

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

Facultad de Ingeniería en Electricidad y Computación

Determinación del estado de falla de motores eléctricos a partir del análisis de ruidos utilizando técnicas de Aprendizaje Profundo

PROYECTO INTEGRADOR

Previo la obtención del Título de:

Ingeniero/a en Ciencias de la Computación

Presentado por:

Josué Eulises Dávalos Carrera

Joan Paulette Vázquez Matute

GUAYAQUIL - ECUADOR

Año: 2022

DEDICATORIA

El presente proyecto lo dedico a mi abuela Zoila Cruz por ser mi principal fuente de motivación y ejemplo para perseverar y lograr mis metas. Por todo su apoyo, consejos, amor y acompañamiento incondicional durante mi formación académica. Además de ser mi pilar fundamental durante mi crecimiento tanto personal como profesional.

Josué Dávalos

DEDICATORIA

Dedico este proyecto a Dios y a mis padres, por ser mi soporte, guía y ejemplo siempre. En especial a mi madre, por su infinito apoyo y consejos que han permitido mantenerme firme en mis propósitos y objetivos.

Paulette Vázquez

AGRADECIMIENTOS

Agradezco a Dios por otorgarnos salud y vida. Brindo mi sincero agradecimiento a los profesores y tutor por su pasión al compartir sus conocimientos y ser guías durante mi proceso de aprendizaje, los cuales permitieron que este proyecto sea posible.

Agradezco especialmente a Paulette Vázquez por brindarme su apoyo desde inicios de mi formación académica, sin duda marco una gran diferencia sobre las habilidades que adquirí y mejoré; sin ella, la versión profesional que soy ahora no hubiese sido posible.

También agradezco a mi mejor amiga Milena Cajape por su aliento, motivación e impulsos durante los momentos difíciles.

Finalmente agradezco a mi familia y amigos que me impulsaron y brindaron su apoyo durante mi formación.

Josué Dávalos

AGRADECIMIENTOS

Agradezco a Dios y a la Virgen por ser mi fortaleza en tiempos de alegría y de adversidad, por enseñarme a ser paciente, perseverante y a hacer todo con amor infinito.

Agradezco de forma especial a la Dra. Carmen Vaca, quien despertó en mí la pasión por la Computación. Gracias por ser mi guía profesional y espiritual todos estos años.

Agradezco a mi compañero de tesis y gran amigo, Josué Dávalos. A quien conocí en primer semestre y con el que compartí grandes experiencias. Gracias por haber sido uno de mis principales apoyos en la universidad.

Agradezco a mis amigos de TAWS, mi segunda familia, por ser mis consejeros de carrera y de vida, ayudándome a cursar los caminos inciertos y emocionantes de la universidad.

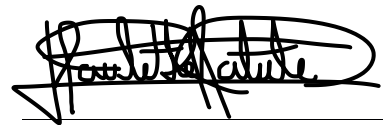
Finalmente, agradezco a todos mis profesores, mi tutor y autoridades de ESPOL, que estuvieron apoyándome en todo momento, haciendo que este proyecto sea posible.

Paulette Vázquez

DECLARACIÓN EXPRESA

“Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; **Josué Eulises Dávalos Carrera y Joan Paulette Vázquez Matute**, y damos nuestro consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”

Josué Dávalos Carrera



Paulette Vázquez Matute

EVALUADORES

.....
MG. Ronald Criollo

PROFESOR DE LA MATERIA

.....
Enrique Peláez Jarrín Ph.D.

PROFESOR TUTOR

RESUMEN

En la industria periódicamente se llevan a cabo rutinas de inspección de la maquinaria para el mantenimiento preventivo. Estas rutinas son efectuadas a través de revisiones programadas que están cuidadosamente diseñadas para identificar posibles problemas y pronosticar las necesidades de mantenimiento necesarias.

Para el mantenimiento predictivo generalmente se usa el registro de vibraciones de los equipos mediante acelerómetros y el análisis en frecuencia de esas señales. Sin embargo, el grado de falla de un equipo se correlaciona fuertemente con el incremento del ruido que la maquina produce. Por tanto, combinar las mediciones de vibración e intensidad de ruido de un equipo utilizando algoritmos de Inteligencia Artificial nos permite obtener resultados más robustos en el diagnóstico de fallas en motores.

El método desarrollado en este trabajo busca el diagnóstico oportuno de fallas en motores eléctricos a través de la identificación de patrones en señales de audio y vibraciones utilizando modelos de Aprendizaje Profundo. Primero, se creó un módulo de preprocesamiento para convertir las señales en imágenes y aumentar los ejemplos de la clase minoritaria. Luego, se creó un módulo de clasificación de imágenes en el que se realizaron distintos experimentos con las arquitecturas VGG19 y ResNet50, además de la arquitectura tipo ensemble y una red neuronal completamente conectada.

Finalmente, el resultado de la clasificación comprobó que el usar datos multimodales en conjunto permiten un diagnóstico eficaz de fallas en motores eléctricos. Se logró una exactitud del 93.02%, empleando dos modelos CNN (uno para cada tipo de señal) con arquitectura tipo ensemble. Por lo tanto, el modelo propuesto resulta eficiente y preciso al momento de diagnosticar el estado de falla de un motor eléctrico, sin necesidad de sensores dedicados a cada motor, sin necesidad de personal especializado y sin detener la actividad productiva de la industria.

Palabras Clave: Anomalías, Mantenimiento Predictivo, Espectrogramas, Ensemble.

ABSTRACT

In the industry, routine inspections of machinery are carried out periodically for preventive maintenance. These routines are carried out through scheduled checks that are carefully designed to identify potential problems and forecast necessary maintenance needs.

For predictive maintenance, equipment vibration recording is generally used by means of accelerometers and the frequency analysis of these signals. However, the level of equipment failure correlates strongly with the increase in noise that the machine produces. Therefore, combining the vibration and noise intensity measurements using artificial intelligence algorithms allows us to obtain more robust results in the diagnosis of engine failures.

The method developed in this work seeks the timely diagnosis of faults in electric motors through the identification of patterns in audio signals and vibrations using Deep Learning models. First, a preprocessing module was created to convert the signals into images and augment the examples of the minority class. Then, an image classification module was created in which different experiments were carried out with the VGG19 and ResNet50 architectures, in addition to the ensemble architecture and a fully connected neural network.

Finally, the result of the classification proved that using multimodal data together allows an effective diagnosis of faults in electric motors. An accuracy of 93.02% was achieved, using two CNN models (one for each type of signal) with ensemble architecture. Therefore, the proposed model is efficient and accurate when diagnosing the failure status of an electric motor, without the need for sensors dedicated to each motor, without the need for specialized personnel and without stopping the productive activity of the industry.

Keywords: *Anomalous, Predictive Maintenance, Spectrograms, Ensemble.*

ÍNDICE GENERAL

RESUMEN	8
ABSTRACT	9
ABREVIATURAS	12
ÍNDICE DE FIGURAS	13
ÍNDICE DE TABLAS	14
CAPÍTULO 1	15
1. Introducción	15
1.1 Descripción del problema	15
1.2 Justificación del problema	16
1.3 Objetivos	16
1.3.1 Objetivo General	16
1.3.2 Objetivos Específicos	16
1.4 Marco teórico	17
1.4.1 Implicaciones de una rutina de inspección de maquinaria	17
1.4.2 ¿Cuándo se debe realizar una inspección de maquinaria?	19
1.4.3 Beneficios de la inspección de maquinarias	19
1.4.4 Aprendizaje Profundo como herramienta para la inspección de maquinarias	19
CAPÍTULO 2	21
2. Metodología	21
2.1 Análisis	22
2.1.1 Requerimientos	22
2.1.2 Alcance y limitaciones de la solución	24
2.1.3 Riesgos y beneficios de la solución	25
2.1.4 Usuarios de la solución	25
2.2 Prototipado	26
2.2.1 Dataset	26
2.2.2 Módulo de Pre-procesamiento	26
2.2.3 Modelos de Predicción	28
2.3 Diseño de la solución	29
2.3.1 Diagrama de despliegue	29

2.4	Software	30
2.4.1	Arquitectura	30
2.4.2	Diagramas	31
2.4.3	Prototipo	32
CAPÍTULO 3.....		36
3.	RESULTADOS Y ANÁLISIS.....	36
3.1	Modelo de Clasificación	36
3.1.1	Particionamiento de los datos	36
3.1.2	Entrenamiento y Validación.....	37
	38
3.1.3	Prueba	38
	39
3.1.4	Discusión	39
CAPÍTULO 4.....		40
4.	Conclusiones y recomendaciones.....	40
4.1.1	Conclusiones	40
4.1.2	Recomendaciones y Trabajo Futuro	40
BIBLIOGRAFÍA		42
APÉNDICES.....		44
APÉNDICE A		44
APÉNDICE B.....		45
APÉNDICE C.....		49

ABREVIATURAS

AE	Auto Encoders
AI	Artificial Intelligence
AUC	Area Under the Curve
CNN	Convolutional Neural Network
CSV	Comma Separated Values
MLP	Multilayer Perceptron
ResNet	Residual Network
VGG	Very Deep Convolutional Networks
WAV	Waveform Audio Format

ÍNDICE DE FIGURAS

Figura 1.1: Rutina de inspección de maquinaria [7]	18
Figura 2.1. Etapas del pre-procesamiento de las grabaciones de sonidos y vibraciones [autoría propia].....	27
Figura 2.2. Resultado del preprocesamiento de las señales de vibraciones [autoría propia]	28
Figura 2.3: Framework del Modelo [autoría propia].....	29
Figura 2.4: Diagrama de despliegue [autoría propia]	30
Figura 2.5: Diagrama de arquitectura [autoría propia]	31
Figura 2.6: Diagrama de Casos de Uso de la calificación del estado de falla de un motor [autoría propia].....	32
Figura 2.7. Página principal [autoría propia].....	33
Figura 2.8. Carga de datos necesarios para la predicción [autoría propia].....	33
Figura 2.9. Visualización de los detalles de la predicción, sección sonido [autoría propia]	34
Figura 2.10. Visualización de los detalles de la predicción, sección vibraciones [autoría propia]	34
Figura 2.11. Detalles de predicción [autoría propia].....	35
Figura 3.1: Métrica de pérdida del modelo [autoría propia]	37
Figura 3.2: Métrica de precisión del modelo [autoría propia].....	37
Figura 3.3: Métrica de área bajo la curva del modelo [autoría propia]	38
Figura 3.4: Comparativa de resultados del modelo final vs. modelos de prueba [autoría propia]	39

ÍNDICE DE TABLAS

Tabla 2.1. Detalles de los datos de motores capturados [autoría propia] 26

CAPÍTULO 1

1. INTRODUCCIÓN

1.1 Descripción del problema

El mantenimiento de equipos y maquinaria es fundamental para mantener operativa una industria y garantizar la calidad de sus productos. Los tipos de mantenimientos más practicados son: mantenimiento correctivo, mantenimiento preventivo y mantenimiento predictivo [1].

