

SISTEMA DE MANTENIMIENTO PREDICTIVO INTELIGENTE

INTELLIGENT PREDICTIVE MAINTENANCE SYSTEM

C. A. Fierro Vizcarra¹
J. A. Alvarado Granadino²
H. De la Garza Gutiérrez³
A. Legarda Sáenz⁴

RESUMEN

En los últimos años ha habido un incremento en la demanda de automóviles, lo que ha hecho que las empresas de la industria automotriz enfoquen recursos y esfuerzos en acortar tiempos en sus procesos y aumentar la producción sin perder calidad en sus productos. Con la llegada de la industria 4.0 se han presentado nuevas tecnologías y herramientas que se enfocan en la automatización para ayudar a las empresas a mejorar y acortar sus procesos. En este trabajo se presenta un proyecto de investigación para desarrollar un sistema de mantenimiento, capaz de predecir fallas en el ámbito industrial utilizando herramientas como recolección de datos y técnicas de inteligencia artificial, con la finalidad de anticipar desperfectos y tener un mejor control de fallas y mantenimiento.

ABSTRACT

In the last years, there has been an increasing demand for vehicles that has led companies in the automotive industry to center their resources and efforts on reducing their process times and increase their production without losing quality in the product. With the new industry 4.0 new technologies and tools focused on automation have arrived to help companies to enhance processes. This study presents an investigation project to develop a maintenance system capable of predicting failures in the industrial field using tools such as data collection and artificial intelligent techniques, to anticipate errors and have better control in failures and maintenance.

ANTECEDENTES

La industria automotriz es un importante pilar económico en México con importantes beneficios, como la generación de empleo, desarrollo de proveedores e implementación de nuevas tecnologías. Es una fuente importante de inversión por parte de diferentes empresas internacionales, que colocan plantas de producción en diferentes puntos del territorio nacional.

El potencial de la industria automotriz mexicana es tal que representa el segundo sector económico más importante del país, además de que significa el elemento primordial de la modernización y estrategias de globalización del mismo (Miranda, 2007).


En los últimos se ha visto un alza en la producción de la industria automotriz, esto refleja una demanda en la sociedad por vehículos, como se muestra en la Figura 1 obtenida de (INEGI, 2025), el crecimiento de la producción solo de vehículos ligeros se ha triplicado en los últimos 20 años.

¹Estudiante de Maestría en Sistemas Computacionales. Instituto Tecnológico de Chihuahua II. m21550270@chihuahua2.tecnm.mx

² Profesor Investigador. Instituto Tecnológico de Chihuahua II. jesus.ag@chihuahua2.tecnm.mx

³ Profesor Investigador. Instituto Tecnológico de Chihuahua II. hernan.gg@chihuahua2.tecnm.mx

⁴ Profesor Investigador. Instituto Tecnológico de Chihuahua II. arturo.ls@chihuahua2.tecnm.mx

Figura 1. Producción de vehículos ligeros de los últimos 20 años.

Fuente: INEGI (2025).

Este incremento en la demanda de los productos en la industria automotriz ha hecho que dentro de ésta se busque la manera de tener procesos de mejor calidad, pero en especial, se buscan procesos cortos y estables que generen una gran producción en masa.

A pesar de que la ingeniería en procesos e ingeniería industrial estudian cómo mejorar la producción, es común que los equipos automatizados no rindan a un 100% por diversos motivos: mal uso del sistema, mala programación, uso de tecnologías obsoletas, y en especial un mantenimiento pobre de los equipos. La suma de todos estos factores da como resultado que un sistema automatizado, detenga la producción y dependiendo de las causas que dieron lugar al suceso, puede ser un tiempo considerable o un tiempo corto y puede ser una falla recurrente o de una sola ocasión. Lo anterior genera pérdidas monetarias importantes para las empresas.

