



UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE GUAYAQUIL
CARRERA DE INGENIERÍA AUTOMOTRIZ

**IMPLEMENTACIÓN DE UN SISTEMA PARA LA EVALUACIÓN DE AMORTIGUA-
DORES DE VEHÍCULOS USANDO SENSORES IOT Y MODELOS DE REDES LSTM**

Trabajo de titulación previo a la obtención del
Título de Ingeniero Automotriz

AUTOR: TONY FERNANDO LINDAO VERA
SAUL EDUARDO VALLEJO YAGUAL

TUTOR: ING. JOSE LUIS MALDONADO ORTEGA, MGTR

Guayaquil – Ecuador

2025

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE
TITULACIÓN**

Nosotros, Tony Fernando Lindao Vera con documento de identificación N°0920922705 y Saul Eduardo Vallejo Yagual con documento de identificación N° 2450037623; manifestamos que: Somos los autores y responsables del presente trabajo; y, autorizamos a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Guayaquil, 22 de agosto del año 2025

Atentamente,



Tony Fernando Lindao Vera

0920922705



Saul Eduardo Vallejo Yagual

2450037623

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Nosotros, Tony Fernando Lindao Vera con documento de identificación No.0920922705 y Saul Eduardo Vallejo Yagual con documento de identificación No. 2450037623, expresamos nuestra voluntad y por medio del presente documento cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autores del Artículo Académico: “Implementación de un sistema para la evaluación de amortiguadores de vehículos usando sensores IoT y modelos de redes LSTM”, el cual ha sido desarrollado para optar por el título de: Ingeniero Automotriz, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribimos este documento en el momento que hacemos la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Guayaquil, 22 de agosto del año 2025

Atentamente,



Tony Fernando Lindao Vera

0920922705



Saul Eduardo Vallejo Yagual

2450037623

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, José Luis Maldonado Ortega con documento de identificación N° 1105738395, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: IMPLEMENTACIÓN DE UN SISTEMA PARA LA EVALUACIÓN DE AMORTIGUADORES DE VEHÍCULOS USANDO SENSORES IOT Y MODELOS DE REDES LSTM, realizado por Tony Fernando Linao Vera con documento de identificación N° 0920922705 y por Saul Eduardo Vallejo Yagual con documento de identificación N° 2450037623, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Guayaquil, 22 de agosto del año 2025

Atentamente,



Jose Luis Maldonado Ortega

1105738395

DEDICATORIA

Dedico este trabajo a la memoria de mis amados padres,

Marianita de Jesús Vera Zambrano y William Bolívar Lindao Jordán,

quienes me guiaron con su amor, esfuerzo y ejemplo. Aunque ya no están a mi lado, su presencia vive en cada paso que doy. Este logro es también de ustedes, por todo lo que sembraron en mí. Que Dios los tenga en su gloria.

Y con especial gratitud y amor, a mi esposa

Daisy Katherine Paredes Delgado,

por su incondicional compañía, por creer en mí aun en los momentos más difíciles, por su paciencia, su amor y su fortaleza. Gracias por estar a mi lado en este camino que hoy se convierte en una meta cumplida.

A mis hijos,

Alanís, Valeria, Sofía, Esahi y Alahia.

fuerza de mi mayor inspiración y motivo de cada esfuerzo. Todo lo que hago es por y para ustedes, para que sepan que, con fe, perseverancia y trabajo, cualquier meta es posible.

Atentamente,

[Tony Lindo Vera]

DEDICATORIA

Dedico este trabajo a mis amados **padres**, mis pilares inquebrantables. Su fe incondicional y su amor inagotable han sido la luz que ha guiado cada uno de mis pasos. Este logro es, en gran parte, el fruto de su incansable apoyo y sus palabras de aliento, que han sido el motor de mi perseverancia.

A la **memoria de mis abuelos**, quienes desde el cielo me cobijan. Los valores y la resiliencia que sembraron en mí son el tesoro más grande que llevo en el alma, una inspiración eterna que me impulsa a ser mejor cada día.

A mis queridas **hermanas y cuñados**, por su compañía, sus consejos y por recordarme siempre que no estaba solo en este camino. Su apoyo ha sido un puerto seguro en la travesía.

Y a ti, mi **enamorada**, el amor de mi vida. Gracias por tu apoyo incondicional, por ser mi compañera, mi refugio y mi mayor impulso. Este logro también es tuyo, un testimonio de nuestro amor y de nuestra meta en común.

Atentamente,

[Saul Vallejo Yagual]

AGRADECIMIENTO

Agradezco en primer lugar a Dios, por darme la vida, la salud, la sabiduría y la fortaleza necesarias para culminar esta importante etapa de mi formación profesional.

A la memoria de mis padres, Marianita de Jesús Vera Zambrano y William Bolívar Lindao Jordán, quienes con su ejemplo de lucha, esfuerzo y amor dejaron una huella imborrable en mi vida. Este logro es también un homenaje a su legado.

A mi esposa, Daisy Katherine Paredes Delgado, por ser mi apoyo constante, por su paciencia, comprensión y por acompañarme con amor incondicional durante todo este proceso.

Agradezco de manera especial al Ing. José Luis Maldonado Ortega, mi tutor, por su guía, experiencia y dedicación durante el desarrollo de esta tesis. Su acompañamiento fue clave para alcanzar los objetivos de este trabajo académico.

Asimismo, expreso mi gratitud a los docentes y a la Universidad Politécnica Salesiana, por brindarme una formación integral y de calidad, así como a mis compañeros, familiares y amigos, quienes, con su apoyo moral y emocional, hicieron posible la culminación de esta meta.

Atentamente,

[Tony Lindo Vera]

AGRADECIMIENTO

Mi más profunda gratitud se eleva a Dios, por la vida, la fortaleza y por guiar cada uno de mis pasos hasta la culminación de esta importante etapa.

A la memoria de mis abuelos, a quienes dedico este logro con profundo cariño y respeto. Sus enseñanzas y valores sembraron en mí la semilla de la perseverancia y la convicción de nunca rendirme.

A mis padres, mis pilares inquebrantables, por su amor incondicional, su fe ciega en mis capacidades y su apoyo constante e incansable. Sus palabras de aliento fueron el motor que impulsó cada jornada y sin ellos, este proyecto no habría sido posible.

A mi enamorada, mi compañera incondicional, gracias por tu amor, tu paciencia y por ser mi motivación diaria. Siempre a mi lado, inspirándome a mejorar y a alcanzar cada meta que me propongo.

Un agradecimiento muy especial a mi tutor, el Ing. José Maldonado Ortega, por su invaluable guía, su experta dirección y su infinita paciencia. Su conocimiento, sus consejos oportunos y su constante apoyo fueron pilares fundamentales que aseguraron la correcta dirección y el éxito de este trabajo de titulación.

Finalmente, extendiendo mi sincero aprecio a la Universidad Politécnica Salesiana, por ser la institución que me abrió las puertas al conocimiento y me brindó una formación integral. Agradezco también a todos los profesores por compartir su sabiduría y experiencia, y a mis compañeros y amigos por el apoyo mutuo y la camaradería que hizo más ligero este camino.

Atentamente,

[Saul Vallejo Yagual]

ÍNDICE DE CONTENIDO

Resumen:	1
1. Introducción.....	1
2. Materiales y Métodos	3
2.1.Montaje experimental.....	3
2.2.Ubicación del sensor.....	4
2.2.1. Para la fijación.....	4
2.3.Configuración del microcontrolador ESP32.....	4
2.4.Protocolo de adquisición de datos	5
2.5 Programación de la red neuronal	5
2.6 Entrenamiento de red.....	6
2.7Pruebas en el banco Dynoshock	7
3. Resultados.....	7
3.1 Base de datos	7
3.2 Graficas de fuerza desplazamiento del Dynoshock	13
4. Discusión	15
5. Conclusiones.....	16
6. Apéndice A Código de entrenamiento de red neuronal	18
7. Apéndice b Graficas Dynoshock Fuerza/Desplazamiento.....	19
8. Referencias	19

Implementación de un sistema para la evaluación de amortiguadores de vehículos usando sensores IoT y modelos de redes LSTM

Tony Lindao Vera ¹, Saul Vallejo Yagual ² y Luis Maldonado ³

¹ Universidad Politécnica Salesiana; tlindaov@est.ups.edu.ec

² Universidad Politécnica Salesiana; svallejoy1@est.ups.edu.ec

³ Universidad Politécnica Salesiana; jmaldonado@est.ups.edu.ec

Resumen:

Esta investigación plantea el diseño y desarrollo de un sistema inteligente para la evaluación del estado de los amortiguadores en vehículos livianos, integrando avances tecnológicos recientes, como el Internet de las cosas (IoT) y modelos de redes neuronales del tipo Long Short-Term Memory (LSTM). Esta estructura se basa en la captación de datos dinámicos provenientes de sensores inerciales, capaces de registrar variables críticas como la aceleración vertical, las frecuencias de vibración y los desplazamientos dinámicos del chasis durante la conducción. Con datos transmitidos en tiempo real a una plataforma, un servidor por medio del protocolo de comunicación MQTT, y almacenados en bases de datos NoSQL optimizada para series temporales. A continuación, se realizó un proceso de preprocesamiento que incluye la limpieza, normalización y segmentación de los datos, para garantizar su calidad antes de ser introducidos en el modelo de inteligencia artificial. Posteriormente, se desarrolló y entrenó una red LSTM con el fin de identificar patrones en los datos secuenciales y predecir comportamientos anómalos que podrían indicar desgaste o fallos de los amortiguadores. Finalmente, el modelo entrenado se integra en una plataforma de monitoreo en tiempo real con un porcentaje de eficiencia del 99% de eficiencia, considerando que se evalúan varios subconjuntos de datos para obtener la condición del amortiguador. Este enfoque no solo se basa en seguridad y el rendimiento del vehículo, sino que también optimiza los costos operativos que contribuye a la digitalización del mantenimiento automotriz.