El mantenimiento correctivo se realiza tras la detección de un fallo o anomalía en la maquinaria y tiene como objetivo restablecer las condiciones normales de funcionamiento. Este mantenimiento puede ser rentable hasta que ocurran fallas catastróficas [2]. El mantenimiento preventivo se lleva a cabo a intervalos predeterminados o de acuerdo con criterios prescritos, con el objetivo de reducir el riesgo de falla [2]. Finalmente, el mantenimiento predictivo hace uso de análisis de datos obtenidos de sensores para hacer predicciones sobre futuras fallas [3].

Para el mantenimiento predictivo generalmente se usa el registro de vibraciones de los equipos mediante acelerómetros y el análisis en frecuencia de esas señales [4]. Por otro lado, es de conocimiento general que el grado de falla de un equipo correlaciona con el incremento del ruido que este produce. Por tanto, el análisis de la intensidad de ruido de un equipo o una maquinaria podría también ser un método efectivo para el mantenimiento predictivo.

Sin embargo, son muy escasos los trabajos realizados en esa línea [5]. Actualmente, el desarrollo de los métodos de clasificación de datos usando Inteligencia Artificial nos brinda la oportunidad de descubrir nuevos y económicas técnicas de diagnóstico de fallas de equipos industriales, que podrían abaratar costos de mantenimiento predictivo [6].

Por ello, explorar el uso de Inteligencia Artificial para obtener un diagnóstico oportuno de una potencial falla es esencial para otorgar un mantenimiento temprano y mejorar la operación de la maquinaria.

1.2 Justificación del problema

El monitoreo de equipos en un entorno de trabajo para la detección de anomalías, sin emplear sensores dedicados a cada máquina, es esencial para el mantenimiento predictivo y no detener la actividad productiva; por lo tanto, es importante proveer a las empresas, en particular aquellas con bajos niveles de automatización, herramientas que faciliten la detección oportuna de fallas.

Además, la posibilidad de identificar condiciones de operación de equipos o maquinaria, sin importar las condiciones del entorno de trabajo. Los métodos actuales consisten en el monitoreo de cada equipo con herramientas especializadas, lo cual incrementa los costos de mantenimiento. El análisis de ruido puede brindarnos una perspectiva no direccional, de bajo costo y que podría implementarse mediante una aplicación en un teléfono móvil.

1.3 Objetivos

1.3.1 Objetivo General

Construir una herramienta de diagnóstico del estado de falla de un motor a partir del análisis de ondas sonoras y vibraciones, utilizando técnicas de Aprendizaje Profundo.

1.3.2 Objetivos Específicos

1. Desarrollar una aplicación móvil que permita capturar y almacenar los sonidos y las vibraciones de motores eléctricos en operación.
2. Desarrollar un soporte para dispositivos móviles que facilite la captura de los datos.
3. Preprocesar y extraer las características de los datos capturados desde los motores.
4. Diseñar un modelo de clasificación de los sonidos y las vibraciones, utilizando técnicas de aprendizaje profundo.

1.4 Marco teórico

En la industria periódicamente se llevan a cabo rutinas de inspección de la maquinaria. Estas rutinas son efectuadas a través de revisiones programadas que están cuidadosamente diseñadas para identificar posibles problemas y pronosticar las necesidades de mantenimiento necesarias [4]. Al medir el estado de la máquina a intervalos regulares, la instalación puede abordar problemas potenciales más rápidamente, reducir los eventos de mantenimiento no planificados y planificar de manera más efectiva las necesidades de inventario.

Ignorar la importancia de las inspecciones de maquinaria puede tener varias consecuencias negativas. Estos pueden incluir:

- Mayor tiempo de inactividad no planificado
- Reducción de la vida útil de los equipos.
- Costos excesivos para reparaciones de emergencia y repuestos
- Operación ineficiente e insegura del equipo

1.4.1 Implicaciones de una rutina de inspección de maquinaria

Las inspecciones pueden comprender una variedad de tareas para equipos, instalaciones y aplicaciones.

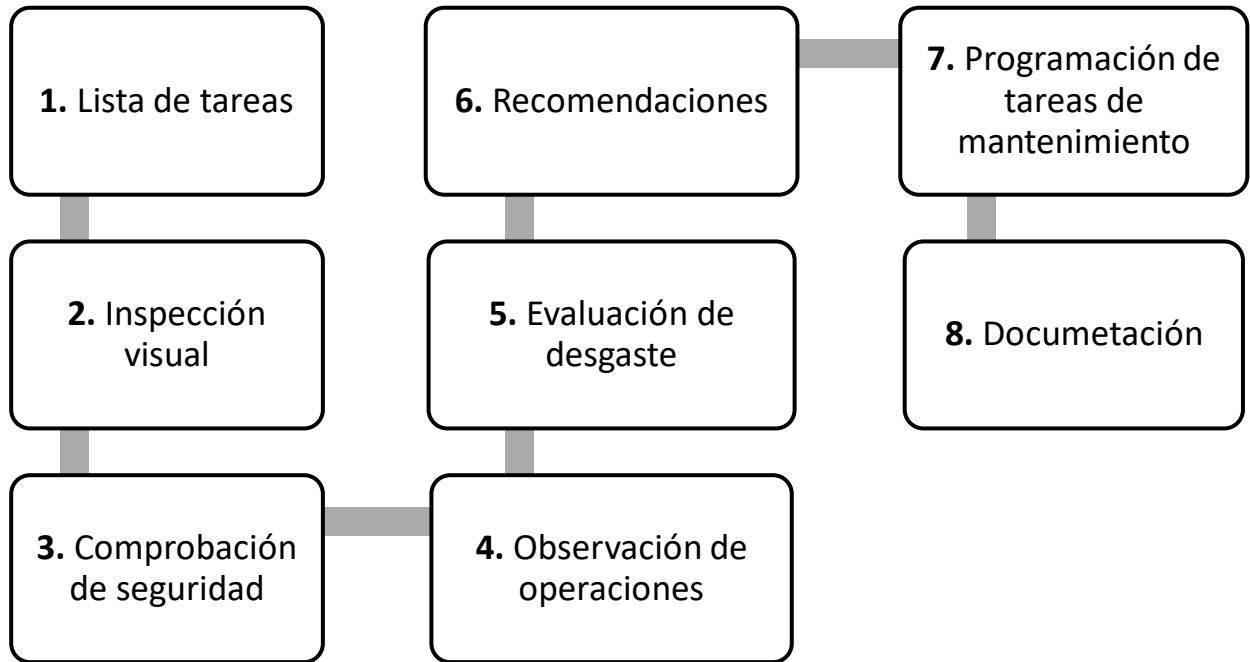


Figura 1.1: Rutina de inspección de maquinaria [7]

En general, una inspección de equipo básico debe incluir los pasos representados en la Figura 1.1, los cuales se detallan a continuación:

1. Una lista de tareas o una lista de verificación basada en una estrategia o intención definida para la inspección.
2. Una inspección visual general de la funcionalidad y los componentes de la máquina.
3. Una comprobación de seguridad, incluidas las funcionalidades a prueba de fallos.
4. Observación de operaciones.
5. Evaluación del desgaste.
6. Recomendaciones para pasos de mantenimiento a corto, mediano y largo plazo para abordar las necesidades identificadas durante la inspección.
7. Programación de cualquier tarea de mantenimiento inmediato reconocida durante la inspección.
8. Documentación, incluido un resumen de inspección y un informe.

1.4.2 ¿Cuándo se debe realizar una inspección de maquinaria?

Las inspecciones exhaustivas de los equipos deben realizarse al menos una vez al año [4]. En la mayoría de los casos, una inspección dos veces al año producirá beneficios de mantenimiento tangibles que pueden justificar el costo del proceso y personal experto [4]. Como se mencionó anteriormente, las inspecciones del estado de la máquina no deben considerarse lo mismo que las tareas estándar de mantenimiento preventivo diario que se realizan dentro de la instalación. La inspección de equipos es una tarea detallada con objetivos y resultados específicos.

1.4.3 Beneficios de la inspección de maquinarias

Inspecciones de mantenimiento regulares incluyen una serie de beneficios. Entre los cuales listamos [4]:

- Mayor confiabilidad
- Mayor calidad de salida
- Mayor conocimiento sobre el mantenimiento y las reparaciones
- Mayor vida útil de la máquina
- Mayor seguridad de los empleados
- Costos de mantenimiento reducidos

1.4.4 Aprendizaje Profundo como herramienta para la inspección de maquinarias

El proceso de inspección de maquinarias tradicional requiere personal experto y herramientas dedicadas para poder obtener un diagnóstico adecuado. Por lo cual, la pequeña y mediana industria que no cuenta con procesos de automatización no realiza estas inspecciones con la periodicidad meritoria. Es así como, gracias a la aparición y evolución de la tecnología han nacido alternativas más económicas, que no requieren herramientas sofisticadas para este fin. Los métodos clásicos basados en el análisis de diversas magnitudes de máquina en condiciones estacionarias están siendo sustituidos por metodologías modernas que se adaptan a cualquier régimen de funcionamiento de la máquina (incluidos los transitorios) [6]. Estos nuevos métodos, que implican el uso de herramientas avanzadas de procesamiento de señales, han mostrado un gran potencial y han proporcionado ventajas espectaculares frente a los enfoques convencionales permitiendo, entre otros hechos, una determinación mucho más fiable de la máquina.

Dheeraj Bansal propuso un sistema de mantenimiento predictivo en tiempo real para sistemas de máquinas basado en una red neuronal [8]. La capacidad de una red neuronal para aprender funciones de mapeo no lineal se utilizó para la predicción de los parámetros del sistema de la máquina utilizando la firma de corriente de movimiento. Este enfoque evita la necesidad de realizar mediciones costosas de los parámetros del sistema. A diferencia de muchos sistemas de monitoreo de condición basados en redes neuronales, este enfoque se valida en un procedimiento de prueba de concepto fuera de línea, utilizando datos de un equipo de prueba experimental que proporciona condiciones típicas de las que se usan en las máquinas de producción [8].