En la industria existe una gran variedad de equipos automatizados, y dentro de cada tipo de equipo existen diferentes marcas, lo que hace que los sistemas automatizados sean muy diferentes entre sí. Esto provoca que la información que se puede obtener de cada uno de estos sistemas tenga variaciones considerables y por consiguiente las técnicas de análisis y predicción serán diferentes para cada uno de ellos. Esta variedad genera una necesidad de diferentes herramientas para recolectar y analizar datos y una posterior toma de decisiones.

Con el desarrollo de la industria 4.0 y el uso correcto de nuevas herramientas, como el “IoT” (Internet of things), “Big Data”, y el “Machine Learning”, aplicados al mantenimiento predictivo, pueden ayudar a resolver algunos de los problemas anteriormente mencionados, participando en la evolución de la industria automotriz. El conocer los problemas a los que se enfrenta las empresas al momento de producir, y las tecnologías más tradicionales dentro de estas, ayudan al estudiante a tener un enfoque más cercano a la industria en general y sus problemas actuales, a su vez, aplicando nuevas tecnologías de la industria 4.0 al mantenimiento predictivo.

METODOLOGIA

Con la llegada de la industria 4.0 aparecieron nuevas tecnologías que permiten automatizar procesos, recolectar y analizar datos que otorgan información valiosa de los equipos, máquinas industriales y producción. Este trabajo se divide en recolección de datos, análisis de datos y finalmente preprocesamiento y entrenamiento.

Recolección de datos

La recolección de datos ofrece información sobre vida útil, nivel de carga y detección de fallos, e incluye información relativa al entorno, (Peralta et al, 2020). El tener disponibles y analizar datos de los equipos industriales permite reconocer patrones y entender el funcionamiento a mayor detalle con el fin de dar un mejor mantenimiento a la maquinaria, extender su vida útil y evitar pérdidas de producción.

Se obtuvo un conjunto de datos de un sistema de la página kaggle.com, el cual contiene un número amplio de características y de información adicional. El conjunto de datos elegido representa un sistema conformado por 100 máquinas, de las que se puede encontrar información como: el modelo y la edad de cada una de las máquinas, el mantenimiento que se ha realizado a cada una con su respectiva fecha, información de producción como, el voltaje, la presión y la vibración a las que estuvieron expuestos los equipos. Y lo más importante para el estudio, los errores y fallas de cada máquina.

Análisis de datos

Para facilitar el proceso de análisis del total de 100 equipos se analizó solamente la máquina número 52. En la Tabla 1 se muestran las fallas totales para esta máquina en específico en un periodo de un año. En la primera columna se muestra la fecha en que aconteció el desperfecto, en la segunda columna la máquina en la que ocurrió y en la tercera columna, el componente que presentó una avería.

Tabla 1. *Fallas en la máquina 52.*

| Fecha | Numero Máquina | Falla |
|-----------------|----------------|-------|
| 1/19/2015 6:00 | 52 | comp2 |
| 1/19/2015 6:00 | 52 | comp4 |
| 7/8/2015 6:00 | 52 | comp4 |
| 8/2/2015 6:00 | 52 | comp2 |
| 10/31/2015 6:00 | 52 | comp1 |
| 10/31/2015 6:00 | 52 | comp4 |
| 12/30/2015 6:00 | 52 | comp4 |

En el conjunto de datos de producción existen registros de los 365 días del año hora por hora, dando un total de aproximadamente 8,760 valores, que representan todas las horas de un año. Esto quiere decir que, de las 8,760 horas registradas, solo se presentaron seis fallas.

Se analizaron los valores de producción en las fechas en que se encontraron fallas, estos valores de producción son parámetros de las máquinas como, vibración, presión, rotación y voltaje. Según la Tabla 1, se encontraron dos fallas el 19 de enero del 2015, una para el componente 2 y otra para el componente 4. En la Tabla 2 se muestra un extracto del


comportamiento de los parámetros de la máquina el día 19 de enero.