Palabras clave: Amortiguadores, Internet de las Cosas (IoT), redes neuronales LSTM, sensores inerciales, preprocesamiento de datos, MQTT, mantenimiento predictivo.

Abstract: This research proposes the design and development of an intelligent system for assessing the condition of shock absorbers in light vehicles, integrating recent technological advances such as the Internet of Things (IoT) and Long Short-Term Memory (LSTM) neural network models. This structure is based on the capture of dynamic data from inertial sensors, capable of recording critical variables such as vertical acceleration, vibration frequencies, and dynamic chassis displacements during driving. The data is transmitted in real time to a platform, a server, via the MQTT communication protocol and stored in NoSQL databases optimized for time series. A preprocessing process was then performed, including data cleaning, normalization, and segmentation, to ensure data quality before being entered into the artificial intelligence model. An LSTM network was subsequently developed and trained to identify patterns in the sequential data and predict anomalous behaviors that could indicate shock absorber wear or failure. Finally, the trained model is integrated into a real-time monitoring platform, achieving a 99% efficiency rate, considering that multiple data subsets are evaluated to determine the shock absorber's condition. This approach not only enhances vehicle safety and performance but also optimizes operating costs, contributing to the digitalization of automotive maintenance.

Keywords: Shock absorbers, Internet of Things (IoT), LSTM neural networks, inertial sensors, data preprocessing, MQTT, predictive maintenance.

Citation: To be added by editorial staff during production.

Academic Editor: Firstname Lastname

Received: date

Revised: date

Accepted: date

Published: date



Copyright: © 2023 por los autores.

Presentado para su posible publicación en acceso abierto bajo los términos y condiciones de Creative Commons Attribution license.

1. Introducción

El sistema de amortiguación es una parte fundamental en cualquier vehículo, ya que afecta en forma directa en la seguridad, el confort y el desempeño durante la conducción. Su principal objetivo es reducir las vibraciones y movimientos que se generan cuando el

vehículo pasa por irregularidades en la calzada, como baches, grietas o desniveles [1]. Gracias a esto, las ruedas mantienen un contacto constante y firme con la carretera, lo que es esencial para que el vehículo sea estable, cómodo y tenga una buena tracción. Cuando este sistema falla o está deteriorado, el conductor puede perder el control fácilmente, aumentando el riesgo de accidentes, sobre todo en situaciones delicadas como curvas cerradas, frenadas repentinas o maniobras para evitar obstáculos.

Muchos estudios han demostrado que un mantenimiento inadecuado de la suspensión esencialmente en los amortiguadores puede afectar gravemente en la maniobrabilidad del vehículo. En [1] resalta que no cuidar estos componentes a tiempo puede hacer que el vehículo responda peor en situaciones complicadas, aumentando las posibilidades de accidente. Además, en [2] advierten que cuando los amortiguadores se desgastan, la distancia de frenado puede aumentar hasta en un 23% en vehículos con sistemas ABS, y hasta en un 30% cuando el desgaste es severo. Esto no solo pone en riesgo la seguridad, sino que también reduce la confianza del conductor para reaccionar ante imprevistos.

El desgaste del sistema de suspensión suele ser un proceso lento y silencioso, por lo que muchas veces pasa desapercibido para el conductor. En [3] se menciona, aunque a simple vista no se identifique el daño, este puede afectar seriamente la estabilidad y el comportamiento del vehículo, si no se detecta a tiempo con métodos de diagnóstico confiables. Además, la suspensión está expuesta a factores externos como terrenos difíciles, sobrecargas y uso prolongado, que aceleran su deterioro.

No solo afecta la comodidad, sino que las fallas en la suspensión son una causa importante de accidentes. Estudios recientes muestran que un desgaste incluso moderado en los amortiguadores puede provocar situaciones peligrosas, como sobreviraje o subviraje, especialmente durante maniobras bruscas o cuando el piso está resbaloso [4]. En Ecuador, [5] reportó que una gran parte de los accidentes se relaciona con fallas mecánicas prevenibles, siendo la suspensión uno de los sistemas más críticos.

Diagnosticar estas fallas a tiempo es complicado debido a las limitaciones que tienen los métodos tradicionales, como la inspección visual o la prueba de rebote, dependen mucho de la experiencia del técnico y tienen limitaciones en precisión y continuidad como lo menciona [6,7] la falta de herramientas automáticas para monitorear la suspensión hace que sea difícil detectar fallas a tiempo, lo que puede provocar intervenciones tardías y riesgos evitables. Además, los equipos especializados como bancos hidráulicos o simuladores suelen ser muy costosos, lo que limita su uso en talleres pequeños, escuelas o técnicos independientes. Estos equipos requieren inversiones altas, espacios adecuados y personal capacitado, lo que dificulta su aplicación frecuente.

La introducción del Internet de las Cosas (IoT) ha permitido colocar sensores inteligentes en partes clave del vehículo, como acelerómetros y giroscopios, para captar datos en tiempo real sobre aceleraciones, cargas y vibraciones. En [8] explican que estas tecnologías crean un entorno conectado que facilita diagnósticos digitales automáticos y continuos. El [9] demostraron que sensores MEMS como el MPU6050 son muy sensibles para detectar micro vibraciones, convirtiéndose en una herramienta económica, no invasiva y eficaz para evaluar amortiguadores sin desmontarlos, facilitando su integración en sistemas inteligentes de monitoreo vehicular.

Para analizar las señales generadas por estos sensores, las redes neuronales LSTM son especialmente útiles, pues pueden detectar patrones no lineales y predecir fallas con alta confianza. Crearon un modelo LSTM que detecta fallas mecánicas anticipadamente en ambientes industriales, permitiendo evaluaciones constantes y detalladas del estado del sistema de suspensión [10].

En este escenario, la implementación del mantenimiento predictivo representa una estrategia de optimización. Esta técnica se fundamenta en la recolección y el análisis ininterrumpido de datos en tiempo real para determinar fallas antes de que se presente físicamente. Así, se optimizan los tiempos de reparación y se reducen costos con el uso de redes neuronales LSTM que analiza datos secuenciales de sensores instalados en vehículos,

logrando predecir fallas mecánicas con más del 95% de precisión, lo que representa un avance significativo en el diagnóstico automatizado [11].

Finalmente, la combinación de sensores inteligentes y redes LSTM ha dado lugar a nuevas herramientas automatizadas para el diagnóstico. Estas no solo detectan fallas, sino que también analizan sus causas de fondo. En [12] proponen una arquitectura donde los vehículos envían su estado en tiempo real a plataformas en la nube, facilitando el mantenimiento remoto y eficiente. Este enfoque innovador es accesible y práctico para superar barreras económicas y técnicas en talleres y profesionales automotrices, mejorando así la seguridad vial y el rendimiento de los vehículos.

En este estudio se plantea el desarrollo y la ejecución de un sistema inteligente para evaluar la condición del estado de amortiguadores de vehículos livianos, integrando sensores IoT, procesamiento de señales y modelos de redes neuronales LSTM. El montaje experimental se realizó mediante la instalación de dos sensores inerciales MPU6050 en las torres de los amortiguadores delanteros, conectados a un microcontrolador ESP32. La comunicación se estableció mediante protocolo I2C, y los datos de aceleración en tres ejes fueron adquiridos en tiempo real, filtrados para reducción de ruido y enviados vía Wi-Fi a un banco de datos almacenada en la nube (Firebase) y con estos datos se entrenó la red del sistema.

2. Materiales y Métodos

2.1. Montaje experimental

Se desarrollo un sistema inteligente para revisar amortiguadores de vehículos usando dispositivos IoT, procesamiento de datos y algoritmos de IA para un diagnóstico predictivo. Las pruebas dinámicas se realizaron con dos ocupantes a bordo (aproximadamente 140-160 kg de carga adicional), lo cual representa una condición intermedia de uso realista sin sobrecargar el sistema de suspensión. Se ha definido una velocidad alrededor de 50 km/h, seleccionada como valor de referencia ya que el límite permitido por la Agencia Nacional de Tránsito que es el ente regulador establece que el límite de velocidad en áreas urbanas.

En la Figura 1 se indica el montaje experimental, que se realizó mediante el uso de dos sensores inerciales MPU6050 que se conectaron con el protocolo I2C a un microcontrolador ESP 32, para la adquisición y almacenamiento de los datos en la nube (Firebase) con conexión WiFi, estos datos posteriormente se usaron para crear una red neuronal que determine el estado de los amortiguadores.