Por otro lado, José Antonio Daviu [6] nos presenta una alternativa para el análisis de fallas y mantenimiento predictivo en motores eléctricos, un tipo de motor a los que la industria ha migrado paulatinamente. En las últimas décadas, se ha realizado un esfuerzo continuo por investigar nuevas técnicas y métodos que sean capaces de determinar el estado de salud de estas máquinas con gran precisión y fiabilidad. Estos nuevos métodos (especialmente los basados en la monitorización de la señal de arranque del motor), que implican el uso de herramientas avanzadas de procesamiento de señales, han mostrado un gran potencial y han proporcionado ventajas frente a los enfoques convencionales permitiendo, entre otros hechos, una determinación mucho más fiable de la máquina [6]. Este artículo revisa la tendencia de análisis de fallas basados en la monitorización de la señal de arranque del motor y muestra las ventajas de este nuevo enfoque con respecto a su aplicación al análisis de magnitudes eléctricas [6]. Se incluyen ejemplos referidos a su aplicación a motores reales que operan en la industria, demostrando el enorme potencial del enfoque basado en transitorios y sus beneficios frente a los métodos convencionales.

CAPÍTULO 2

2. METODOLOGÍA

La clasificación de anomalías en motores es una herramienta disruptiva con el potencial de convertirse en un agente que agilice la detección temprana de fallas en la maquinaria de las plantas industriales. Además, puede ser de gran ayuda para investigadores, centros gubernamentales y empresas en general que manejen maquinaria industrial que requiera mantenimiento regular. Por lo tanto, la optimización de la adquisición, procesamiento y visualización de los datos es un punto clave.

El diseño de nuestra solución se enfoca en el desarrollo de una plataforma escalable y modularizada, que permite el desarrollo libre de un mejor modelo sin afectar la estructura del mismo. Adicionalmente, el código será liberado para que cualquier persona que desee aportar con mejoras pueda hacerlo.

Con esta finalidad, en este capítulo se propone una metodología que comprende desde la extracción, limpieza, preprocesamiento, análisis y almacenamiento de datos, hasta el diseño, desarrollo y visualización de los datos de sonido y vibración de los datos de motores de ciertas empresas de la ciudad de Guayaquil.

En la Sección 2.1 se detallan los requerimientos funcionales y no funcionales de la plataforma, lo que permite luego delimitar el alcance del proyecto, así como sus limitaciones. Por último, se detallan los beneficios y riesgos que este tipo de proyecto representa para los usuarios potenciales.

En la Sección 2.2 se describen los módulos que son necesarios para el desarrollo del prototipo: 1) Base de datos utilizada, con una descripción a detalle de todas las variables; 2) Módulo de preprocesamiento, en donde se describen todas las fases realizadas para obtener las estructuras de datos finales y 3) Modelos, en esta subsección se listan los modelos que fueron entrenados para la obtención del modelo refinado para la clasificación de fallas en motores.

En la Sección 2.3 se presenta el diseño de la solución junto al diagrama de despliegue respectivo, en el cual se representa cómo está estructurada la solución desde la adquisición de los datos, hasta la presentación visual del resultado de clasificación.

Por último, en la Sección 2.4 se detalla a nivel de software, el modelo arquitectónico que se utilizó; un diagrama de Casos de Uso que ilustra el comportamiento

usual de la solución en un ambiente común y finalmente se describe el prototipo realizado, tomando en consideración todos los aspectos de las secciones anteriores.

2.1 Análisis

En esta sección de análisis se describen los requerimientos del proyecto, contemplando su alcance y limitaciones. Luego, se detalla la metodología para la recolección de datos que mejor se adecua a la solución y, por último, se listan los usuarios potenciales de la solución.

2.1.1 Requerimientos

En las reuniones realizadas con el cliente se especificaron los requerimientos funcionales y no funcionales que debe cumplir el proyecto, tomando en consideración las necesidades de los usuarios. A continuación, se especifican los requerimientos funcionales y no funcionales planteados:

2.1.1.1 Requerimientos Funcionales

Para este proyecto hemos desarrollado una aplicación móvil para la recolección de los datos de sonido y vibración de motores como un complemento adicional a la aplicación web, para mayor detalle referirse al APÉNDICE. La finalidad de la aplicación móvil es proveer a los usuarios una herramienta sencilla que les permita grabar los sonidos y vibraciones desde sus propios celulares. Por esto, hemos dividido esta subsección en requerimientos funcionales para la aplicación móvil y para la aplicación web.

2.1.1.1.1 Móvil

- REQ 1. El sistema debe permitir capturar los valores generados por el acelerómetro del teléfono celular usando la frecuencia máxima que este permita.
- REQ 2. El sistema debe permitir capturar grabaciones de sonidos.
- REQ 3. El sistema debe permitir recolectar y eliminar varias grabaciones de sonidos y vibraciones en conjunto para un tipo de motor definido.
- REQ 4. El sistema debe permitir capturar y registrar metadatos de varias muestras de un motor con variaciones en sus parámetros.
- REQ 5. El sistema debe permitir crear experimentos predefinidos, estableciendo el tiempo de grabación y retraso para empezar la grabación.

- REQ 6. El sistema emitirá un sonido cuando el temporizador haya llegado a cero, para indicar la finalización del experimento.
- REQ 7. El sistema guardará los archivos de sonido y de vibraciones en la carpeta de descargas del celular en formato WAV y CSV respectivamente.
- REQ 8. El sistema tendrá un apartado para editar detalles de configuración del experimento. Los cuáles serán: tipo de máquina, estado de la máquina, planta, tiempo del experimento y tiempo de espera antes de empezar a grabar.

2.1.1.1.2 Web

- REQ 9. El sistema debe permitir cargar grabaciones de sonido en formato WAV.
- REQ 10. El sistema debe validar que las grabaciones de sonido que se carguen sean únicamente tipo WAV.
- REQ 11. El sistema debe permitir cargar archivos CSV con datos de vibraciones.
- REQ 12. El sistema debe validar que los archivos de velocidad que se suban sean únicamente de tipo CSV.
- REQ 13. El sistema mostrará, en la interfaz gráfica, representaciones visuales de los espectrogramas generados.
- REQ 14. El sistema mostrará al usuario un mensaje de retroalimentación que le indicará que los datos se están procesando.
- REQ 15. El sistema mostrará una porción de muestra del sonido al usuario, para que pueda este visualizarlo.
- REQ 16. El sistema mostrará gráficamente al usuario el sonido y las porciones en las que se ha detectado una falla en el motor.
- REQ 17. El sistema procesará audios de menos de un minuto de duración.
- REQ 18. El sistema debe proporcionar mensajes de error que sean informativos y orientados al usuario final.
- REQ 19. El sistema retornará un valor categórico de clasificación de sonido (normal, potencial falla y falla) con un intervalo de confianza.
- REQ 20. El sistema debe informar al usuario si un motor tiene potencial de falla y/o presencia de anomalías.

2.1.1.2 Requerimientos No-Funcionales

- REQ 21. La aplicación móvil debe ser compatible para los sistemas operativos Android y iOS.
- REQ 22. El sistema debe ser capaz de grabar/capturar sonido y vibración en una misma sesión y de forma síncrona.
- REQ 23. El tiempo desde la obtención de los datos hasta la presentación de resultados debe ser menor a 3 min.
- REQ 24. El sistema debe desarrollarse aplicando principios de ingeniería de software (completar)
- REQ 25. patrones y recomendaciones de programación que incrementen la seguridad de datos.
- REQ 26. El sistema debe poseer interfaces gráficas bien formadas que permita obtener información del estado de un motor de forma sencilla, rápida y confiable.

2.1.2 Alcance y limitaciones de la solución

Durante las reuniones con el cliente y recolección de datos (sonido y vibraciones) de maquinarias de diferentes fábricas de guayaquil se identificaron las siguientes limitaciones:

- El ingreso a diferentes fábricas ubicadas en guayaquil para la captura datos requiere autorización gerencial.
- Poca disponibilidad de maquinarias en estado de fallas y/o anomalías.
- Poca disponibilidad de maquinarias del mismo tipo en ambos estados, normal y fallo.
- Diferentes versiones de Sistemas Operativos (SOs).
- Presencia de ruidos del entorno además del ruido del motor, escenario real.
- La recolección de datos requiere motores con armadura de hierro, para poder colocar el teléfono móvil sobre su superficie adherido con un imán. Motores con armadura de aluminio fundido se descartaron del análisis.

Por lo tanto, se espera que el modelo clasificador sea capaz de identificar motor en estados de fallas y anomalías con un rendimiento aceptable. Ya que, debido a las

limitaciones mencionadas, se ha establecido realizar una clasificación binaria, mas no la identificación del estado preciso y/o más detallado de un motor en particular.

2.1.3 Riesgos y beneficios de la solución

2.1.3.1 Riesgos

- Daño y/o deterioro del dispositivo móvil por la exposición frecuente al imán.
- Que el modelo de detección de fallas no sea generalizable, es decir, predicciones para cierto tipo de motores en particular.
- Gastos operativos innecesarios debido a mantenimientos preventivos realizados por predicción errónea de presencia de anomalía del modelo.

2.1.3.2 Beneficios

- Detección oportuna de fallas de un motor eléctrico de forma rápida usando un dispositivo móvil.
- Disminución de costo para determinar la presencia de anomalías en un equipo industrial.
- Personal en general pueda determinar la presencia de fallas de un motor por medio de su dispositivo móvil.

2.1.4 Usuarios de la solución

Debido al espectro amplio de usuarios que se pueden beneficiar de una solución como la que presenta este proyecto, hemos identificado los siguientes usuarios potenciales:

- Gerentes de plantas industriales
 - Los gerentes de plantas industriales pueden implementar la solución en sus empresas y que estas estén al alcance de su personal técnico en todo momento.
- Inspectores de motores en planta
 - Pueden ayudarse de la solución para hacer diagnósticos rápidos del estado de los motores que luego pueden ser validados por sus procesos profesionales.
- Trabajadores de planta
 - Un trabajador de planta que sospeche de alguna falla en el motor puede grabar los sonidos y movimiento con la aplicación móvil y verificar el estado

del motor a través de la página web. No necesitará de un experto para hacer un diagnóstico de un motor.

- Investigadores
 - La aplicación móvil les permitirá recolectar este tipo de datos (sonido y movimiento) de una forma más fácil y rápida.

En general, el proyecto está diseñado para que cualquier persona con la pericia o no, pueda utilizar las aplicaciones y obtener una categorización para el estado de un motor.