Tabla 2. Extracto de datos de la máquina 52.

| Fecha | Número Máquina | voltaje | rotación | presión | vibración |
|------------------|----------------|---------|----------|---------|-----------|
| 19/01/2015 6:00 | 52 | 167.13 | 296.19 | 92.82 | 58.93 |
| 19/01/2015 7:00 | 52 | 160.91 | 515.70 | 95.16 | 38.53 |
| 19/01/2015 8:00 | 52 | 192.11 | 448.47 | 119.57 | 46.93 |
| 19/01/2015 9:00 | 52 | 160.31 | 428.00 | 111.15 | 35.84 |
| 19/01/2015 10:00 | 52 | 172.16 | 459.91 | 105.67 | 42.70 |
| 19/01/2015 11:00 | 52 | 154.84 | 507.448 | 79.33 | 37.47 |
| 19/01/2015 12:00 | 52 | 177.28 | 419.01 | 86.36 | 38.81 |
| 19/01/2015 13:00 | 52 | 196.49 | 492.35 | 102.28 | 24.38 |

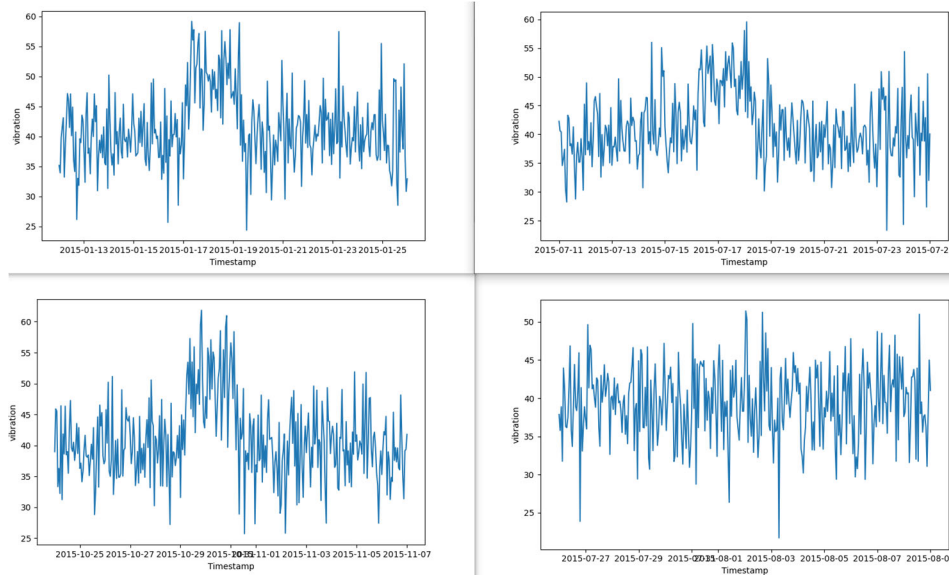
Observando la Tabla 2 es difícil reconocer patrones de comportamiento que den información útil del funcionamiento de la máquina, sin embargo, si se grafican los valores obtenidos de la tabla se obtiene una representación visual más fácil de interpretar. La Figura 2 muestra los parámetros de producción en días cercanos a la falla del 19 de enero, estos pueden parecer aleatorios, sin embargo, dos días antes del evento los valores de vibración empiezan a presentar picos irregulares que se pueden identificar a simple vista.

Figura 2. Datos de producción de enero.




Analizando más días en los que existen fallas, las gráficas muestran un patrón en el que para cada día que existe un evento, el parámetro de vibración muestra picos claramente altos por periodos de tiempos largos. La Figura 3 muestra estas anomalías en cuatro días donde se registraron fallas.

Figura 3. Datos de vibración para cuatro días donde se registraron fallas.



Lo anterior indica que los valores de vibración tienen un peso importante en el funcionamiento de la máquina, se puede afirmar que los equipos son sensibles a esta variable y un cambio brusco en estos valores vendrá acompañado de una falla. Si se analiza la Figura 4, se puede observar que las anomalías empiezan aproximadamente dos días antes de que la falla se haga presente.