Figura 1. Montaje experimental para pruebas.

El MPU6050 fue seleccionado por sus características adecuadas para registrar vibraciones estructurales y dinámicas en sistemas automotrices y destaca por tener las siguientes características:

- Acelerómetro y giróscopo de tres ejes.
- Alta sensibilidad y resolución de 16 bits.
- Comunicación mediante protocolo I2C.

- Tamaño compacto, mínimo consumo y la fácil integración con microcontroladores del ESP32.

Estas características lo convierten en una solución eficaz y económica para proyectos de monitoreo de vibraciones en tiempo real.

2.2. Ubicación del sensor

El sensor MPU6050 fue fijado directamente sobre la torre del amortiguador, zona que representa una ubicación estratégica para registrar las vibraciones verticales transmitidas por el chasis y directamente relacionadas con el estado del sistema de suspensión. Esta ubicación ofrece las siguientes ventajas:

- Acceso directo a las oscilaciones estructurales.
- Facilidad de fijación sin interferir con partes móviles.
- Repetibilidad de datos al estar en un punto fijo y sólido

2.2.1. Para la fijación

Se utilizó dos imanes de neodimio para la fijación de los sensores y para evitar daños se los encapsulo dentro de una carcasa como se observa en la Figura 2.



Figura 2. (a) Acelerómetro en torre izquierda (b) Acelerómetro en torre derecha.

La posición de los sensores influye en la determinación de las fuerzas que actúan sobre el amortiguador, para este caso de estudio se ubicó los sensores como están en la Figura 3 indica la fuerza vertical en el eje, la fuerza lateral en el eje X, la fuerza longitudinal en el eje Z.



Figura 3. Representación gráfica de amortiguador con sus ejes

2.3. Configuración del microcontrolador ESP32

Una vez realizada las conexiones con los dos acelerómetros se procede a configurar con ayuda de Python para la recopilación de los datos con el microcontrolador ESP32. El código que se empleo fue para lo siguiente:

- Leer datos en tiempo real del sensor MPU6050 vía I2C.
- Configurar la dirección I2C predeterminada (0x68) del sensor.
- Establecer un patrón de muestreo de 100 Hz.
- Procesar los datos con un supresor de media móvil para disminuir ruido.
- Enviar los datos a Firebase usando conectividad Wi-Fi.

El desarrollo se encuentra en el Apéndice A.

Como resultado de la adquisición se obtiene los datos en el firebase los cuales se procesan para obtener el valor de fuerza G utilizando la ecuación 1

$$Fuerza G = \frac{Valor\ del\ sensor}{32768 * 2} \quad (1)$$

2.4. Protocolo de adquisición de datos

El flujograma de pruebas se detalla en la Figura 4. El primer paso es verificar las conexiones de los sensores, los cuales son instalados en las torres de los amortiguadores. A continuación, se verifica que la presión de los neumáticos sea la correcta ajustada a 31 PSI. Para la recolección de datos, se utilizaron amortiguadores nuevos, cuyos datos fueron procesados y cargados en el base de datos (Firebase). Este proceso se repite para cada caso.

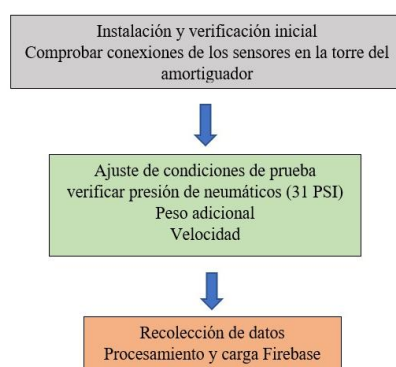


Figura 4. Flujograma de adquisición de datos.

Tras la adquisición de los datos, se realizó la etiquetación a cada conjunto según el estado real del amortiguador. Para ello, se realizaron 15 corridas en cada una de las condiciones operativas: bueno, regular y malo sumando un total de 45 corridas.

Las pruebas se realizaron en las instalaciones de la Universidad Politécnica Salesiana, sede Guayaquil donde, se colocó obstáculos para simular las irregularidades de la calzada y rompe velocidades, esto con el fin de obtener un circuito controlado que simule el comportamiento real.

2.5 Programación de la red neuronal

Para el estudio, se empleó un modelo de red neuronal Bidireccional LSTM conformado por 10 capas. La arquitectura diseñada resultó robusta, integrando dos capas LSTM bidireccionales capaces de capturar patrones tanto en la dirección hacia adelante como hacia atrás de las secuencias temporales, lo que permitió un aprendizaje más profundo de las dependencias contextuales. Además, se incorporaron un par de capas de normalización para estabilizar el entrenamiento y acelerar la convergencia, junto con tres capas de Dropout estratégicamente ubicadas con el fin de reducir el sobreajuste y mejorar la capacidad de generalización del modelo. A esto se añadió una capa densa oculta con la función de activación LeakyReLU, la cual favorece un mejor flujo de gradientes al evitar la saturación en valores negativos. Finalmente, se implementó una capa de salida con activación Softmax, encargada de proporcionar la clasificación final en las diferentes categorías definidas para la clasificación final. Cada bloque de memoria LSTM, como se muestra en la Figura 5, consta de lo siguiente:

- Una célula de memoria, que mantiene su estado a lo largo del tiempo.
- Una puerta de entrada, que controla qué información nueva debe agregarse.
- Una puerta de olvido, que restablece la memoria cuando es necesario.
- Una puerta de salida, que determina qué parte de la memoria debe emitirse.

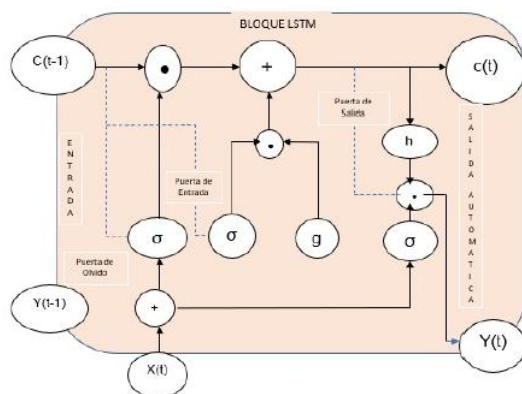


Figura 5. Bloque de memoria LSTM

Para la preparación de la red neuronal su uso un método estricto para garantizar la precisión de los resultados. En primer lugar, se accedió al banco de datos de Firebase donde previamente se tiene el código para la recolección de datos. Esta data fue sometida a un proceso de limpieza y preparación detallado para poder entrenar el modelo LSTM.

Se estructuró un código mediante Python el código completo se muestra en el apéndice A, para analizar los patrones de los sensores y poder clasificar el amortiguador, la red neuronal se procesa los datos y crea un modelo que puede clasificar el estado del amortiguador, diferenciando entre las categorías "bueno", "regular" y "malo".

2.6 Entrenamiento de red

Para entrenar la red, se emplearon 2,700 datos, que se dividieron entre 900 datos buenos, regular y malos un volumen suficiente para que el modelo pudiera reconocer las características específicas de cada condición del amortiguador. Este proceso se ejecutó en Google Colab, un ambiente de desarrollo en la nube que proporcionó los recursos computacionales necesarios.

El modelo de red neuronal LSTM se diseñó con una arquitectura basada en capas recurrentes, que procesan la información de los sensores. Los datos fueron divididos en tres subconjuntos: entrenamiento (70 %), validación (15 %) y prueba (15 %). Durante la etapa de entrenamiento, se aplicaron funciones de pérdida apropiadas para la detección de patrones y se ajustaron parámetros configurables, como la cantidad de neuronas, las unidades por capa, la tasa de aprendizaje y el número de épocas.

El proceso metodológico empieza importando los datos en formato .xlsx. Se procedió a aplicar pasos de preprocesamiento,

- Los valores infinitos fueron reemplazados por valores nulos y se eliminaron los registros incompletos.
- Se filtraron los datos considerando únicamente las tres clases de interés.
- Las variables fueron normalizadas en un rango de 0 a 1 mediante la técnica MinMaxScaler.

La información se organizó en secuencias temporales de 50 pasos para cada clase. Una vez completado el preprocesamiento, el conjunto de datos se dividió en dos subconjuntos: el 80 % para el entrenamiento del modelo y el 20 % restante para su validación y prueba.

Para que el modelo funcionara de forma eficiente, se optimizó con el algoritmo Adam y se utilizó la función de pérdida categorical crossentropy. Además, se aplicó dos técnicas clave: Early Stopping y una reducción adaptativa de la tasa de aprendizaje, lo que nos ayudó a mejorar su rendimiento y eficiencia.

Se aseguró, que el modelo era fiable, evaluando su desempeño con métricas como la exactitud (accuracy), la matriz de confusión y las curvas de precisión/pérdida. Se estructuró un código mediante Python el código completo se muestra en el Apéndice A, para

analizar los patrones de los sensores y poder clasificar el amortiguador, la red neuronal se procesa los datos y crea un modelo que puede clasificar el estado del amortiguador, diferenciando entre las categorías "bueno", "regular" y "malo".

