



**Elaboración de un modelo de Deep Learning para su uso en mantenimiento predictivo
dentro de la industria de generación de energía**

Esteban Quintero Gómez

Informe de prácticas para optar por el título de Ingeniero Mecánico

Asesor

Andrés Felipe Agudelo Santamaría, Ingeniero Mecánico, Doctor en Ingeniería

Universidad de Antioquia

Facultad de Ingeniería

Departamento de Ingeniería Mecánica

Medellín, Antioquia, Colombia

2023

Cita

(Quintero Gómez, 2023) [1]

Referencia

[1] E. Quintero Gómez, “Elaboración de un modelo de Deep Learning para su uso en mantenimiento predictivo dentro de la industria de generación de energía”, trabajo de grado profesional, pregrado, Universidad de Antioquia, Medellín, 2023

Estilo IEEE (2020)



Centro de Documentación de Ingeniería-(CENDOI)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: Nombres y Apellidos.

Decano/Director: Nombres y Apellidos.

Jefe departamento: Nombres y Apellidos.

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

Dedico este trabajo a todas a todas las personas que me han acompañado a lo largo de todas las etapas de mi vida, mi familia, amigos y profesores. Por su puesto, a mi alma mater, y a la empresa que me abrió las puertas para la elaboración de este proyecto

Agradecimientos

Agradezco a mi alma mater, la Universidad de Antioquia, por haberme dado los pilares fundamentales de mi hacer profesional, además de una educación universal. Agradezco a mi familia por siempre estar a mi lado y a la empresa Accenture que me abrió las puertas.

TABLA DE CONTENIDO

RESUMEN	7
ABSTRACT	8
I. INTRODUCCIÓN	9
II. OBJETIVOS	10
A. Objetivo general	10
B. Objetivos específicos	10
III. MARCO TEÓRICO	10
IV. CONJUNTO DE DATOS	11
V. PLANTEAMIENTO DEL PROBLEMA	12
VI. METODOLOGÍA	12
VII. ENTRENAMIENTO DEL MODELO	14
Clustering (Agrupamiento)	16
Enfoque supervisado	17
Métricas del modelo	18
Error de reconstrucción	18
Matriz de confusión y curva ROC	19
VIII. CONCLUSIONES	19
IX REFERENCIAS	21

LISTA DE FIGURAS

Fig. 1. Arquitectura de Autoencoder.	22
Fig. 2. Metodología usada.	22
Fig. 3. Curva de aprendizaje.	
Fig. 4. Gráfica de Clusters en 2D.	
Fig. 5. Gráfica de Clusters en 3D.	
Fig. 6. Gráfica del error de reconstrucción.	
Fig. 7. Matriz de confusión y Curva ROC/AUC	

SIGLAS, ACRÓNIMOS Y ABREVIATURAS

AE	Autoencoder
ML	Machine Learning
LSTM	Long Short Term Memory
MAE	Mean Absolute Error
ICMMS	Administración inteligente del sistema de control y mantenimiento
SVM	Support Vector Machine
SCADA	<i>Supervisory Control And Data Acquisition</i>
SAP	<i>Systems, Application and Products in data processing</i>

RESUMEN

Este informe tiene como finalidad mostrar la construcción e implementación de un modelo de aprendizaje profundo para la detección de anomalías de funcionamiento en máquinas dentro de la industria de generación de energía.

Para esto se usa una arquitectura de Autoencoder compuesta de redes neuronales recurrentes de tipo Long Short Term Memory (LSTM) y función de activación Tangente hiperbólica (Tanh). Además de dos enfoques, uno supervisado, que permite la detección de anomalías con ayuda de la métrica, error absoluto promedio (MAE). Por otro lado, se usa un enfoque no supervisado, que aprovecha la capacidad de reducción de dimensionalidad del Encoder y un análisis de componentes principales (PCA), para una posterior graficación en 2D y 3D con técnicas de Clusterizado.

El resultado final, es un modelo bastante robusto capaz de aprender el estado de operación “Normal” de la máquina, por lo cuál, también es capaz de detectar otros estados, como “Anomalo”. Además, se logran las visualizaciones en 2D y 3D de los *clústers*.