2.2 Prototipado

2.2.1 Dataset

Para el entrenamiento del modelo clasificador, se construyó un dataset de sonido y vibraciones de motores en estado normal y anómalo de varias fábricas y talleres mecánicos de Guayaquil. Estos datos fueron recolectados por medio de la aplicación móvil desarrollada. La aplicación recolecta ambos tipos de datos, sonido y vibraciones en formato WAV y CSV respectivamente. Para la recolección, es necesario fijar el teléfono al motor, para ello se empleó un imán. A continuación, en la Tabla 2.1, se presenta estadísticas de los datos capturados:

Tabla 2.1. Detalles de los datos de motores capturados [autoría propia]

Estado	No. Motores	No. Grabaciones	Tiempo Promedio Grabación [Seg]
Normal	11	21	20
Anómalo	2	4	20

Se logró capturar sonidos y vibraciones de 13 motores diferentes, 11 en estado normal y 2 en estado anómalo. De los cuales, se realizaron 21 grabaciones a los motores de estado normal y 4 grabaciones a los motores en estado anómalo, todos los audios con una duración promedio de 20 segundos.

2.2.2 Módulo de Pre-procesamiento

Los sonidos y vibraciones requieren de un preprocesamiento previo al entrenamiento del modelo de aprendizaje profundo. La Figura 2.1 presenta las etapas

de transformaciones que se realiza al sonido y a las vibraciones. A continuación, se detalla los pasos del pre-procesamiento:




Figura 2.1. Etapas del pre-procesamiento de las grabaciones de sonidos y vibraciones [autoría propia]

1. Cargar el sonido y las vibraciones en su representación digital.
2. Dividir el sonido y las vibraciones en ventanas temporales de 20 segundos.
3. Dividir el sonido en tramos y a cada tramo aplicar una función de windowing, este último paso nos ayuda a evitar las distorsiones del sonido y vibraciones en el dominio de la frecuencia.
4. Realizar la transformada de Fourier para convertir el sonido y las vibraciones del dominio temporal al dominio frecuencial.
5. Obtener la matriz del espectrograma del sonido y las vibraciones. Esta matriz es la representación de las series temporales del sonido y vibraciones en el dominio temporal (eje x) y el dominio frecuencial (eje y).

En la Figura 2.2 se visualiza el resultado del pre-procesamiento descrito para las grabaciones de vibraciones de un motor en particular. La representación en espectrogramas es similar para las grabaciones de sonido, aunque estas no poseen 3 ejes de medición.

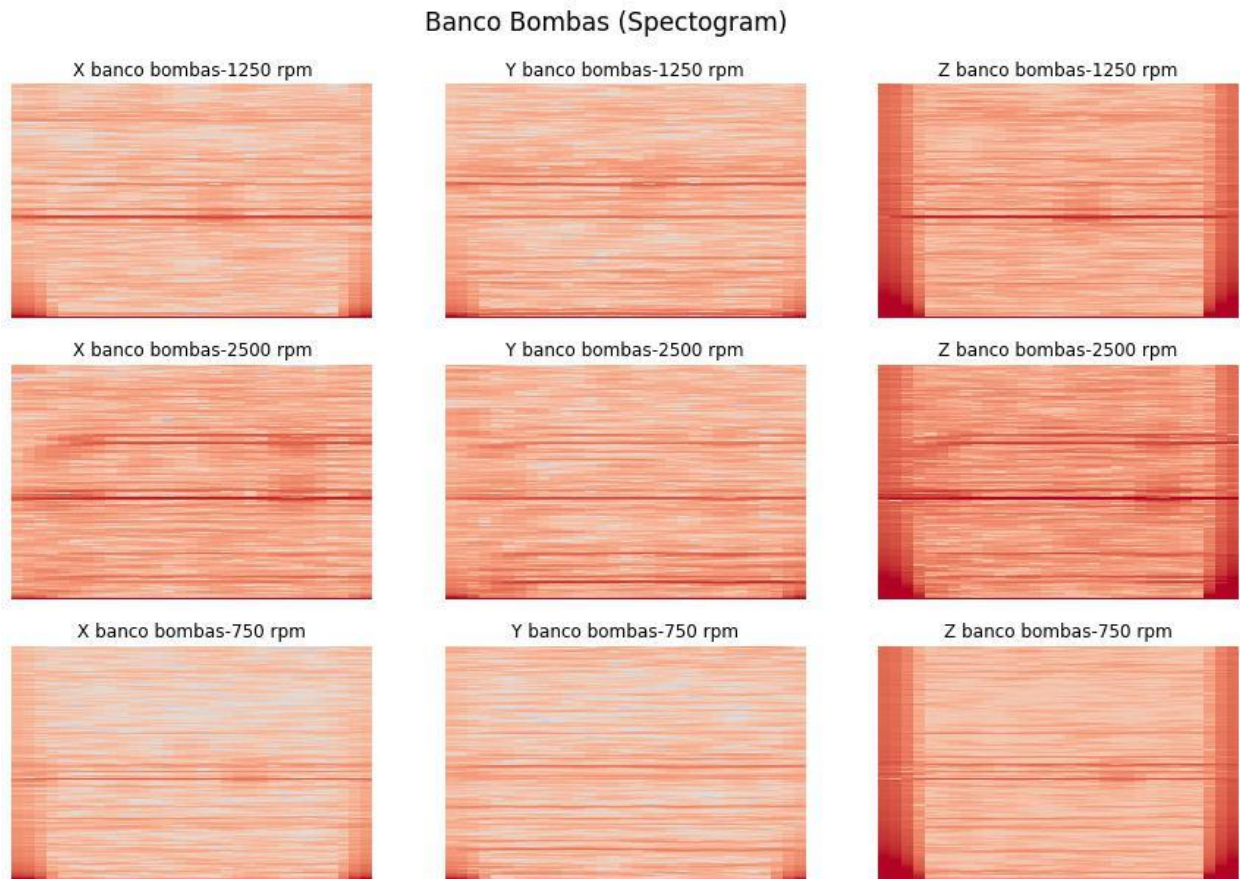


Figura 2.2. Resultado del preprocesamiento de las señales de vibraciones [autoría propia]

2.2.3 Modelos de Predicción

Para este proyecto se utilizó modelos de redes neuronales. Para esto, el sonido y las vibraciones se procesan para obtener su representación en espectrogramas. Estos espectrogramas se convierten en imágenes y serán la entrada del modelo de aprendizaje profundo. Por ende, la entrada del modelo será un bloque de imágenes concatenadas, imágenes de espectrogramas de sonidos y vibraciones.

Adicionalmente, se usó aprendizaje por transferencia de dos redes convolucionales, VGG16 Y Resnet50. Estas redes se encuentran entrenadas por autoría propia para determinar anomalías en sonidos de motores de juegos del dataset ToyADMOS [9]. Finalmente, se construyó una arquitectura de tipo Ensemble, como se muestra en la Figura 2.3.

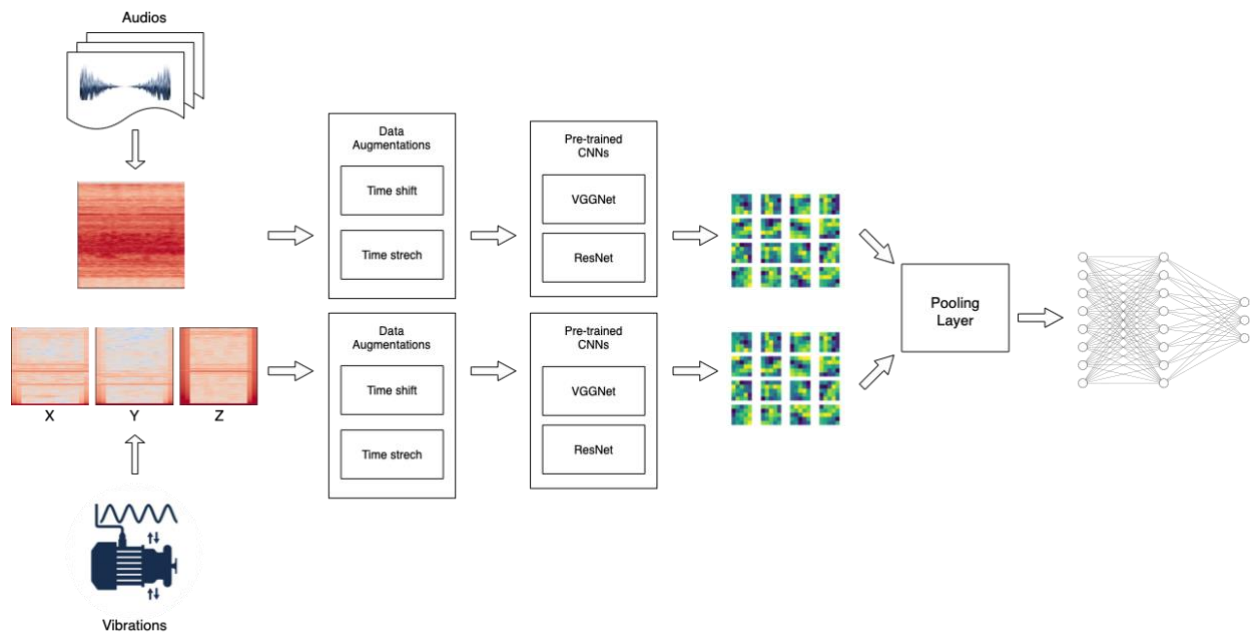


Figura 2.3: Framework del Modelo [autoría propia]

2.3 Diseño de la solución

En esta sección se describe el diseño de la solución a través de un diagrama de despliegue, el cual detalla el flujo completo desde la obtención de los datos hasta su pre-procesamiento y presentación de resultados.

2.3.1 Diagrama de despliegue

El usuario graba desde su celular el movimiento y sonido del motor a través de una aplicación. Esas grabaciones son la entrada para la aplicación web, la cual a través de un módulo de lectura de archivos los guarda en una base de datos temporal. Luego, en el servidor en el que está alojado el modelo, el módulo de pre-procesamiento de datos lee los archivos y los convierte a espectrogramas para pasarlos al módulo de clasificación. Este último recibe los espectrogramas y devuelve una respuesta, que es un valor categórico de estado de falla del motor. Finalmente, este valor es mostrado por la aplicación web al usuario. Se detalla gráficamente este diseño en la Figura 2.4.