2.7 Pruebas en el banco Dynoshock

Como se muestra en la figura 6, la pantalla principal del software Dynoshock dispone tres pruebas a velocidad variable, prueba a velocidad constante y prueba averiguación rápida, para el caso de estudio la prueba de velocidad variable.




Figura 6. Pantalla principal software dynoshock.

Al finalizar la prueba se obtiene la gráfica de la Figura 7 que representa el diagrama de fuerza/desplazamiento, se puede identificar lo que corresponde al punto muerto superior (PMS) del desplazamiento, el punto muerto inferior (PMI), máxima velocidad en compresión (MCC) y la máxima velocidad expansión (MCE)

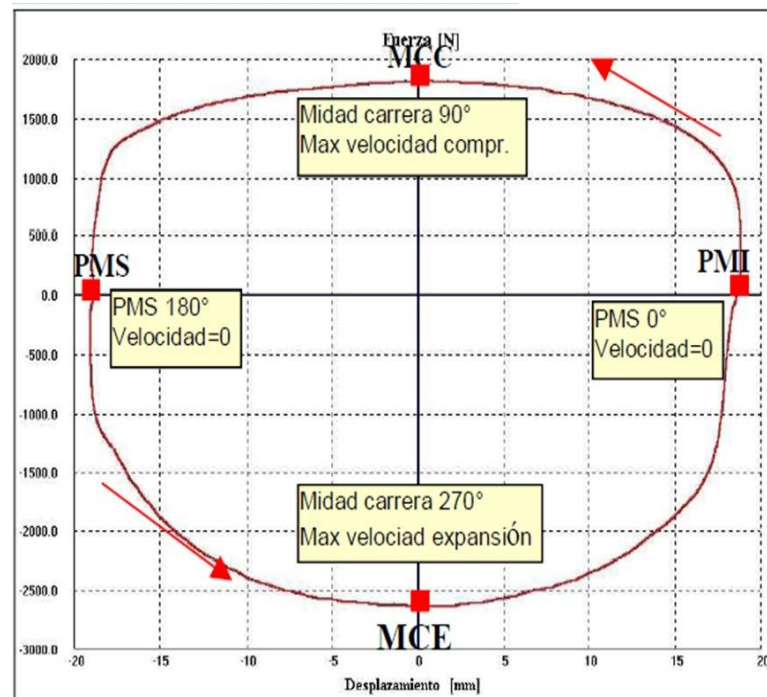


Figura 7. Diagrama de Fuerza/Desplazamiento prueba a velocidad constante (1 ciclo)

3. Resultados

3.1 Base de datos

Los datos adquiridos por los sensores inerciales, mediante el uso de la Ecuación 1 se transformó a unidad de aceleración gravitacional (G) para su debida interpretación. Se realizó un muestreo de 60 datos por cada condición a evaluar. En las gráficas recopiladas se observa que, a medida que el amortiguador pierde su capacidad absorber las irregularidades de controlar el movimiento de la carrocería, reducir el rebote y mantener el contacto

de los neumáticos con la superficie, la amplitud de los picos de aceleración aumenta de forma significativa.

En la Tabla 1 se muestra la señal del sensor inercial correspondiente al eje x que representa el esfuerzo lateral, estos datos miden el movimiento y vibraciones originado en el plano horizontal producto de tomar una curva o recibir un impacto de un costado.

Tabla 1. Muestreo del sensor inercial en el eje X

Sensor	Tiempo (s)	MPU 6050	Fuerza G
Bueno	1	0	0
	2	336	0,02050781
	3	784	0,04785156
	4	4168	0,25439453
	5	-3556	-0,21704102
Regular	1	80	0,00488281
	2	-788	-0,0480957
	3	-2918	-0,17810059
	4	1678	0,10241699
	5	-4488	-0,27392578
Malo	1	160	0,00976563
	2	-1912	-0,11669922
	3	-6620	-0,40405273
	4	-812	-0,04956055
	5	-5420	-0,33081055

Con los datos obtenidos, se procede a graficar y analizar el comportamiento de cada uno de los amortiguadores. El comportamiento del amortiguador en buen estado se aprecia en la Figura 8 (a), en la Figura 8 (b) se puede observar que el amortiguador estado regular tiene un incremento de la amplitud de la fuerza G, a comparación del amortiguador en mal estado que la amplitud de la fuerza es superior a las anteriores como se muestra en la Figura 8 (c).




Figura 8. Graficas Fuerza G vs Tiempo (a) señal de sensor en buen estado eje X. (b) Señal de sensor estado regular eje X. (c) Señal de sensor en mal estado eje X.

La Figura 9 ilustra la respuesta de la fuerza G en el eje X a lo largo del tiempo para las tres condiciones de prueba del amortiguador: "**BUENO**", "**REGULAR**" y "**MALO**". Como se observa en la gráfica, el amortiguador en condición "**BUENO**" (línea naranja) exhibe una respuesta más estable y controlada, con amplitudes de oscilación menores y más consistentes. En contraste, las condiciones "**REGULAR**" (línea gris) y "**MALO**" (línea azul) muestran una mayor variabilidad y picos de fuerza G más pronunciados, indicando una menor capacidad de absorción de impactos. Notablemente, la condición

"MALO" presenta las mayores amplitudes negativas, sugiriendo una deficiencia significativa en el desempeño del amortiguador.




Figura 9. Grafica Fuerza G vs Tiempo de las señales del sensor 1 en eje X

En el eje Y se representa la correlación de las vibraciones longitudinales generadas por los esfuerzos de frenado o aceleración. Tal como se demuestra en la Tabla 2, los datos obtenidos reflejan valores tanto negativos como positivos, lo que indica la dirección de las fuerzas ejecutadas sobre el vehículo.

Tabla 2. Muestreo de eje Y

Estado	Tiempo (s)	MPU 6050	Fuerza G
Bueno	1	0	0
	2	1748	0,10668945
	3	3436	0,2097168
	4	3732	0,2277832
	5	3356	0,20483398
Regular	1	352	0,02148438
	2	596	0,03637695
	3	3008	0,18359375
	4	4054	0,24743652
	5	3606	0,22009277
Malo	1	0	0
	2	704	0,04296875
	3	-556	-0,03393555
	4	2580	0,1574707
	5	4376	0,26708984

La Figura 10 ilustra el comportamiento de los amortiguadores en el eje Y, el cual está relacionado con su nivel de desgaste. La Figura 10 (a) presenta la respuesta de un amortiguador en buen estado, mostrando una amplitud de oscilación relativamente baja y estable. La Figura 10 (b) corresponde a un amortiguador en estado regular, donde se evidencia una mayor amplitud en los picos de Fuerza G, lo que indica un deterioro en su capacidad de amortiguación. La Figura 10 (c) muestra un amortiguador en mal estado, que exhibe una respuesta menos controlada, con oscilaciones más erráticas, lo que representa una deficiencia significativa en su desempeño.




Figura 10. Graficas Fuerza G vs Tiempo (a) señal de sensor en buen estado eje Y. (b) Señal de sensor estado regular eje Y. (c) Señal de sensor en mal estado eje Y.

La Figura 11 ilustra la respuesta de los amortiguadores en el eje Y para cada uno de los tres estados analizados. Se evidencia que la amplitud de la fuerza G aumenta considerablemente con el desgaste del componente. Esto es crítico, ya que los esfuerzos longitudinales generados por la aceleración y el frenado se manejan de forma menos controlada. Por lo tanto, el deterioro del amortiguador afecta negativamente la estabilidad direccional del vehículo.




Figura 11. Grafica Fuerza G vs Tiempo de las señales del sensor 1 en eje Y.

La Tabla 3 representa los resultados adquiridos sobre el eje Z, los cual se observa el esfuerzo vertical. Estos valores permiten analizar de manera directa la capacidad del amortiguador para disipar la energía producida por impactos y baches, lo que es fundamental para determinar su efectividad.

Tabla 3. Muestreo de eje Z

Estado	Tiempo (s)	MPU 6050	Fuerza G
Bueno	1	0	0
	2	17560	1,07177734
	3	14348	0,87573242
	4	17648	1,07714844
	5	21108	1,28833008
Regular	1	8132	0,49633789
	2	17018	1,03869629
	3	16706	1,01965332
	4	17980	1,09741211
	5	20570	1,25549316
Malo	1	0	0
	2	16264	0,99267578
	3	16476	1,00561523
	4	19064	1,16357422
	5	18312	1,11767578

En la Figura 12 se presenta el esfuerzo vertical que cada amortiguador soporta. La Figura 12 (a) muestra una señal uniforme y de baja amplitud, caracteriza un amortiguador

en buen estado, el cual absorbe eficientemente las fuerzas verticales del terreno. En la Figura 12 (b), la señal exhibe una amplitud más alta y errática, indicando un estado regular o de desgaste moderado, donde la capacidad de amortiguación ha comenzado a disminuir, la Figura 12 (c) representa una condición de falla avanzada, con picos de amplitud significativamente más altos que demuestran la incapacidad del amortiguador para mitigar las fuerzas. Esta variación es un indicador directo de la eficiencia con la que el amortiguador absorbe o transmite las fuerzas del terreno. Por esta razón, este eje es considerado el más crítico para evaluar el desempeño general del componente.