Figura 4. Valores de producción y fallas.



Preprocesamiento y entrenamiento

Con base en el análisis anterior se puede afirmar que la maquinaria que se está analizando es sensible a algunos parámetros como la vibración, y cuando se presentan anomalías en estas variables, independientemente de la causa, es probable que vaya a ocurrir una falla. Según la figura 4 los valores de vibración se elevan dos días antes del desperfecto. En el estudio de Gunawan (2022) encontró que se pueden tratar los datos como series de tiempo para predecir eventos futuros.

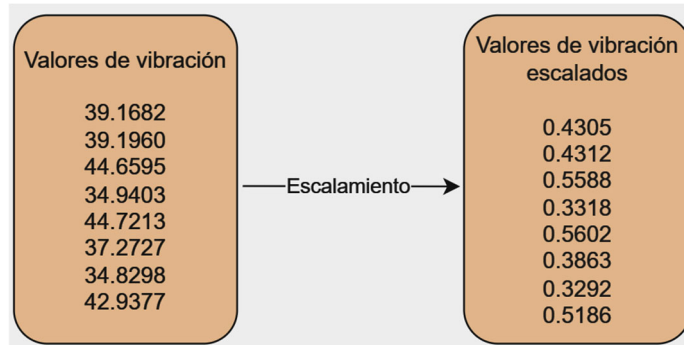
Con esta información es importante elegir una técnica adecuada que tenga la capacidad de predecir valores, con base en datos anteriores. Al tratar los datos como series de tiempo, una opción para predecir el comportamiento de los equipos son las redes neuronales recurrentes, ya que por sus características son buenas procesando tipos de datos secuenciales.

Las redes LONG SHORT TERM MEMORY (LSTM) son un tipo de redes neuronales recurrentes que incorporan dos memorias, a corto plazo y a largo plazo, y fueron propuestas por (Hochreiter & Schmidhuber, 1997). Esta nueva arquitectura de redes recurrentes puede unir y reconocer patrones de hasta 1000 pasos, aun en casos de ruido o secuencias de entrada poco comprensibles, lo que las hace idóneas para tratar con series de tiempo de grandes magnitudes. Las LSTM tienen una de las arquitecturas de aprendizaje profundo más avanzadas y exitosas para predicción de series temporales, reconocimiento de escritura y análisis de discurso (de Lucio, 2020).

Las redes LSTM se han visto aplicadas en diferentes campos, en (Ibargüengoytia et al, 2018) se describe un sistema para predicción de potencia eólica y en (Ramírez et al, 2018) se implementó un modelo para la predicción de actividades en negocios, lo que muestra la versatilidad y efectividad de esta arquitectura.

La tabla 1 muestra que la primera falla se presentó el 19 de enero, para esta etapa de preprocesamiento se tomaron datos solo del parámetro de vibración, de 17 días antes y 17 días después de la falla, generando más muestras, obteniendo datos de datos de 34 días, empezando el 2 de enero y terminando el 5 de febrero. Una vez hecha la ventana, se utilizó un estimador que escala y traduce los datos de la columna de vibración de modo que el total de datos queda en un rango dado que para este trabajo es entre cero y uno como se muestra en la siguiente figura, esta escalación en los datos ayuda a balancear el impacto de las variables y mejora el rendimiento del algoritmo. La Figura 5 muestra una representación de este proceso.

Figura 5. Representación de escalamiento en los datos de vibración.



En el siguiente paso se convirtieron los datos en secuencias de 5, es decir que para cada valor objetivo se toman los datos de 5 horas hacia atrás, empezando por el sexto valor para tener suficientes muestras anteriores. Como resultado se obtuvo una serie de tiempo en secuencias de 5 que es la que finalmente se ingresó a la red LSTM.