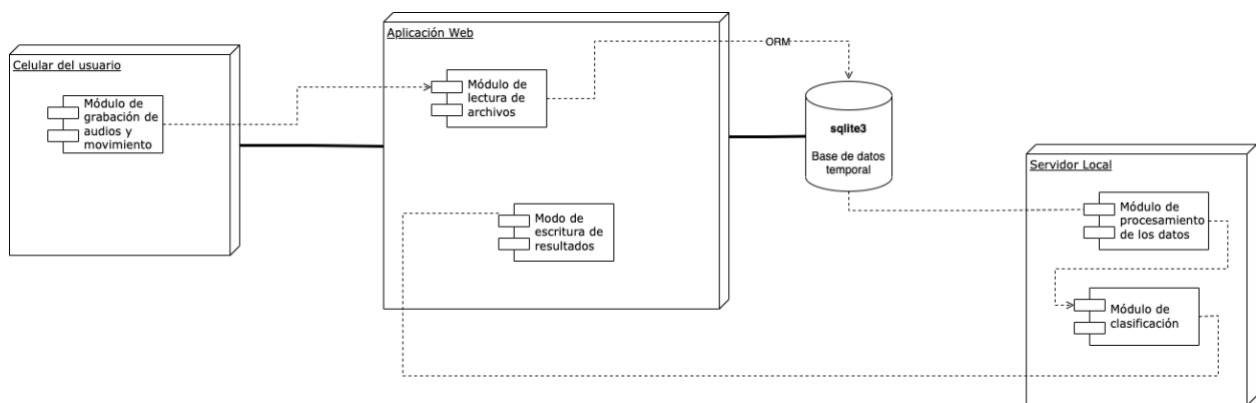


Figura 2.4: Diagrama de despliegue [autoría propia]

2.4 Software

La sección de software presenta la arquitectura de la solución, diagrama de casos de uso y finalmente el prototipo de la aplicación móvil.

2.4.1 Arquitectura

El proyecto se encuentra estructurado como se muestra en la muestra la Figura 2.5. Hemos obviado la adquisición de los datos porque a pesar de que ofrecemos una aplicación móvil, queda a discreción del usuario utilizar la aplicación que proponemos u otra.

La arquitectura se compone de tres secciones principales:

1. Aplicación web: El usuario interactúa con la interfaz gráfica y esta a su vez recepta los archivos que serán pasados al módulo de lectura para ser enviados a la sección de preprocesamiento de datos.
2. Pre-procesamiento de datos: Los datos de la sección anterior son almacenados en una base de datos local para luego ser pre-procesados y enviados a modelo a través de un API.

3. Aprendizaje profundo: El modelo recibe los datos para clasificarlos y devolver un valor categórico que clasifica el estado de falla del motor a analizado. Este valor es pasado por medio del API al módulo de escritura y posteriormente a la interfaz gráfica para que el usuario visualice la respuesta del modelo.

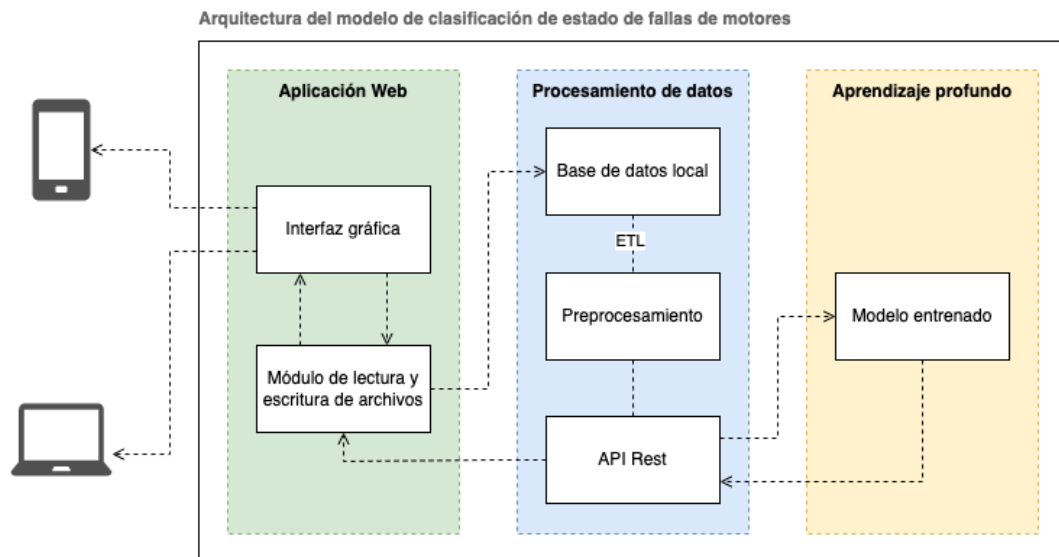


Figura 2.5: Diagrama de arquitectura [autoría propia]

2.4.2 Diagramas

2.4.2.1 Diagrama de Casos de Uso de la clasificación del estado de falla de un motor

Cuando un usuario obtiene los resultados de clasificación del estado de falla de un motor

se seguirá el proceso de la Figura 2.6. En la cual se describen los siguientes pasos:

1. El usuario graba el sonido y movimiento del motor.
2. Las grabaciones son subidas a la página web propuesta.
3. En el backend se preprocesan los datos y los transforma a espectrogramas para que sirvan de input al modelo.
4. El modelo pre-entrenado clasifica los espectrogramas y retorna un valor categórico.

5. Finalmente, el usuario puede visualizar la respuesta del modelo.

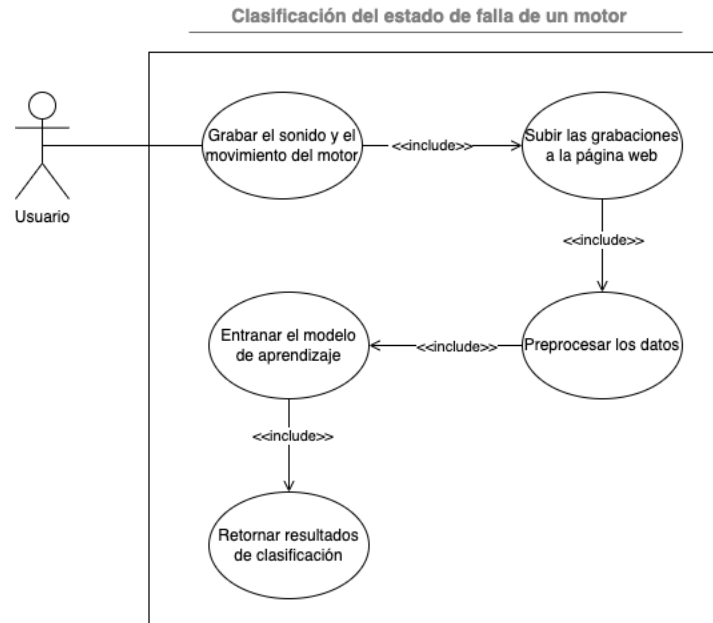


Figura 2.6: Diagrama de Casos de Uso de la clasificación del estado de falla de un motor [autoría propia]

2.4.3 Prototipo

La aplicación web se usa principalmente para realizar predicciones del estado de los motores. Para esto, es necesario que se cargue a la aplicación el nombre del motor, el archivo de sonido y vibraciones. A continuación, se detalla el flujo de las ventanas de la aplicación web:

En la Figura 2.7 se observa la ventana principal de la aplicación web. En esta ventana se puede visualizar el listado de las predicciones que el usuario ha realizado, así como todas las predicciones que se hayan realizado por otros usuarios ordenados cronológicamente. Adicionalmente, se dispone de un botón en la parte superior izquierda que dirige al usuario a la interfaz principal de la API de Django.

Detección de anomalías en motores			Admin
+ Predicción			
Predicciones Realizadas			
Turbina Josue S.A.	Anómalo	92.35 %	Ver Detalles
Taladrina Paulette S.A.	Nomal	53.42 %	Ver Detalles
Banco de Bombas - Lab. Mecánica	Nomal	62.54 %	Ver Detalles
Ponchadora Hidráulica	Anómalo	51.33 %	Ver Detalles
Motor de Cinta Transportadora	Anómalo	62.35 %	Ver Detalles
Turbina Mecánica	Nomal	83.52 %	Ver Detalles

Proyecto materia Integradora ESPOI - Josue Dávalos y Paulette Vázquez

Figura 2.7. Página principal [autoría propia]

La Figura 2.8 ilustra la interfaz en donde el usuario debe ingresar los datos del motor que desea predecir. Es necesario que el formato del archivo de sonido sea WAV y CSV para el archivo de vibraciones. Además, al completar la subida de archivos, se muestra una opción para reproducir el sonido.

Figura 2.8. Carga de datos necesarios para la predicción [autoría propia]

Adicionalmente en la Figura 2.9 se visualiza la interfaz que muestra más detalles de la predicción por cada motor ingresado. En esta ventana el usuario puede reproducir el sonido y visualizar los tramos de este en donde el modelo identificó presencia de

anomalía. Así mismo, puede observar la imagen del espectrograma de la sección del sonido seleccionado.

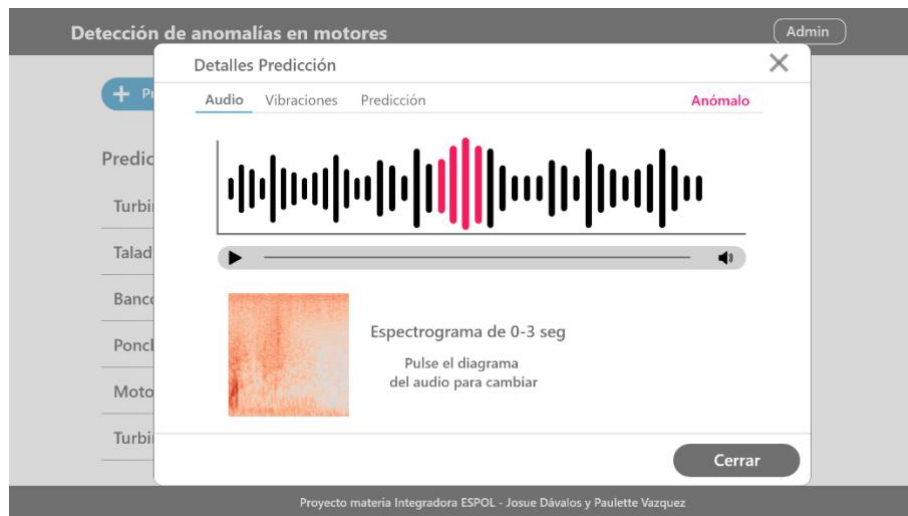


Figura 2.9. Visualización de los detalles de la predicción, sección sonido [autoría propia]

Además de sonido, el usuario podrá visualizar las curvas de frecuencias de las vibraciones por cada eje de dicha grabación, tal como se muestra en la Figura 2.10. Estas visualizaciones representan la amplitud en frecuencia por cada eje de medición.