Figura 12. Gráficas Fuerza G vs Tiempo (a) señal de sensor en buen estado eje Z. (b) Señal de sensor estado regular eje Z. (c) Señal de sensor en mal estado eje Z.

La Figura 13 indica el comportamiento del amortiguador en el eje Z que es el eje principal para la evaluación del estado del amortiguador.

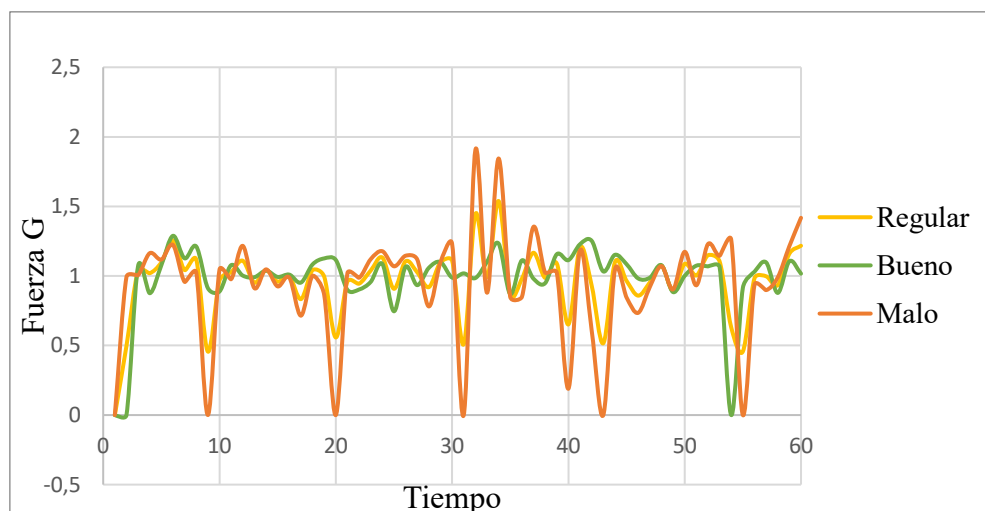


Figura 13. Grafica Fuerza G vs Tiempo de la señal de sensor 1 en eje Z.

3.1 Red Neuronal

El modelo de red neuronal LSTM, entrenado con estas señales, clasificó de manera exitosa las tres condiciones, lo que demuestra la viabilidad del sistema como una herramienta de diagnóstico predictivo para el mantenimiento vehicular.

La evaluación del modelo se basó en métricas de clasificación, presentando en la Tabla 4 y en la Figura 14 respectivamente. Dicho reporte detalla, para cada clase (0, 1 y 2), los valores de precisión, exhaustividad (recall) y puntaje *f1-score*.

La precisión estima el porcentaje de predicciones correctas dentro de las instancias asignadas a una clase, mientras que la exhaustividad o recall determina la proporción de instancias reales de una clase que fueron correctamente identificadas. El puntaje *f1-score* es el promedio conforme a la exactitud y la exhaustividad, ofreciendo un valor equilibrado

cuando ambas métricas son importantes. El parámetro *support* especifica el número de muestras reales por cada clase en el grupo de prueba.

Según los resultados del reporte de clasificación Tabla 4 el modelo mostró un rendimiento perfecto en el conjunto de prueba, ya que todas las clases obtuvieron valores de precisión, exhaustividad y puntaje F1 de 1.00. Además, la exactitud global *accuracy* también alcanzó el 100%, confirmando que todas las predicciones coincidieron con las etiquetas reales.

Tabla 4. Reporte de clasificación

	Precisión	recall	F1-score	Support
0	1.00	1.00	1.00	173
1	1.00	1.00	1.00	173
2	1.00	1.00	1.00	165
Accuracy			1.00	511
Marco avg	1.00	1.00	1.00	511
Weighted avg	1.00	1.00	1.00	511

En la Figura 14 se aprecia la matriz de confusión, dispuesta en una estructura de 3×3, permite visualizar la distribución de aciertos y errores para cada clase. La diagonal principal contiene los casos correctamente clasificados: 173 situaciones para la clase 0, 173 para la clase 1 y 165 para la clase 2. Las celdas fuera de la diagonal presentan valor cero, lo que indica la ausencia total de confusiones entre clases y un desempeño perfecto del modelo en el conjunto evaluado.

En este escenario, la precisión indica la proporción de instancias correctamente clasificadas dentro del total de predicciones asignadas a una clase específica, mientras que la exhaustividad (*recall*) cuantifica la proporción de instancias correctamente identificadas dentro del conjunto real de dicha clase. El puntaje f1-score corresponde a la media armónica entre la precisión y la exhaustividad, proporcionando un indicador balanceado del rendimiento cuando ambas métricas tienen igual relevancia. El parámetro *support* representa el número total de muestras reales por clase en el conjunto de evaluación.

De acuerdo con los resultados, todas las clases alcanzaron valores de precisión, exhaustividad y puntaje F1 iguales a 1,00, lo que evidencia un rendimiento perfecto del modelo sobre el conjunto de prueba. La exactitud global (*accuracy*) también alcanzó el 100 %, confirmando que la totalidad de las predicciones coincidió con las etiquetas reales, sin errores de clasificación.




Figura 14. Matriz de confusión

3.2 Graficas de fuerza desplazamiento del Dynoshock

Los resultados del caso de un amortiguador en buen estado, el ciclo de histéresis fuerza–desplazamiento muestra una forma elíptica bien definida, con fuerzas máximas estables de alrededor de 35 kg y una relación compresión–extensión simétrica lo que indica un comportamiento normal de un amortiguador en óptimas condiciones. Como lo evidencia en la Figura 15.

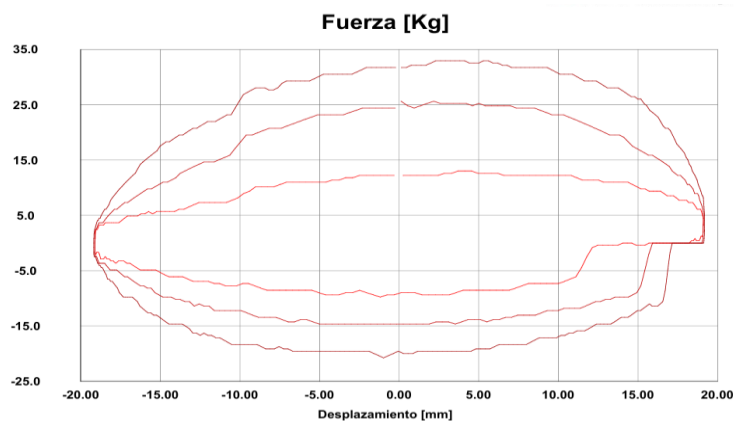


Figura 15. Fuerza (kg) vs Desplazamiento (Bueno)

En el caso del amortiguador regular, la curva del DynoShock ya no mantiene una forma elíptica debido a que se reduce la amplitud 15 kg con lo cual la curva se convierte en asimétrica. Ver figura 16.




Figura 16. Fuerza (kg) vs Desplazamiento (Regular)

Por otro lado, cuando el amortiguador está en mal estado, el gráfico de DynoShock muestra un patrón errático, caracterizado por una disminución de fuerzas a 8 kg máximas y la pérdida de la histéresis típica. Como muestra la Figura 17

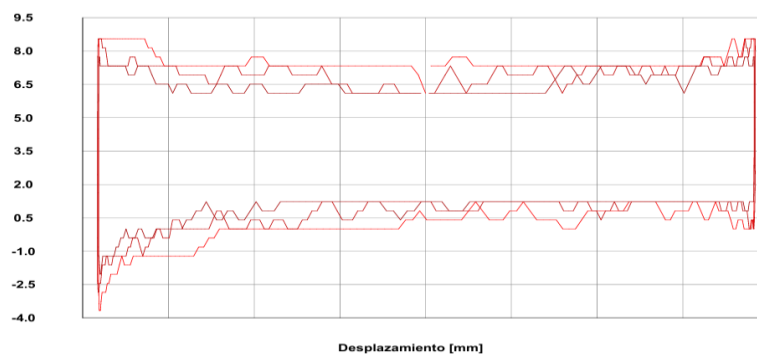


Figura 17. Fuerza (Kg) vs Desplazamiento (Malo)

La Tabla 5 muestra que, a medida que el amortiguador se deteriora, existe una disminución de la fuerza máxima, por otro lado, la forma de histéresis pierde simetría, las

vibraciones aumentan en amplitud y frecuencia. Un amortiguador en buen estado mantiene fuerza alta y estable, histéresis definida y bajas vibraciones; en estado regular presenta pérdida parcial de capacidad; y en mal estado pierde gran parte de la amortiguación, transmitiendo vibraciones excesivas.