En la Figura 6 se muestra una representación de la forma que tomaron los datos después del último proceso, es importante mencionar que la hora en la figura es mostrada en formato de 24 horas para facilitar la visualización, pero en la secuencia tienen un formato “One Hot Encoding”. El formato “One Hot Encoding” se compone de 24 variables que representa cada hora del día y todos tendrán valor de cero excepto una variable que tendrá un valor de uno, representando la hora en que se registró el valor.

Figura 6. Secuencias formadas del conjunto de datos.



En naranja se muestran las secuencias que son las entradas de la red LSTM, conformada por 5 elementos que contienen los valores anteriores y la hora de cada evento. En azul se muestran los valores objetivos que son las entradas esperadas para cada una de las secuencias, así quedan definidas las entradas y salidas de la red LSTM. La Figura 6 muestra solo 3 secuencias con sus respectivos resultados deseados, sin embargo, para una ventana de 34 días como se había comentado el total de secuencias es de 653.

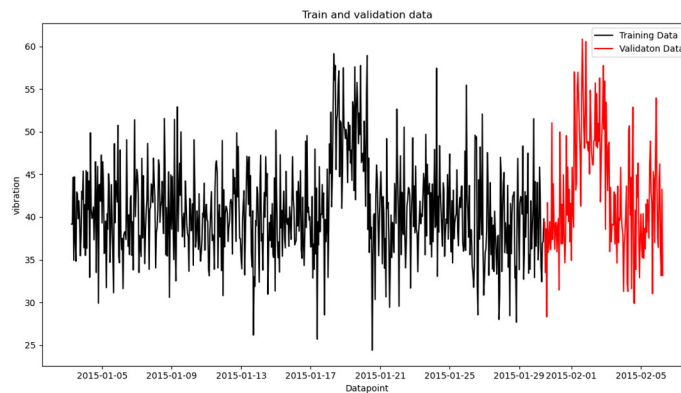
Como se mencionó anteriormente, para el entrenamiento se seleccionó un tipo de red neuronal recurrente conocida como LSTM, las cuales por su arquitectura son ideales para

procesar secuencias de datos, ya que cuentan con una memoria a corto plazo y otra a largo plazo, esta memoria sirve para dar peso a información importante de las primeras secuencias y no pierda relevancia a medida que se ingresan más secuencias con el tiempo.

El modelo se conforma por 4 capas, que consiste en una capa de entrada, 2 capas ocultas y una capa de salida o de activación.

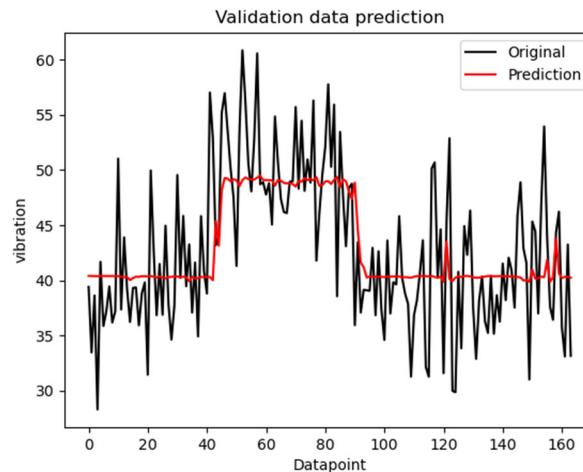
El modelo tiene una ratio de aprendizaje de 0.035 y se entrenó con 50 épocas. El conjunto de datos se dividió en una parte entrenamiento que consiste en un 80% del total de datos y una parte de validación que consiste en el otro 20% restante, representado en la Figura 7.

Figura 7. Datos de entrenamiento y validación.



En la fecha elegida para el entrenamiento se observan dos alteraciones de los valores, una en los datos de entrenamiento y otra en los valores de validación. Después de entrenar la red con estos datos, se obtuvo una pérdida de 0.0134 y un error de validación 0.0155, dejando que la red termine el entrenamiento hasta las 50 épocas. La figura 8 muestra los datos de validación en negro y la predicción en rojo. A simple vista se observa que la red no es exacta en predecir los valores de los datos individualmente, sin embargo, logra predecir la anomalía que es lo que indica una falla a futuro.