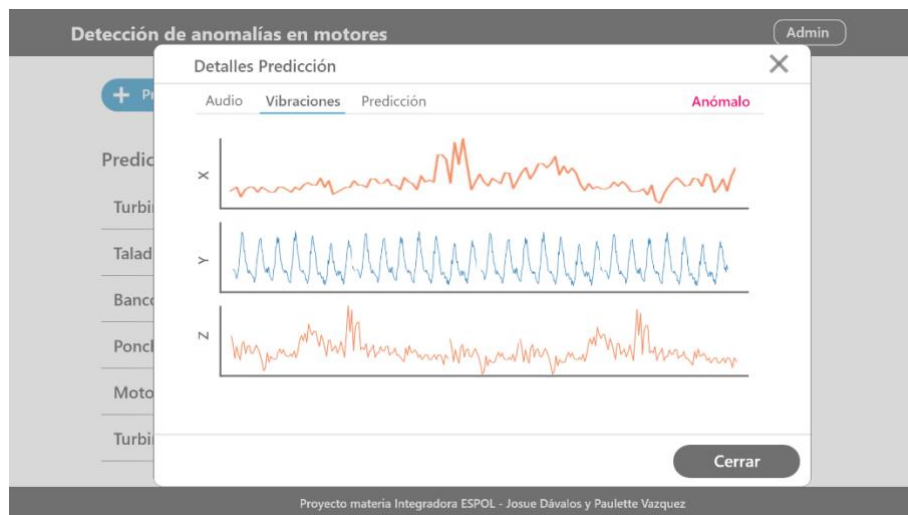


Figura 2.10. Visualización de los detalles de la predicción, sección vibraciones [autoría propia]

Finalmente, se dispone de una sección en la que el usuario puede observar metadatos de la predicción, así como la distribución de probabilidades por para clase otorgada por el modelo, Figura 2.11.



Figura 2.11. Detalles de predicción [autoría propia]

CAPÍTULO 3

3. RESULTADOS Y ANÁLISIS

En este capítulo se describen los resultados del modelo desarrollado como se especificó en la Sección 2.3. En la Sección 3.1.1 se detalla el particionamiento de los datos, en la Sección 3.1.2 se explican los resultados de las métricas durante la fase de entrenamiento y validación, en la Sección 0 se explican los resultados de la fase de prueba, y por último en la Sección 0 se discuten los resultados generales y se hace una comparación con los resultados de otras investigaciones en el área.

3.1 Modelo de Clasificación

3.1.1 Particionamiento de los datos

Dado que tenemos 25 grabaciones en total de los 13 motores, decidimos dividir los datos de entrenamiento y prueba de la siguiente manera:

- Entrenamiento: 80% de todos los tipos de motores.
- Validación: 20% de grabaciones completas de motores que no aparecen en el entrenamiento.

Dado este particionamiento, hemos utilizado el 80% del conjunto de datos para entrenamiento y el 20% para validación. Seleccionamos esta parte del conjunto de datos para prueba porque queremos evaluar si el modelo es capaz de clasificar nuevas muestras del mismo tipo de motor y así evaluar su generalización.

3.1.2 Entrenamiento y Validación

Después de dividir los datos en entrenamiento y validación, entrenamos el modelo durante 30 épocas hasta que convergió a una pérdida aceptable de 0.2014, como se muestra en la Figura 3.1.




Figura 3.1: Métrica de pérdida del modelo [autoría propia]

La Figura 3.2 muestra cómo se desempeñó el modelo durante las fases de entrenamiento y validación en términos de precisión. Como puede verse en esta figura, el modelo alcanzó un 92% de precisión durante las fases de entrenamiento y validación. El modelo funciona bien y no parece estar sobre ajustado a los datos de entrenamiento.

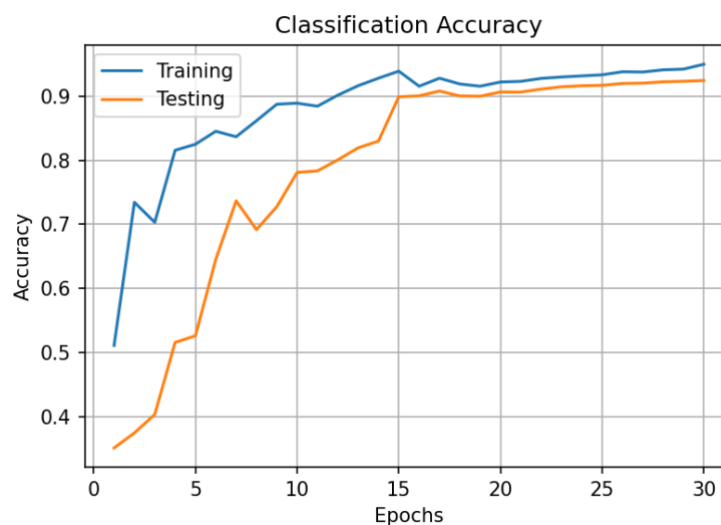


Figura 3.2: Métrica de precisión del modelo [autoría propia]

También se calculó la puntuación del área bajo la curva (AUC). Dado que la precisión no es sensible al desequilibrio de clases, el uso de AUC permitirá que la clase minoritaria tenga un impacto más fuerte. La Figura 3.3, muestra que el puntaje AUC es de 95%, superando a la métrica de precisión y confirma que el desequilibrio de clases no afectó negativamente al modelo propuesto.

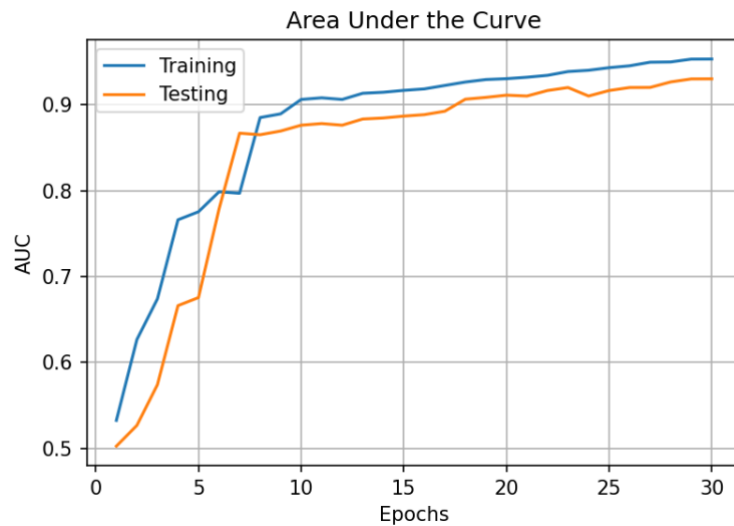


Figura 3.3: Métrica de área bajo la curva del modelo [autoría propia]

3.1.3 Prueba

La Figura 3.1, Figura 3.2, Figura 3.3, y Figura 3.4 describen los resultados de las pruebas. El modelo que utilizaron las CCNs pre-entrenadas con los datos de motores de la base ToyADMOS superó a las CNNs entrenadas originalmente con ImageNet, con valores de AUC de 93.02% y 84.94% respectivamente, aproximadamente 9 puntos porcentuales más.

A pesar de que el ensamblaje de VGG16 y ResNet50 pre-entrenadas con ImageNet no fue el mejor para este proyecto en específico, funciona de manera similar a otros modelos. Sin embargo, el modelo final que utiliza redes pre-entrenadas con motores de juguete es superior, debido a que el contexto de las imágenes con las que se lo entreno es similar al de este proyecto.

Este modelo final fue embebido en una página web que recibe grabaciones de sonidos y vibraciones de motores y retorna la clasificación con su respectivo valor de

confianza. En el APÉNDICE B se encuentra el manual de uso de la aplicación web para mayor detalle.

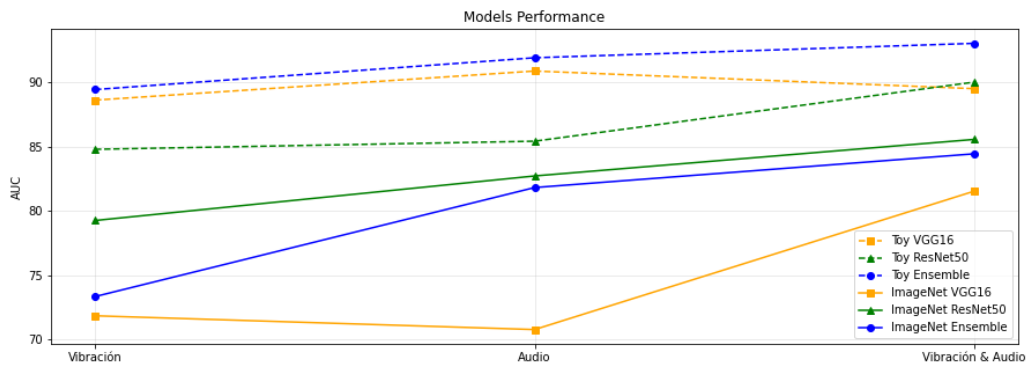


Figura 3.4: Comparativa de resultados del modelo final vs. modelos de prueba [autoría propia]

3.1.4 Discusión

En el campo de la clasificación de datos de ruido de maquinaria, podemos encontrar varios trabajos relacionados que utilizan patrones espacio temporales para hacer un análisis de series de tiempo y diagnosticar el estado de falla de un motor. Sin embargo, con el surgimiento de nuevas técnicas de aprendizaje automático (ML), los métodos clásicos basados en el análisis de varias magnitudes de máquinas en condiciones estacionarias están siendo reemplazados por metodologías basadas en inteligencia artificial (IA) que pueden adaptarse a una variedad de regímenes operativos de la máquina [10] [11] [9]. Estos nuevos métodos [10] [11], que involucran el uso de herramientas avanzadas de procesamiento de señales, como los codificadores Automáticos o AE en sus siglas en inglés, han mostrado potencial y han proporcionado ventajas sobre las metodologías convencionales, permitiendo una determinación confiable de los parámetros de operación de la máquina [12].

El modelo que hemos propuesto utiliza CNNs pre-entrenadas, que generalmente se usan para tareas de Visión por Computadora (CV). Además, utilizamos técnicas de aumento de datos para resolver el problema del desequilibrio de clases en nuestros datos, y un conjunto de dos modelos CNNs+MLP.

CAPÍTULO 4

4. CONCLUSIONES Y RECOMENDACIONES

4.1.1 Conclusiones

En este trabajo hemos analizado sonidos para la detección de anomalías acústicas de motores eléctricos utilizando técnicas de Aprendizaje Profundo. Para la extracción de características, utilizamos redes neuronales fácilmente disponibles como: VGG16 y ResNet50, que fueron previamente entrenadas para clasificar imágenes de ToyADMOS. Luego usamos estas características para entrenar una red MLP completamente conectada. Los resultados indican que nuestro marco impulsa el estado del arte al obtener un AUC del 93%, con un mejor rendimiento que los AE y otros marcos de CNN.

