66.1 65.9
 75.1
 74.9 68.9 70.5 67.5 69.9 71.5 68.9 64.4 65.5 66.2 68.3 74.5 69.9
 68.8
 66.8 74.5 65.7 66.5 69.5 67.2 68.9 69.3 71.5 73. 67.6 67.2 74.2
 78.3
 72. 72.6 67.5 68.3 76.9 71.8 73.6 75.3 67.5 65.8 71.1 71.9 66.9
 83.3
 76.1 71.7 70. 66.3 69.7 65.1 76.2 69.2 65.6 68. 63.4 71.4 64.9
 78.
 76.7 68.6 64.4 68.1 70.9 66.8 65.4 64.1 66.3 80.8 82.6 75.4 64.9
 70.8
 76.9 67.7 70.7 66.5 79.5 68.3 68.2 66.1 69.9 69.9 69.6 71.7 65.
 72.3
 68.4 75.1 67.3 70.5 67. 78.3 76.8 68.1 65.3 70.5 70.9 69.6 72.3
 71.
 70.5 75.2 64.7 68.7 76.8 73.7 74.7 69.1 69.1 67.9 69. 72.6 74.8
 73.
 72. 70.1 66.9 72.6 62.8 62.6 71.8 64.5 74.3 69.8 76.2 72.6 70.2
 66.8
 64.1 64.3 69.1 67.7 67.6 69. 70.1 68.7 72.9 72.4 63.5 80.8 71.9
 72.5
 67.7 66.8 76.6 74.8 70.7 68.8 67.1 67. 65.5 74.6 65.4 70.1 70.7
 68.8
 65.1 65.7 67.7 67.4 75.4 68. 70.3 70.5 71.1 66.1 67.9 64.9 66.1
 63.2
 70.8 68.5 66.6 71.3 68.7 67.7 68.5 69.3 73.8 63.7 70.5 67.3 71.5
 79.6
 69.8 64.4 63.6 66.9 65. 68.8 65.4 72.7 65.7 65.5 75.3 70.6 70.8
 68.6
 67.4 78.1 67.9 70.5 69. 65.3 65.5 62.4 71.1 70.5 71. 71.9 70.5
 67.6


```
74.9 73.5 72.2 73.2 66.9 69.6 66.1 68.5 70.8 67.7 68.5 69.4 67.2
72.7
71.6 78.1 69.9 65. 73.7 70. 67.8 65.7 71.6 65.7 70.3 71. 64.3
64.7
67.1 76.1 69.8 67.9 70. 68.7 63.2 66.7 68.3 64.6 72.2 68.4 64.8
66.1
74.3 72. 65.5 68.5 67.9 67.6 77.7 70.7 73.3 68.4 67.3 65.9 77.8
71.1
63.6 69.9 82.5]
```

```
from sklearn.model_selection import train_test_split
X_train, X_test, Y_train, Y_test =
train_test_split(X,Y,test_size=0.2)
```

```
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.svm import SVR

# Split data into training and testing sets
X_train, X_test, Y_train, Y_test = train_test_split(X, Y,
test_size=0.2)

# Create and train the Support Vector Regression model
svr_rbf = SVR(kernel='rbf', C=1e3, gamma=0.00001)
svr_rbf.fit(X_train, Y_train)
```



```
prediction_semanas_array = np.array(data.drop(['Prediction'],
axis=1))[:-prediction_semanas:]
```

```
print(prediction_semanas_array)
```

```
[[ 998.    67.8   67.4   63.6]
 [ 999.    68.4   66.8   69.9]
 [1000.    67.2   68.    82.5]]
```

```
#modelo de prueba
svr_rbf_confidence= svr_rbf.score(X_test, Y_test)
print('svr_rbf accuracy: ', svr_rbf_confidence)
```

```
svr_rbf accuracy: -0.014246833335805897
```

```
#imprime valor predicho
svm_prediction= svr_rbf.predict(X_test)
print(svm_prediction)
print()
#imprime valores reales
print(Y_test)
```

```
[69.81646989 69.7965728 71.9875613 70.41535441 68.38611753
70.66141086
69.87838607 70.19899313 69.79023239 69.04716955 69.38691546
69.23870075
69.23249238 70.0678368 68.89023236 68.56193562 69.55043014
69.58349548
```