Tabla 5. Tabla comparativa entre datos obtenidos de sensores inerciales y dynoshock

Condición	Fuerza máx. DynoShock (kg)	Forma de histéresis	Amplitud máx. picos (G)	Rango de frecuencia dominante (Hz)	Observaciones clave
Bueno	35	Elíptica bien definida	$\leq 1,2$ G	10–12 Hz	Absorción óptima de vibraciones, simetría compresión–extensión
Regular	15	Elíptica con ligera asimetría	1,5–2,0 G	12–15 Hz	Parte de la vibración se transmite al chasis, pérdida parcial de capacidad
Malo	8	Irregular, pérdida de forma	$> 2,0$ G	15–20 Hz	Alta transmisión de vibraciones, pérdida significativa de amortiguación

Para los tres estados de evaluación el modelo logró una clasificación perfecta (accuracy 100%). Los resultados confirman que la combinación de censado IoT, análisis frecuencial y clasificación automática mediante LSTM permite un diagnóstico predictivo preciso y de bajo costo, aplicable en tiempo real. El sistema propuesto es escalable a flotas vehiculares y puede integrarse en plataformas de mantenimiento predictivo, contribuyendo a mejorar la seguridad, el confort y la eficiencia operativa

Los resultados obtenidos a través de un limitado muestreo y pruebas realizadas exclusivamente en un solo tipo de vehículo, bajo condiciones controladas y sin variaciones significativas de temperatura, humedad o estado del pavimento. Por tanto, la capacidad predictiva del modelo podría variar frente a condiciones ambientales extremas o en vehículos con configuraciones de suspensión diferentes

Para la validación del sistema, se seleccionó de manera aleatoria un conjunto de datos correspondiente a un amortiguador nuevo para evaluar la capacidad del modelo para clasificar correctamente su estado operativo. Estos datos fueron procesados siguiendo el mismo flujo de preprocesamiento y secuenciado aplicado durante el entrenamiento.

Posteriormente, se obtuvieron las predicciones del modelo y se construyó la matriz de confusión, como se ilustra en la Figura 18 la cual permitió contrastar las etiquetas reales con las estimadas. El resultado evidenció que el sistema identificó de forma consistente la condición "bueno" del amortiguador, lo que confirma su capacidad para reconocer patrones asociados a un componente en óptimo estado y, por ende, su correcto funcionamiento bajo condiciones reales de operación.

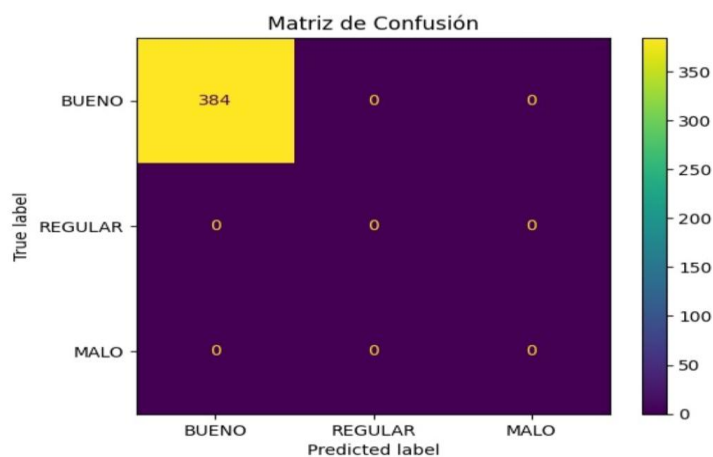


Figura 18. Matriz de confusión con datos aleatorios

4. Discusión

Las mediciones dinámicas realizadas con el ESP32 permitieron caracterizar el comportamiento de los amortiguadores en distintos estados (Figura 19); en condiciones óptimas se registraron valores de aceleración relativamente constantes, con picos que rara vez superaron 1,2 G, lo que evidencia una adecuada absorción de vibraciones.

En el estado intermedio, los registros mostraron fluctuaciones más pronunciadas, con picos recurrentes entre 1,5 G y 2,0 G, lo que indica que parte de la energía vibratoria es transmitida al chasis.

En la condición deficiente se observaron oscilaciones constantes con picos superiores a 2,0 G, acompañados de incrementos de más del 30% en la energía espectral dentro del rango de 10 a 20 Hz, lo que confirma una baja capacidad de amortiguación y una elevada transmisión de vibraciones al chasis. Estos resultados están en concordancia con estudios previos realizados en [13,14] que detallan valores similares




Figura 19. Gráfica de señal de sensor 1 en eje Z.

En las pruebas realizadas con el banco DynoShock se identificaron curvas de histéresis con morfología elíptica, propias de un comportamiento funcional, aunque en la condición clasificada como “regular” se evidenció una reducción en la magnitud de la fuerza y una ligera asimetría entre las fases de compresión y extensión, lo que sugiere la presencia de desgaste interno y una pérdida progresiva de eficiencia energética, esto se puede observar en la Figura 20.

En la condición “deficiente”, la curva de histéresis perdió su forma característica, presentando amplitudes de fuerza significativamente inferiores a los valores de referencia y discontinuidades atribuibles a la degradación del fluido hidráulico o a fallos en el sistema de válvulas internas. De manera complementaria, las mediciones dinámicas obtenidas con el sistema IoT basado en ESP32 mostraron un comportamiento concordante con los ensayos estáticos: en estado adecuado, las aceleraciones oscilaron de manera estable entre 1 y 1,5 g; en condición regular se registraron picos recurrentes de 1,5 a 2 g; mientras que en estado deficiente se observaron oscilaciones superiores a 2 g, evidenciando un aumento considerable en la transmisión de vibraciones al chasis.

En conjunto, estos hallazgos confirman la utilidad de la integración de pruebas estáticas y dinámicas como una estrategia complementaria para el diagnóstico del estado real de los sistemas de suspensión, permitiendo correlacionar el deterioro estructural del amortiguador con su capacidad de disipación de energía y con los niveles de confort y seguridad vehicular.

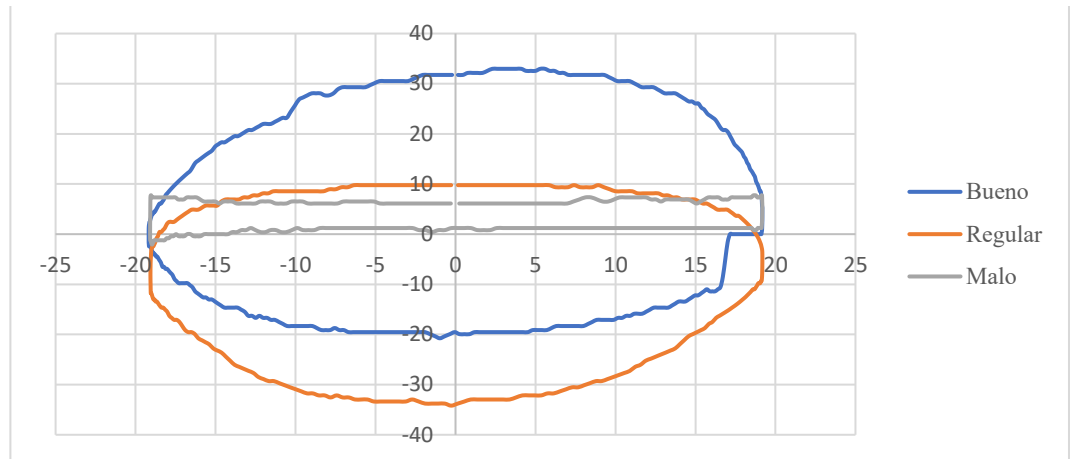


Figura 20. Gráfica de fuerza desplazamiento

Los valores obtenidos en este estudio muestran una gran concordancia con los datos analizados. Para los amortiguadores en buen estado, el banco DynoShock registró una fuerza máxima de compresión de 330 kgf (aproximadamente 3237 N) y una fuerza máxima de extensión cercana a los 3000 N.

Esto resultó en una simetría compresión-extensión del 92%. Si bien estos valores son un poco más altos que el rango típico para amortiguadores nuevos (1500–2500 N en compresión), esto podría ser atribuido a las características particulares del modelo probado o a variaciones en la calibración del equipo de medición.

En el caso del estado regular, las fuerzas medidas evidencian una pérdida moderada de la capacidad de amortiguación, con una reducción del 30% en comparación con el estado "bueno" y una menor simetría compresión-extensión, lo que concuerda con los patrones observados en investigaciones anteriores.

Se puede apreciar fuerzas máximas se situaron por debajo de los 900 N, con una marcada pérdida de forma en el ciclo de histéresis y un incremento en la amplitud de las vibraciones registradas, lo que concuerda con el comportamiento típico de amortiguadores con desgaste severo. Esta validación comparativa respalda la fiabilidad del sistema de medición propuesto y confirma su capacidad para diagnosticar con precisión el estado del sistema de suspensión.

5. Conclusiones

El sistema propuesto posee la capacidad de evaluar el estado de amortiguadores y catalogarlos como bueno regular y malo, con una precisión superior al 95% la cual lo convierte en una herramienta eficaz para el diagnóstico preventivo de amortiguadores. Además, el sistema es capaz de almacenar los datos y luego dar una respuesta en tiempo real, con ayuda de redes neuronales LSTM, dos sensores inerciales MPU6050 que se conecta aun microcontrolador EPS32 encargado de la adquisición de datos para la entrada de la red neuronal.