Además, confirmamos que las características basadas en imágenes podrían usarse para la detección de anomalías acústicas. Por lo tanto, el mantenimiento predictivo de motores eléctricos también podría monitorearse mediante registro acústico con una excelente precisión.

4.1.2 Recomendaciones y Trabajo Futuro

Durante el desarrollo del modelo de clasificación y de la aplicación web hemos identificado varios aspectos clave que se deben considerar tanto para replicar este proyecto como para trabajos futuros que tomen de base el mismo.

Modelo de clasificación:

- Tanto los datos de vibraciones como los de audio fueron convertidos a espectrogramas, es importante tomar en cuenta el tamaño de las imágenes para evitar que los píxeles no sean representativos. Es decir, la imagen no tiene que ser muy pequeña ni muy grande para evitar la pérdida de información. No importa si el tamaño de las imágenes de las vibraciones es diferente a la de sonidos, de hecho, en nuestro caso, el que sean diferentes, debido a su origen, nos permitió obtener mejores resultados.
- Al momento de recolectar datos de motores en funcionamiento en la industria, es complicado encontrar motores en estado de falla a la misma escala de motores en buen estado. Por este motivo la aumentación de

datos es crucial para evitar el desbalance de clases al momento de entrenar el modelo. Sin embargo, es un proceso demorado, por lo que aconsejamos empezar con métodos básicos como los que hemos utilizado.

- En el caso que se desee probar otros esquemas o redes neuronales, es una buena práctica no tomar todos los datos, sino utilizar como máximo el 40% en nuestro caso en donde la base es pequeña. Esto con la finalidad de poder hacer comparaciones rápidas y no tomar demasiado tiempo con modelos que no funcionan bien con datos de motores.

Aplicación web:

- La modularización es uno de los principios primordiales al desarrollar una aplicación web cuando se quiere optimizar tiempo o errores en cascada en cambios futuros.
- El hacer la aplicación modular facilita la escalabilidad del programa. Sugerimos que se mantengan estos principios para que la aplicación se pueda mejorar a lo largo del tiempo.

El garantizar que los puntos previamente mencionados se cumplan permitirá hacer mejoras al proyecto. A continuación, detallamos el trabajo futuro que se podría realizar:

- Además de realizar “time shift” y “time stretch” como técnicas par aumentación de datos, se podrían utilizar técnicas más sofisticadas, que acorde al estado del arte mejoren el rendimiento de los modelos para este tipo de datos.
- Utilizar diferentes enfoques de operaciones con los vectores de vibraciones: concatenar ejes, sumar ejes, multiplicar ejes, etc.
- Utilizar otras redes neuronales y probar otros enfoques de ensamblaje.
- Usar CNNs pre-entrenadas de dominios más relacionados a este tópico y con mayor variedad de motores, para que el modelo pueda generalizar con mayor precisión el estado de falla de motores diversos.

BIBLIOGRAFÍA

- [1] Interplay Learning, «Interplay Learning,» January 2020. [En línea]. Available: <https://www.interplaylearning.com/blog/different-types-of-maintenance>.
- [2] ABB, «ABB,» 2022. [En línea]. Available: <https://new.abb.com/medium-voltage/service/maintenance/feature-articles/4-types-of-maintenance-strategy-which-one-to-choose>.
- [3] Jonathan Davis, «HippoCMMS,» June 2021. [En línea]. Available: <https://hippocmms.iofficecorp.com/blog/different-types-of-maintenance>.
- [4] R. K. Mobley, «Predictive Maintenance,» de *Plant Engineer's Handbook*, Butterworth-Heinemann, 2001, pp. 721, 723-755.
- [5] J. a. Z. Z. a. S. C. a. Y. R. a. C. X. Wu, «Fault-attention generative probabilistic adversarial autoencoder for machine anomaly detection,» *IEEE Transactions on Industrial Informatics*, vol. 16, nº IEEE, pp. 7479--7488, 2020.
- [6] J. Antonino-Daviu, « Electrical Monitoring under Transient Conditions: A New Paradigm in Electric Motors Predictive Maintenance,» de *MDPI*, 2020.
- [7] R. Z. Daza, «DESARROLLO E IMPLEMENTACIÓN DE RUTINAS DE MANTENIMIENTO PREVENTIVO Y CORRECTIVO PARA LAS ÁREAS DE ENSAMBLE Y REVISIÓN EN LA INDUSTRIA ICOLLANTAS BAJO EL ENTORNO AS400,» Santiago de Cali, 2006.
- [8] D. J. E. B. J. Dheeraj Bansal, «A real-time predictive maintenance system for machine systems,» *International Journal of Machine Tools & Manufacture*, p. 759–766, 2004.
- [9] K. Yuma, S. Shoichiro, H. Noboru, U. Hisashi y I. Keisuke, «ToyADMOS: A Dataset of Miniature-Machine Operating Sounds for Anomalous Sound Detection,» 2019.
- [10] J. a. Z. Z. a. S. C. a. Y. R. a. C. X. Wu, «Fault-attention generative probabilistic adversarial autoencoder for machine anomaly detection,» *IEEE*

Transactions on Industrial Informatics, vol. 16, n° IEEE, pp. 7479--7488, 2020.

- [11] D. Y. a. Y. I. D. Oh, «Residual error based anomaly detection using auto-encoder in SMD machine sound,» *Sensors*, vol. 18, n° MDPI, p. 1308, 2018.

APÉNDICES

APÉNDICE A

PROTOTIPO FALLIDO DEL SOPORTE PARA EL TELÉFONO MÓVIL

Se diseñó y construyó un prototipo de un soporte universal para teléfonos móviles realizado por medio de una impresora 3D. La función principal de este soporte es mantener al teléfono móvil fijo en la superficie de un motor por medio de 3 imanes colocados en la parte trasera del mismo. De esta forma, se esperaba que las señales de vibraciones capturadas sean lo más cercanas posibles a la señal de vibraciones original emitida por el motor.

Sin embargo, se determinó que dicho soporte potencialmente introduciría ruido a las señales capturadas. Este ruido introducido se debe principalmente su peso (más de 200 gramos), material usado en la impresión y lo resortes que posee para presionar al teléfono en ambos ejes.




Figura A. 1: Prototipo fallido del soporte móvil impreso [autoría propia]

APÉNDICE B

MANUAL DE USUARIO

Cargar datos y Predecir

1. En la pantalla principal de la aplicación web se visualiza un botón llamado “Nueva Predicción”. Inicie una nueva predicción, una ventana modal para el cargue de las señales de audio y movimiento aparecerá.
2. En la Figura B. 1 se muestra la ventana modal. Escriba el nombre del motor y agregue las señales de audio y movimiento en formato WAV y CSV respectivamente. Automáticamente podrá reproducir el audio si así lo desea.
3. Presione el botón “Predecir” y espere a que el modelo retorne un resultado.

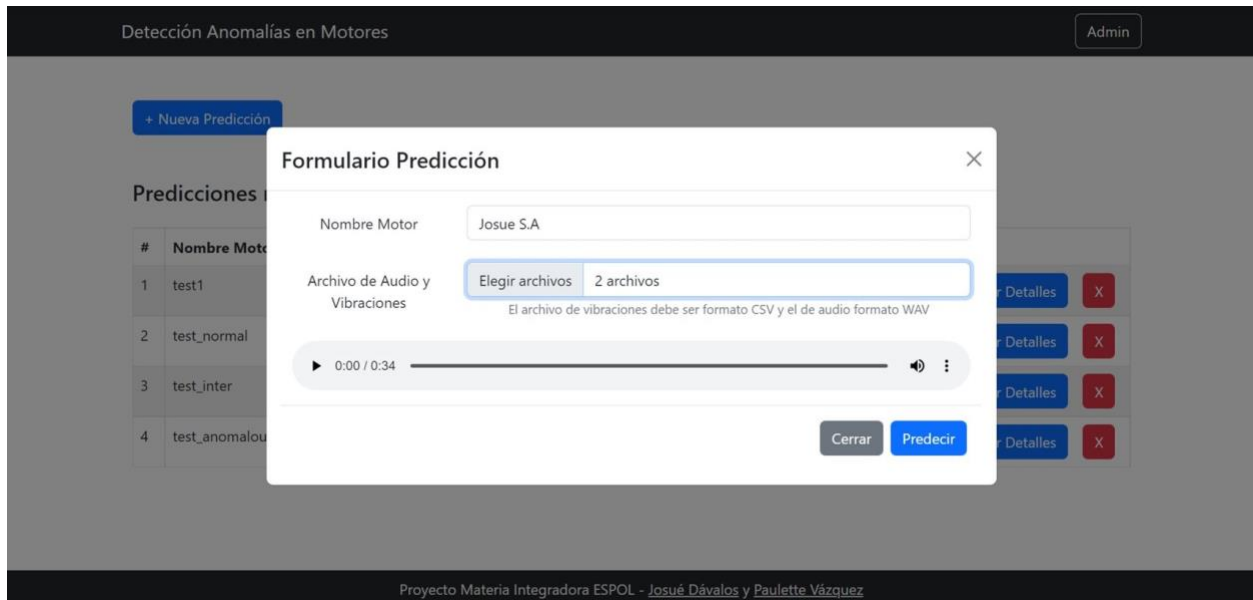


Figura B. 1: Pantalla cargue de señales de audio y movimiento [autoría propia]

Resultados

1. La Figura B. 2 representa la pantalla principal de resultados de las predicciones. Para mostrar los detalles de una predicción presione el botón “Ver detalles”.

[+ Nueva Predicción](#)

Predicciones realizadas

#	Nombre Motor	Predicción	
1	josue	Anomalous	Ver Detalles X
2	test	Anomalous	Ver Detalles X
3	Paulette_SA	Anomalous	Ver Detalles X

Figura B. 2: Pantalla de Resultados [autoría propia]

2. Se presenta una ventana modal con tres pestañas: audio, vibraciones y más datos, como se muestra en la Figura B. 3. La pestaña predeterminada es la de audio, la cual se divide en las siguientes subsecciones:
 - 2.1. Clasificación general del audio, se escoge el grado de clasificación más crítica entre todas las particiones de 10 segundos del audio completo.
 - 2.2. Serie temporal del audio, en el eje x representa el tiempo y el eje y representa la amplitud de la onda sonora. Cada partición de 10 segundos del audio está pintada con un color de acuerdo con su clasificación de anomalía. Verde si está en buen estado, amarillo si está cercano a fallar y rojo si está dañado.
 - 2.3. Reproductor de audio, permite escuchar el audio cargado cuando se requiera.
 - 2.4. Imagen del espectrograma, al dar clic en cualquier partición de 10 segundos de la serie temporal, se muestra su espectrograma respectivo.
 - 2.5. Clasificación del audio, se presenta una tabla con la probabilidad del estado de falla de cada clase (Normal, Intermedio y Anómalo). Esta tabla se actualiza dependiendo de la partición del audio que se haya seleccionado.