69.22336358 70.02379712 69.51627776 68.19230801 69.67094118
69.76498151
69.64388969 68.34092258 69.1209065 70.34228482 69.04399304
69.6862427
68.97268586 70.13853591 71.34458342 69.87396153 69.47053098
69.51309877
70.2109698 69.61979758 70.43815525 68.8756308 68.36495338
69.59481896
69.0924286 69.59017337 70.56247037 69.76304784 69.71382225
70.1895965
70.16626892 69.71914935 70.44695005 69.76818177 71.26933971
69.31740057
69.56064726 69.92054915 69.47083491 70.14022198 69.11160146
69.65160494
70.1466095 69.86905192 70.21025087 68.57207556 69.70916936
69.54427891
70.42054586 69.36219198 69.94680988 69.66859702 69.52982989
70.2571885
69.91417789 69.47433444 69.46604693 69.79998268 69.79484559
68.34515283
68.41802124 69.60248818 69.8391309 69.82916463 69.61031017
70.17349539
70.98667754 70.50210482 69.79892229 69.604482 69.56311843
69.40837723
69.39842894 68.56999723 69.76001676 69.61820344 70.22694073
69.75737832
70.13045123 69.43094206 71.00577666 69.4907271 69.89337543
68.85379522
69.7311098 68.18662652 68.30331069 70.47503735 70.24558409
70.16538665
68.70552791 70.21950354 70.77421946 69.78270772 70.30686875
69.65626926
73.52741993 69.7206613 69.58817955 69.6657871 69.33346121
68.83346697
69.77311309 70.3198931 70.18093191 69.15713454 68.76717369
69.76434744
71.60527311 70.61103445 69.41485849 69.359898 71.96906274
69.92349222
70.69937476 70.37103935 69.73978655 68.16051109 70.14009628
69.45024514
70.2671128 69.28362611 69.39108021 69.92969186 68.60254608
69.33708397
70.00473461 69.0319571 70.38885579 70.07444569 70.16325765
69.61381986
69.41790646 71.84037163 69.87289316 69.47479964 69.13712262
71.11466317
70.12768473 69.12331991 69.1551465 69.12124634 69.81854148
70.02617706
70.06924106 69.47792698 70.01261853 69.80539294 69.7106437
68.14171979
70.2214095 68.92812707 69.19252112 69.39688458 70.27494004
69.95008981
69.66468492 69.95301121 69.74517849 68.27093729 69.5199228
70.4961241
69.81696518 70.10750122 69.67380505 69.82260866 70.08774454
70.07793845
70.22834015 71.13704131 68.52547575 70.11130564 69.74512614
69.95521275

```

69.57169185 69.65740643 69.49702042 69.53940745 69.65184593
69.74543349
69.44290842 68.36252728]

[73.3 76.2 69.8 72.7 63.9 71. 69.7 68.6 68.9 64.3 68.7 69.1 66.7
67.6
68.4 76.6 69.3 70.9 71.1 71.6 68.4 68.4 75.3 66.8 68.1 69. 69.8
63.6
71.8 71.2 76.9 77.8 75.2 67.9 66. 66.4 70.3 76.9 74.7 76.4 66.9
68.5
66.5 68.8 65.2 80.5 70.9 70.3 63.7 63.3 72. 66.9 66. 70.1 71.7
69.5
75.1 77.6 79.4 66.9 63.8 72.2 71.7 66.7 65.6 69. 71.5 67.9 70.2
67.5
71.5 66.4 70.9 70.1 69.7 72.8 73.5 63. 63.4 76.1 68.7 66.7 67.6
69.4
72.4 70.5 66.7 71.9 74.2 71.9 71.1 65.5 62.6 67.8 77.4 75. 72.
76.1
63. 68.3 71.7 71.9 73.5 69.6 76.6 69.8 76.7 75. 70.7 75.2 64.3
69.9
64.9 64.7 70.9 74.1 63.8 71.3 70.8 74. 72.7 66.6 63.5 63.2 70.8
73.4
74.3 74.1 68.4 68. 69.3 76.2 77.8 71.7 72.9 66.5 75.7 70.5 70.3
76.7
75.3 69.4 74.3 66.3 77.6 63.6 69.7 70.1 63.6 73.3 68.8 73. 73.9
71.7
72.4 71.1 68.5 71.1 77.7 65.6 77.7 72.3 70.5 74.1 69.3 67. 62.9
69.
72.9 68.3 70.3 70.5 69.8 66.1 67.2 69.9 78.3 64.4 64.3 67. 75.
75.4
70.7 68.6 69.9 72.1 69.1 72.9 73.5 67.3 67.6 62.6 67.7 71.1 65.8
65.
66.5 73.3 68.4 69.6]

```

```

svm_prediction= svr_rbf.predict(prediction_semanas_array)
print(svm_prediction)

data.tail(prediction_semanas)

```

```
[69.28657377 68.94864085 67.99559109]
```

```

#muestra las primeras tres filas
data.head(3)

```

Mediciones	LAB1_S1	LAB1_S2	LAB1_S3	Prediction	
0	1	68.7	64.5	73.4	63.4
1	2	69.6	67.2	65.0	79.5
2	3	75.9	66.5	61.6	70.4