***Palabras clave:* EJEMPLO: Machine Learning, Deep Learning, Autoencoder, Redes Neuronales Recurrentes, LSTM, Mantenimiento Predictivo, Monitoreo de condición.**

ABSTRACT

The purpose of this report is to show the construction and implementation of a deep learning model for the detection of operating anomalies in machines within the power generation industry.

For this purpose, an Autoencoder architecture composed of Long Short Term Memory (LSTM) recurrent neural networks and Hyperbolic Tangent Activation Function (Tanh) is used. In addition to two approaches, one supervised, which allows the detection of anomalies with the help of the metric, Mean Absolute Error (MAE). On the other hand, an unsupervised approach is used, which takes advantage of the dimensionality reduction capability of the Encoder and a Principal Component Analysis (PCA), for a subsequent 2D and 3D plotting with Clustering techniques.

The final result is a quite robust model capable of learning the "Normal" operating state of the machine, so it is also able to detect other states, such as "Anomalous". In addition, 2D and 3D visualizations of the clusters are achieved.

El *abstract* es el mismo resumen, pero en idioma inglés. Conserva la misma extensión o aproximada, es decir, mínimo 150 y máximo 250 palabras.

***Keywords:* Machine Learning, Deep Learning, Autoencoder, Recurrent Neural Nets, LSTM, Predictive Maintenance, Condition monitoring.**

I. INTRODUCCIÓN

Dentro de la operación normal de una planta de producción en cualquier tipo de industria, la gestión de activos y las estrategias de mantenimiento juegan un rol determinante en la producción y ganancias de las compañías. Una estrategia con bastante apogeo en las últimas décadas es el mantenimiento centrado en la confiabilidad, el cual está fundamentado en teorías estadísticas de supervivencia, y trata de predecir el deterioro de la vida útil de un equipo o máquina en el transcurso del tiempo, con el objetivo de predecir una falla y así poder agendar un mantenimiento antes de un paro inminente. Los paros inminentes son en exceso nocivos para las compañías, ya que, adicionalmente al costo de mantenimiento correctivo, se pierde dinero durante el tiempo que la producción esté parada. Además, en la industria de generación de energía, se corre el peligro de tener un paro inminente y poder no cumplir con la cuota de energía programada para el país, razón por la cual se puede incurrir en sanciones.

Por otro lado, algunas veces se programan mantenimientos preventivos cambiando repuestos o dispositivos cuando no hay necesidad, incurriendo a su vez en gastos innecesarios para las compañías. En este escenario, los ingenieros están encargados de velar por el cuidado y funcionamiento de estas máquinas, gastando la menor cantidad de dinero posible, y la mejor forma de hacerlo es tomar decisiones basadas en la información que está en los datos de operación de los equipos. Una manera de potenciar la gestión de activos por medio del mantenimiento preventivo en las diferentes industrias que usan maquinaria, es incorporar la tecnología de gemelo digital a cada máquina y dispositivo dentro de la planta de producción y a todas en conjunto. El gemelo digital ofrece muchas ventajas, debido a que permite el monitoreo en tiempo real y el almacenamiento de información específica de ese dispositivo, gracias a sistemas de adquisición de datos incorporados en éstos. Con esta información es posible evaluar el desempeño y el estado de salud de los equipos, y adicionalmente se puede predecir una eventual falla de varias maneras. Una de ellas es usando la sólida teoría estadística de supervivencia o confiabilidad, mediante la cual se evalúa el posible tiempo de deterioro con el transcurso del tiempo.

Adicionalmente, se pueden usar modelos de aprendizaje computacional que clasifiquen un tipo de falla y una franja de tiempo en la cual pueda existir una eventual falla, escenario en el cual

se debe generar una alerta. Un ejemplo de este, puede ser una alerta generada por un modelo de Machine Learning – ML, que indique que la máquina fallará la siguiente semana debido a un aumento crítico en el valor de la presión, debido a otro sensor, o varios de éstos. 1

II. OBJETIVOS

A. Objetivo general

Desarrollar un modelo de Deep Learning para aplicar en mantenimiento predictivo en la industria de generación de energía.