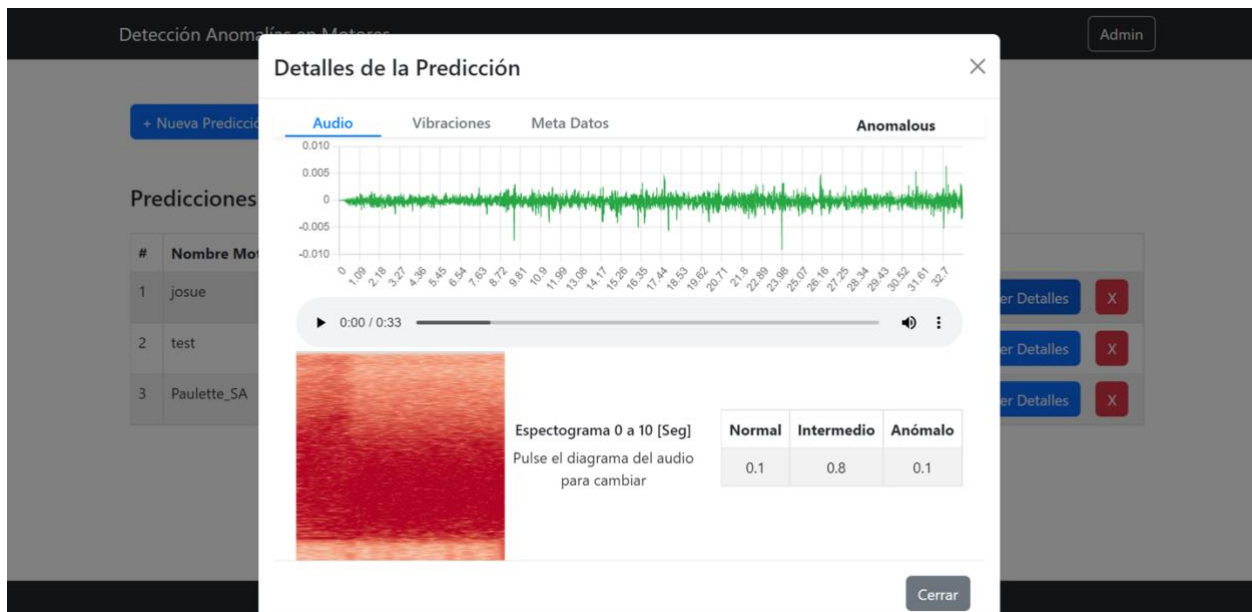


Figura B. 3: Pantalla de Detalles de la Predicción [autoría propia]

3. La siguiente pestaña “Vibraciones” representada en la Figura B. 4, cuenta con las siguientes subsecciones:
 - 3.1. Señal temporal de las vibraciones en el eje x.
 - 3.2. Señal temporal de las vibraciones en el eje y.
 - 3.3. Señal temporal de las vibraciones en el eje z.

En todas las series el eje x representa la frecuencia y el eje y representa los decibelios.

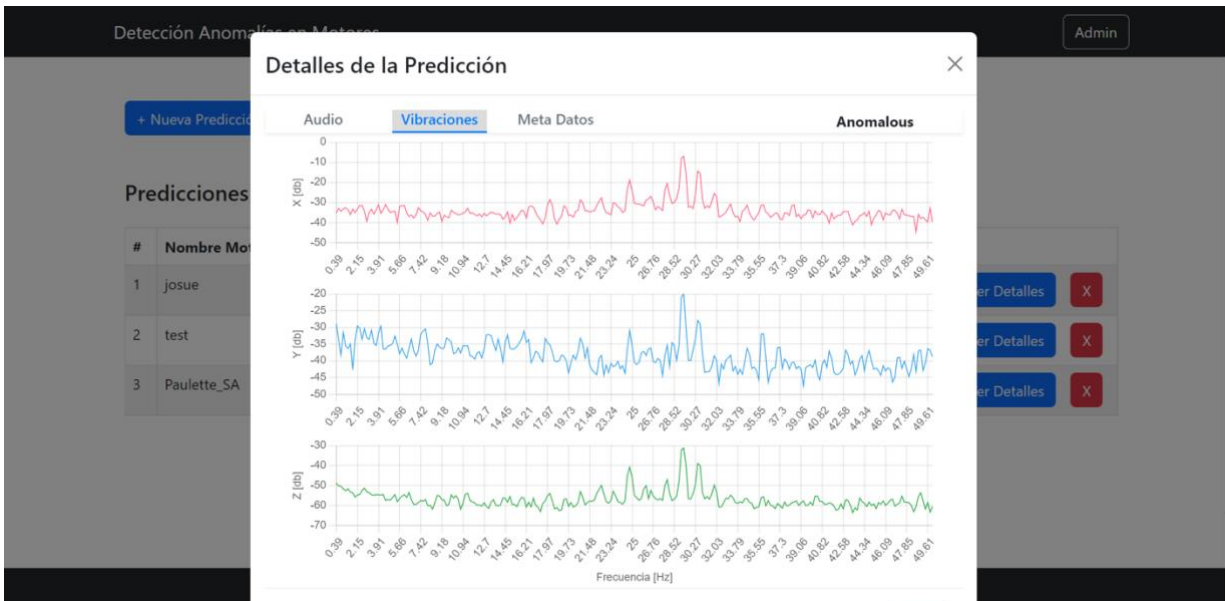


Figura B. 4: Pantalla de Detalles de las Vibraciones [autoría propia]

4. Por último, en la Figura B. 5 se muestra la pestaña de “Metadatos”. En la que se detalla:
 - 4.1. Nombre del motor.
 - 4.2. Directorio en donde se almacenaron las señales de audio y movimiento.

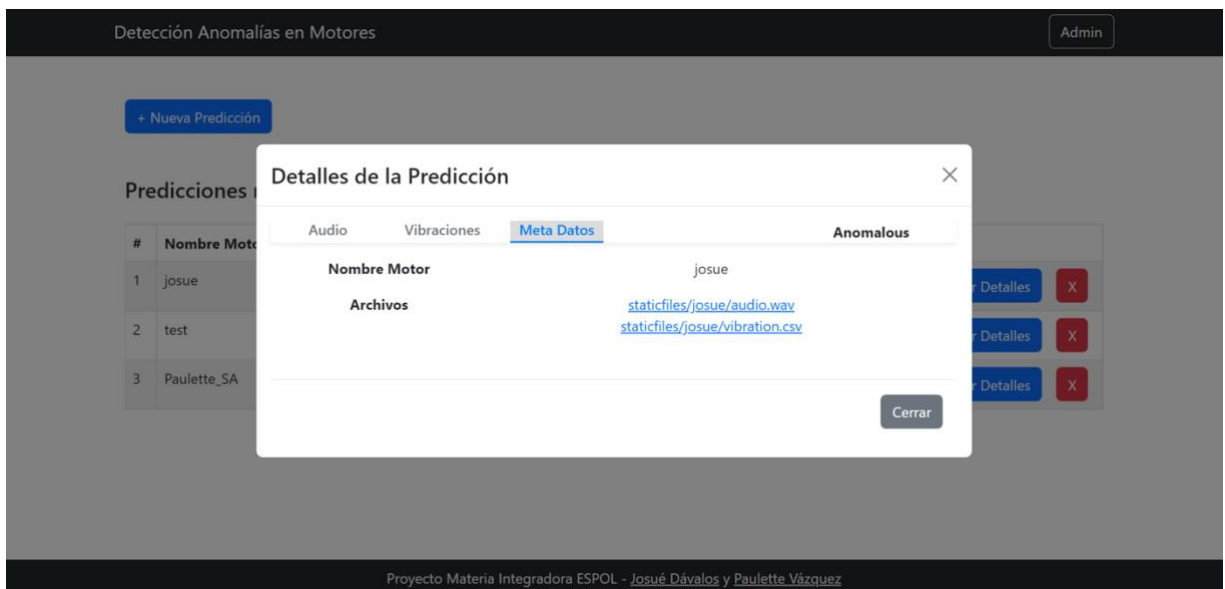


Figura B. 5: Pantalla de Metadatos [autoría propia]

5. Para continuar diagnosticando el estado de otros motores, presione el botón “Cerrar” y repita los pasos desde el inicio.

APÉNDICE C

MANUAL DE DESPLIQUUE

1. Requerimientos preinstalación

1.1. Requerimientos del Sistema

Cualquier sistema operativo que soporte Python 3.7 puede ser usado para este proyecto.

1.2. Requerimientos del Software

El proyecto se implementó usando Django, esquema implementado en Python. Se utilizó Python 3.7 y se incluyeron las siguientes librerías:

- black~=22.0
- flake8>=3.7.9, <4.0
- ipython>=7.31.1, <8.0
- isort~=5.0
- jupyter~=1.0
- jupyterlab~=3.0
- kedro==0.18.1
- kedro-telemetry~=0.2.0
- nbstripout~=0.4
- pytest-cov~=3.0
- pytest-mock>=1.7.1, <2.0
- Py test~=6.2
- kedro-viz==5.0.0
- librosa==0.9.2
- django==4.0.6
- sqlparse==0.4.2
- tzdata==2022.1
- django-cors-headers==3.13.0
- djangorestframework==3.13.1
- xgboost==1.6.1
- matrixprofile==1.1.10
- protobuf==3.11.2

- stumpy==1.11.1
- tsfresh==0.19.0
- tensorflow>=2.6.0

1.3. Requerimientos de Hardware

Los requerimientos recomendados de hardware para la ejecución del proyecto y cumplir los requerimientos son los siguientes:

1.3.1. Requerimientos de Hardware Mínimos

- Procesador: Intel Core2 Duo / AMD Athlon
- Velocidad Procesador: 1.8GHz
- Random access memory (RAM): 4 Gb
- Capacidad de disco duro: 20 Gb

1.3.2. Requerimientos de Hardware Recomendados

- Procesador: Intel Core i3 530 / AMD Phenom
- Velocidad Procesador: 2.2 GHz
- Random access memory (RAM): 8 Gb
- Capacidad de disco duro: 30 Gb

2. Instalación del Proyecto

2.1. Pre-requisitos

Tener acceso al repositorio del proyecto donde se encuentra guardado el código.

2.2. Instalación

Para asegurarnos que todo fue correctamente instalado, en la carpeta de origen iniciar el proyecto en localhost y esperar hasta que compile:

```
$ kedro run
```