Para garantizar el correcto entrenamiento del modelo LSTM se utilizaron condiciones controladas que nos ayudan a identificar patrones específicos de cada nivel de desgaste. Gracias a su estructura recurrente, el modelo pudo retener información de secuencias de datos anteriores, optimizando así la clasificación de las vibraciones vehiculares. La combinación de sensores físicos, procesamiento en el borde (ESP32) y clasificación en la nube mediante aprendizaje profundo resulta en un sistema de monitoreo eficiente, autónomo y de bajo costo, que se alinea con las necesidades actuales del mantenimiento predictivo en el sector automotriz.

Las mediciones dinámicas con el ESP32 permitieron diferenciar con claridad el desempeño del amortiguador en sus distintos estados como se muestra en la tabla 4. en condiciones adecuadas, los valores de aceleración se mantuvieron estables con picos menores a 1,2 G, reflejando una correcta absorción de vibraciones. En estado intermedio se

registraron fluctuaciones más marcadas con picos de hasta 2,0 G, lo que indica una transmisión parcial de energía hacia el chasis.

En la condición deficiente se observaron oscilaciones constantes con picos superiores a 2,0 g e incrementos en la energía espectral entre 10 y 20 Hz, lo que confirma una pérdida notable de capacidad de amortiguación. Estos resultados evidencian la eficacia del sistema de medición IoT para caracterizar el comportamiento dinámico de los amortiguadores y correlacionar su estado estructural con su desempeño funcional.

La validación del sistema se realizó con el banco de pruebas DynoShock corroborando que los resultados obtenidos por el sistema propuesto tienen realce con la condición real del amortiguador con eso se demuestra su alta precisión y eficacia. Esto probó su capacidad para evaluar la absorción de vibraciones y detectar degradaciones en etapas tempranas. En resumen, los hallazgos demuestran que la integración de IoT y redes neuronales en el diagnóstico de amortiguadores no solo es una solución innovadora, sino también escalable y aplicable en entornos reales, con un impacto positivo en la seguridad, el confort y la eficiencia operativa del vehículo.

Apéndice A. Código de entrenamiento de red neuronal

```

1 # 1. IMPORTACIÓN DE LIBRERIAS
2 import pandas as pd
3 import LSTM, Dense, Dropout, Bidirectional, BatchNormaliza-
4 tion, LeakyReLU from tensorflow.keras.callbacks
5 import classification_report, confusion_matrix from tensor-
6 flow.keras.models
7 import numpy as np from sklearn.model_selection
8 import Adam from imblearn.over_sampling
9 import EarlyStopping, ReduceLROnPlateau from tensor-
10 flow.keras.utils import to_categorical from tensorflow.keras.op-
11 timizers
12 import train_test_split from sklearn.preprocessing
13 import MinMaxScaler from sklearn.utils.class_weight
14 import compute_class_weight from sklearn.metrics
15 import Sequential from tensorflow.keras.layers
16 import SMOTE import matplotlib.pyplot as plt import seaborn as
17 sns

18 # 2. CARGAR DATOS

19 from google.colab import files uploaded = files.upload()

20 # Subir ARCHIVO_NUEVO.xlsx df = pd.read_excel("ENTRE-
21 NAMIENTO_1.xlsx")

22 df.replace([np.inf, -np.inf], np.nan, inplace=True) df.dro-
23 pna(inplace=True) df['estado'] = df['estado'].astype(int) df =
24 df[df['estado'].isin([0, 1, 2])]

25 # 3. PREPARACIÓN DE DATOS

26 time_steps = 50 features = df.drop(columns=['estado']).values la-
27 bels = df['estado'].values scaler = MinMaxScaler() fea-
28 tures_scaled = scaler.fit_transform(features)

29 def crear_secuencias_por_clase(X, y, time_steps):
30 X_seq_total, y_seq_total = [], [] for clase in np.unique(y):

31 idx = np.where(y == clase)[0] X_clase = X[idx]
32 for i in range(len(X_clase) - time_steps): X_seq_to-
33 tal.append(X_clase[i:i+time_steps]) y_seq_total.ap-
34 pend(clase)

35 return np.array(X_seq_total), np.array(y_seq_total)

36 X_seq, y_seq = crear_secuencias_por_clase(features_scaled, la-
37 bels, time_steps)

38 # 4. IGUALAR CLASES
39 X_flat = X_seq.reshape((X_seq.shape[0], -1)) # aplanar para
40 SMOTE smote = SMOTE()

41 X_resampled, y_resampled = smote.fit_resample(X_flat, y_seq)

42 X_resampled = X_resampled.reshape((-1, time_steps, fea-
43 tures.shape[1])) # restaurar forma 3D y_cat_resampled =
44 to_categorical(y_resampled)

45 # 5. DATOS ENTRENAMIENTO Y PRUEBA
46 X_train, X_test, y_train, y_test = train_test_split(

47 X_resampled, y_cat_resampled, test_size=0.2, shuffle=True,
48 random_state=42

49 # 6. CREACION DEL MODELO
50 model = Sequential([

51 Bidirectional(LSTM(128, return_sequences=True), in-
52 put_shape=(X_train.shape[1], X_train.shape[2])),
53 BatchNormalization(),
54 Dropout(0.4),
55 Bidirectional(LSTM(64)),
56 BatchNormalization(),
57 Dropout(0.3),
58 Dense(64),
59 LeakyReLU(alpha=0.1),
60 Dropout(0.3),
61 Dense(3, activation='softmax')])

62 model.compile(optimizer=Adam(learning_rate=0.001),
63 loss='categorical_crossentropy', metrics=['accuracy'])

64 early_stop = EarlyStopping(monitor='val_loss', patience=6, re-
65 store_best_weights=True) reduce_lr = ReduceLROnPlat-
66 eau(monitor='val_loss', factor=0.5, patience=3, verbose=1) #
67 == 7. ENTRENAR EL MODELO == history = model.fit(
68 X_train, y_train, validation_data=(X_test, y_test),
69 epochs=20, batch_size=32, callbacks=[early_stop, re-
70 duce_lr], verbose=1)

71 # EVALUACIÓN MODELO
72 loss, acc = model.evaluate(X_test, y_test) print(f"\n Accuracy en
73 conjunto de prueba: {acc:.4f}")

74 y_pred_probs = model.predict(X_test) y_pred =
75 np.argmax(y_pred_probs, axis=1) y_true = np.argmax(y_test,
76 axis=1)

77 print("\n 📄 Reporte de clasificación:\n") print(classification_re-
78 port(y_true, y_pred))

79 cm = confusion_matrix(y_true, y_pred) plt.figure(figsize=(6, 5))
80 sns.heatmap(cm, annot=True, fmt="d", cmap="Blues", xtickla-
81 bels=[0, 1, 2], yticklabels=[0, 1, 2]) plt.xlabel("Predicción")
82 plt.ylabel("Real") plt.title("Matriz de Confusión") plt.show()

83 # 9. ENTRENAMIENTO
84 plt.figure(figsize=(10, 4)) plt.subplot(1, 2, 1) plt.plot(history.his-
85 tory['accuracy'], label="Entrenamiento") plt.plot(history.his-
86 tory['val_accuracy'], label="Validación") plt.title("Precisión")
87 plt.legend()

88 plt.subplot(1, 2, 2) plt.plot(history.history['loss'], label="Entre-
89 namiento") plt.plot(history.history['val_loss'], label="Valida-
90 ción") plt.title("Pérdida") plt.legend() plt.tight_layout()
91 plt.show()

92 model.save("modelo_entrenado_cnn_lstm50_100.h5")

93 #print("Modelo guardado como modelo entre-
94 nado_cnn_lstm.h5") model.save("modelo_entrenado50_100.ke-
95 ras")
96 #print("Modelo guardado como modelo_entrenado.keras")

97 # ACCEDER A GOOGLE

98 from google.colab import drive drive.mount('/content/drive')
99

```

Apéndice B.