B. Objetivos específicos

1.2.1. Construir un modelo de aprendizaje profundo con arquitectura de autoencoder, compuesto por redes neuronales de tipo Long Short Term Memory

1.2.2. Abordar dos enfoques, uno supervisado para el cual se calculan métricas convencionales y otro no supervisado el cual aplica técnicas de reducción de dimensionalidad.

1.2.3. Detectar anomalías con el enfoque supervisado y visualizar los componentes principales en 2D y 3D.

III. MARCO TEÓRICO

En la era de la industria 4.0, el análisis de datos y la infraestructura en la nube permiten tomar decisiones informadas de acuerdo con datos en tiempo real, tomados directamente de la planta de operación [1]. Además, esto posibilita monitorear y mapear un comportamiento normal de los dispositivos determinantes en la operación, permitiendo así generar alertas de acuerdo con comportamientos anormales, debido a medidas y cambios significativos de rango de las variables disponibles. También, gracias a técnicas de confiabilidad, se pueden predecir posibles fallas en una

franja temporal futura [1], lo cual es información valiosa para los ingenieros encargados de programar tareas de mantenimiento.

En el mismo escenario, se permite implementar una administración inteligente del sistema de control y mantenimiento (ICMMS), el cual les permita a los ingenieros de mantenimiento tener información de primera mano del estado de las máquinas y dispositivos en operación, de acuerdo con los datos en tiempo real obtenidos mediante la instrumentación disponible [2].

Con respecto a los modelos, Wong y Luo [3], proponen implementar una arquitectura de redes neuronales recurrentes tipo *encoder-decoder (autoencoder)* para generar un mapeo de las máquinas en operación, de acuerdo con todas las entradas disponibles desde la instrumentación. De esta manera, se aprovechan las principales características de las variables, para finalmente crear un mapeo con modelos supervisados (SVM) y no supervisados (*Clustering*), que permitan generar alertas de acuerdo con eventos de funcionamiento anómalo.

IV. CONJUNTO DE DATOS

Entrando en materia, se usará un conjunto de datos de acceso dispuesto de manera tabular y libre, usado por la comunidad de científicos de datos para probar diferentes modelos de mantenimiento predictivo. En este caso se tienen datos dispuestos en series de tiempo tomados cada minuto, de sensores e información de una bomba centrífuga. Entre ellos se encuentra información de presión, temperatura, régimen de giro, torque, consumo de energía, corriente, voltaje, vibraciones etc. Para un total de 50 señales.

Cabe resaltar que, entre más atributos se tengan es mucho más beneficioso para el arreglo de redes neuronales, ya que es más información de la que se pueden extraer características principales y lograr la reducción de dimensionalidad deseada.

Conjunto de datos disponible en el sitio web: <https://towardsdatascience.com/lstm-for-predictive-maintenance-on-pump-sensor-data-b43486eb3210> [4]

V. PLANTEAMIENTO DEL PROBLEMA

En los últimos años, las industrias están adoptando tecnología 4.0 para ejecutar todo de manera más controlada e inteligente. Sistemas de supervisión como SCADA (*Supervisory Control And Data Acquisition*) y SAP (*Systems, Application and Products in data processing*) se usan para recolectar información de sensores inteligentes para analizarlos y tomar decisiones basados en ellos.

Sin embargo, comúnmente no se usan herramientas más sofisticadas y confiables que permitan extraer más información. Modelos de ML, tales como modelos de aprendizaje no supervisado, aprendizaje supervisado, o incluso *Deep Learning*.

Por estas razones, en este trabajo se busca usar métodos de *Deep Learning* para analizar datos de plantas de generación de energía y sus componentes internos, de modo que se pueda aprovechar información relevante antes desechada. En efecto, se usa un conjunto de datos de libre acceso con información de una bomba centrífuga. En esta hay una variedad de señales obtenidos por sensores, como presión, temperatura o vibraciones, además de datos intrínsecos de la máquinas, como lo son el régimen de giro, el torque o el consumo de potencia eléctrica.

VI. METODOLOGÍA

La Arquitectura del tipo Autoencoder (ver Figura 1) es una forma de organizar las redes neuronales y el número de neuronas en ellas, con el objetivo de que la red en total aprenda a identificar y a construir patrones en los datos para su aprovechamiento posterior.