Figura 8. Datos de validación y predicción de la red LSTM.



RESULTADOS

Por último, se muestra la figura 11 con los datos reales en azul, la predicción en rojo, y el día en que ocurrió la falla indicada por una línea punteada en rojo. La figura tiene información de datos del 15 de julio del 2015 y del 31 de octubre del 2015 respectivamente.

Figura 11. Predicción de la red respecto a la falla para dos fechas diferentes.



El resultado de estas últimas pruebas mostrado en la figura 11 dice que después de haber detectado una anomalía, la falla se hará presente en un periodo de 2 a 5 días. Lo que indica que cuando la red detecta una falla, se tiene un tiempo de dos a cinco días para planear un mantenimiento a la máquina en cuestión y evitar que la falla se haga presente en tiempo de producción que podría ser un momento más crítico.

CONCLUSIONES

La producción de la industria automotriz en México se ha incrementado en los últimos 20 años y se espera que siga evolucionando debido a la demanda de vehículos en la sociedad. Esto ha generado una necesidad de procesos más eficaces por parte de las empresas, procesos que generen más producción, en menos tiempo y con mejor calidad.

El desarrollo de un sistema predictivo para fallas o comportamientos de equipos resulta más complejo de lo anticipado. Aunque las empresas manejan vastas cantidades de información que podrían ser útiles para este fin, la realidad es que la protección rigurosa de estos datos, motivada por los riesgos de espionaje empresarial, hacen que obtener la información sea una tarea difícil sin una afiliación directa a la empresa. Esto genera un desafío principalmente en la etapa de recolección de datos y el posterior análisis.

Como se mencionó en la fase de pruebas y resultados, la red puede predecir la falla con al menos dos días de antelación lo que puede no ser suficiente tiempo para arreglar el desperfecto antes de que suceda. Sin embargo, el hecho de saber que el sistema encontrara una falla en los próximos días es una ventaja, aunque dos días no sean suficientes para planear un mantenimiento adecuado es verdad que se puede detener producción y arreglar la causa de la falla para evitar un desperfecto mayor que tomaría más tiempo arreglarlo.

BIBLIOGRAFÍA

- de Lucio, J. (2020). Estimación adelantada del crecimiento regional mediante redes. *Investigaciones Regionales – Journal of Regional Research*, 45-64. doi:<https://doi.org/10.38191/iirr-jorr.21.007>
- Gunawan, J. (2022). *Kaggle*. Obtenido de <https://www.kaggle.com/code/jegun19/predictive-maintenance-time-series-forecasting>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Ibargüengoytia, G., Reyes, A., Borunda, M., & García, U. (2018). Predicción de potencia eólica utilizando técnicas modernas de Inteligencia Artificial Wind power forecasting using Artificial Intelligence tools. *Ingeniería Investigación y tecnología*, 1-11. <http://dx.doi.org/10.22201/fi.25940732e.2018.19n4.033>
- INEGI. (07 de 03 de 2025). *Instituto Nacional de Estadística y Geografía (INEGI)*. Obtenido de https://www.inegi.org.mx/app/indicadores/?ind=6207131345&tm=6#D6207131345_180#D6207131345_180
- Miranda, A. (2007). La industria automotriz en México Antecedentes, situación actual y perspectivas. *Contaduría y administración*, 211-248.
- Peralta, J., Martínez, B., & Enríquez, J. (2020). Industria 4.0. *Inventio*, 39. 10.30973/inventio/2020.16.39/4
- Ramírez, U., Tello, E., & Ríos, A. (2018). Modelo basado en redes neuronales recurrentes LSTM para la predicción de la siguiente actividad en procesos de negocio. *Pistas educativas*, 40, 962-974.