Gráficas Dynashock Fuerza/Desplazamiento de los amortiguadores bueno, regular y malo

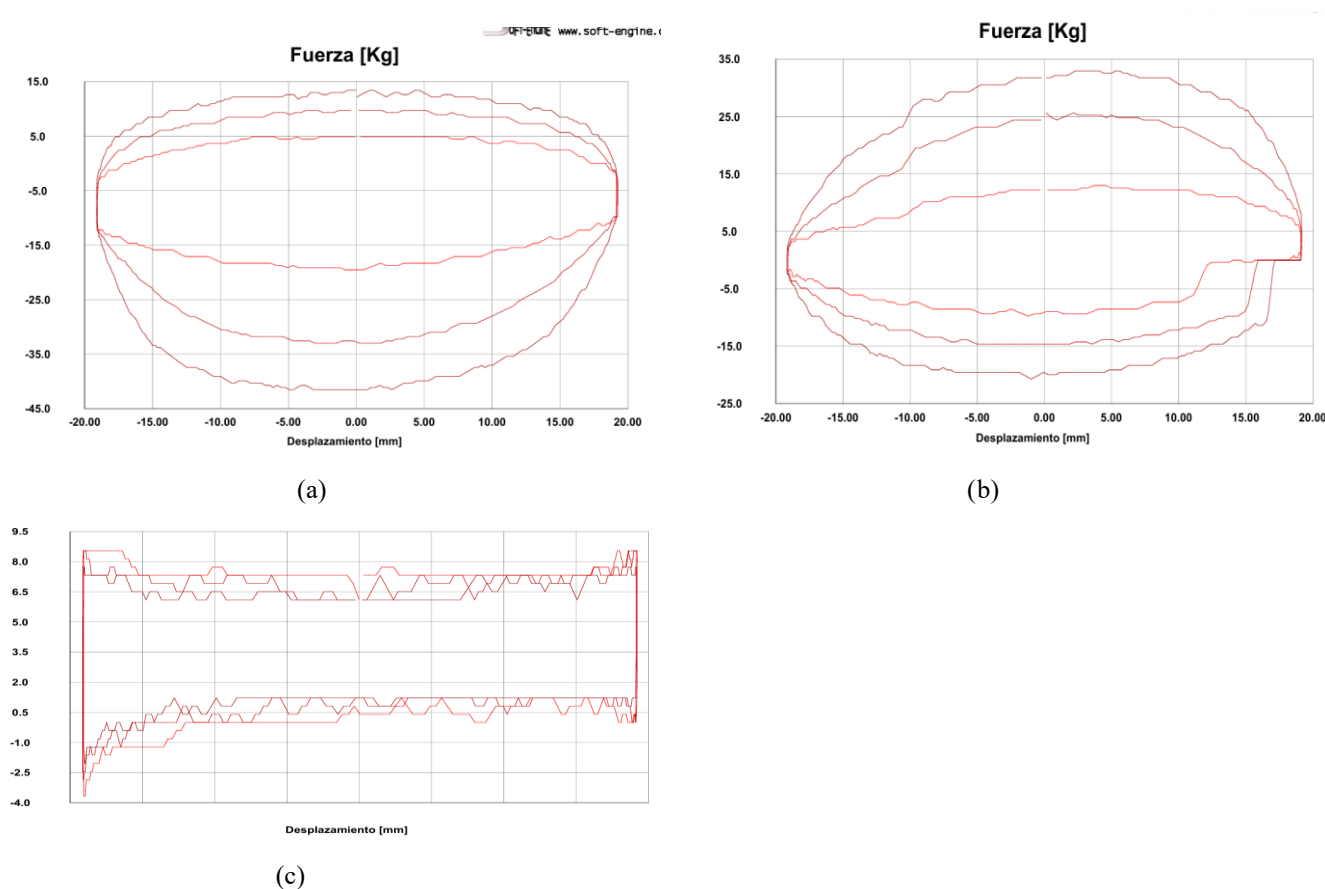


Figura B 1. Gráfica fuerza vs desplazamiento (a) Amortiguador en Estado Bueno, (b) Amortiguador en Estado Regular y (c) Amortiguador en Estado dañado.

Referencias

- Montero, J. (2024). Mantenimiento reglamentario de vehículos y su incidencia en la seguridad. *Mantenimiento reglamentario de vehículos y su incidencia en la seguridad*. Universidad Politécnica de Madrid, Madrid, España. doi:oa.upm.es/81027/
- Wegener, M., & Rompe, J. e. (2024). Investigation and Phenomenological Modeling of Degraded Twin-Tube Shock Absorbers. *Vehicles*, MDPI. doi: 10.3390/vehicles7010026
- Kowalski, M., & Nowakowski, P. (2025). Analysis of automotive suspension system failures and reliability evaluation. *MPDI*. doi:10.3390/app15020805
- Xiang, X., Ni, X., Dai, R., & Huang, X. (2025). *Identification of vehicle suspension shock absorber rattle noise based on wavelet packet feature fusion and GWO-LSTM*. *Sound & Vibration*. doi:10.59400/sv1941
- Maldonado, R., & Neira, E. (2019). Análisis de los accidentes de tránsito provocados por fallas mecánicas en los vehículos de la categoría N1 y de la subcategoría M3 tipo bus, en el cantón Cuenca-Ecuador. Obtenido de bitstream/123456789/17610/1/UPS-CT008371.pdf
- Nowakowski, T., Szymański, G., Jóska, M., Mańczak, R., & Mokrzan, D. (2024). The application of multiresolution analysis wavelet decomposition of vibration signals in the condition monitoring of car suspension. *21(1)*, 10953–10967. doi:10.15282/ijame.21.1.2024.01.0847
- Arena, F., Collotta, M., Luca, L., Ruggieri, M., & Termine, F. (2022). Predictive Maintenance in the Automotive Sector: A Literature Review. *Mathematical and Computational Applications*, doi:10.3390/mca27010002
- Abdelkader, G., Elgazzar, K., & Khamis, A. (2021). Connected Vehicles: Technology Review, State of the Art, Challenges and Opportunities. *Sensors*, *21(22)*, 7712. doi:10.3390/s21227712
- Ahmed, H., Sahandabadi, S., Bhawya, & Ahamed, M. (2023). Application of MEMS Accelerometers in Dynamic Vibration Monitoring of a Vehicle. *Micromachines*, *14(5)*, 923. doi:10.3390/mi14050923
- Chen, Y., Liu, X., Fan, W., Duan, N., & Zhou, K. (2024). A Deep-LSTM-Based Fault Detection Method for Railway Vehicle Suspensions. *Machines*, *12(2)*. doi:10.3390/machines12020116

11. Wang, Y., & Li, W. (2021). Transfer-Based Deep Neural Network for Fault Diagnosis of New Energy Vehicles. *Frontiers in Energy Research*. doi:10.3389/fenrg.2021.796528
12. Arana, C. (2021). Redes neuronales recurrentes: Análisis de los modelos especializados en datos secuenciales. Universidad del CEMA, Argentina. Obtenido de ucema.edu.ar/publicaciones/download/documentos/797.pdf
13. Bhatnagar, V. (2024). *Effectiveness in Different Driving Conditions: Evaluating Shock Absorbers' Performance*. SSRN Electronic Journal. doi:10.2139/ssrn.4983405
14. Deubel, C., Schneider, S., & Prokop, G. (2024). *Effect of Shock Absorber Friction on Vehicle Vertical Dynamics*. SAE International Journal of Vehicle Dynamics, Stability, and NVH. doi:10.4271/10-08-02-0010
15. D'Mello, G., Gomes, R., Mascarenhas, R., Ballal, S. K., & Lobo, V. (2022). *Wheel alignment detection with IoT embedded system*. *Materials Today: Proceedings*, doi:10.1016/j.matpr.2021.11.566
16. Fayyad, J., Jaradat, M., Gruyer, D., & Najjaran, H. (2020). *Deep Learning Sensor Fusion for Autonomous Vehicle Perception and Localization*. A Review. *Sensors*. doi:10.3390/s20154220
17. Khattach, O., Moussaoui, O., & Hassine, M. (2025). *End-to-End Architecture for Real-Time IoT Analytics and Predictive Maintenance Using Stream Processing and ML Pipelines*. *Sensors*. doi:10.3390/s25092945
18. Mitu, N., Vassilev, V., & Tabany, M. (2021). *Low Cost, Easy-to-Use, IoT and Cloud-Based Real-Time Environment Monitoring System Using ESP8266 Microcontroller*. Obtenido de repository.londonmet.ac.uk/6999/
19. Sai, S., Venkatesh, S., Dhanasekaran, S., Balaji, P. A., Sugumaran, V., Lakshmaiyi, N., & Paramasivam, P. (2023). *Transfer Learning Based Fault Detection for Suspension System Using Vibrational Analysis and Radar Plots*. *Machines*. doi:10.3390/machines11080778
20. Thangavelu, R., Rajesh, S., & Thangaraj, S. (2021). *Vibration Analysis of Composite Internal Door Panel of a Car Using FFT Analyzer*. *AIP Conference Proceedings*. doi:10.1063/5.0042280
21. Urbina, L., Moreno, M., Duchanoy, C., & Calvo, H. h.-1. (2016). Pronóstico del área de contacto de los neumáticos de un vehículo vía redes neuronales recurrentes. *Research in Computing Science*,. doi:/10.13053/res-116-1-14
22. Villavicencio, H., & Jeykco, W. (2024). Universidad Nacional de Ingeniería. doi:10.4271/2024-01-5036
23. Wang, F., Wen, H., & Xie, S. (2025). *Performance analysis and hybrid control strategy research of vehicle semi-active suspension for ride comfort and handling stability*. *Machines*. doi:10.3390/machines13050393
24. Zhang, H. W. (2023). *Smart vehicle maintenance scheduling using real-time sensor data in fleet operations*. *Sensors*, 24(24), 7918. <https://doi.org/10.3390/s24247918>.
25. Zwosta, F., Kubenz, J., & Prokop, G. (2024). *Experimental Analysis of the influence of Damper Degradation by Loss of Oil on the Straight Braking Performance of Passenger Car with ABS*. doi:190.4271/2024-01-5036
26. Japanese Automobile Standards Organization. (1993). JASO C611: Suspension struts for automobiles. Tokyo, Japan: Japanese Automobile Standards Organization