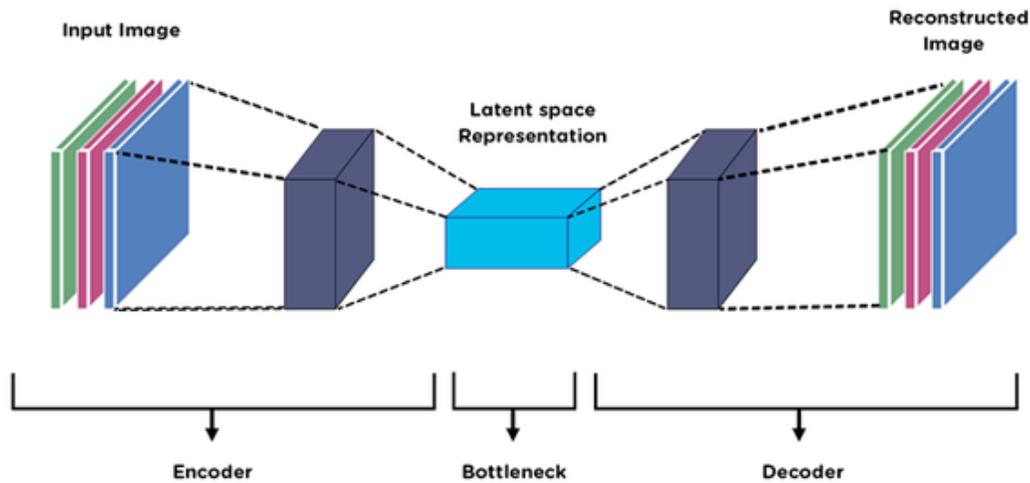


Figura 1. Arquitectura de Autoencoder [5].

El llamado “*Encoder*”, es la primera etapa de la arquitectura, en la cual la primera capa recibe un vector con las dimensiones de entrada. En la siguiente capa se reduce el número de neuronas, lo cual disminuye las dimensiones del vector sin perder información relevante, a lo cual le sigue este proceso una vez más.

Por otro lado, el llamado “*Decoder*” es un arreglo de capas que forma un reflejo del “*Encoder*”, de tal manera que las capas vayan teniendo el mismo número de neuronas que su contraparte en el “*Encoder*”, con el propósito de reconstruir el vector una vez codificado, y tratando de conservar sus características principales, aprendidas en la parte de “*Encoder*”.

Con la ayuda de esta arquitectura se trabajó con dos enfoques, uno supervisado y otro no supervisado. El no supervisado, usando la metodología propuesta por Wong y Luo [2], en la cual, una vez entrenado el modelo usando la arquitectura completa de *Autoencoder*, y verificando que verdaderamente había aprendido las características más importantes de los datos, sólo se usa la parte inicial de la arquitectura, es decir el *Encoder*, como un reductor de dimensionalidad no lineal, para después obtener una visualización gráfica en 2D y 3D, así como para proceder con la identificación de patrones con técnicas de *clustering* como K-Means.

De esta manera, cada vez que se ejecute el código con el modelo en operación, se debe llegar a gráficas en donde la distribución de los *clusters* sea muy parecida y se conserven sus posiciones. Si por el contrario, estos *clusters* se mueven de regiones, es porque hay una inconsistencia en el funcionamiento de la máquina.

El enfoque supervisado, se usó con ayuda de los *labels* (identificadores) disponibles en el conjunto de datos inicial, en el cual se tenía acceso a los estados de la máquina como una columna más en los datos. Es decir, que con los datos recolectados en cierto instante, se sabía el estado de la máquina (normal: “Normal”, recuperación: “*Recovery*”, averiada: “*Broken*”).

De esta manera se aprovecha la arquitectura completa de *Autoencoder*, ya que inicialmente se alimenta el modelo con un vector que se debe codificar y decodificar, devolviendo un vector similar al inicial. En este punto, es posible medir el error entre el vector alimentado, con respecto al vector devuelto por el *autoencoder*, y obtener una métrica llamada, “Error de reconstrucción”. Es aquí donde se pudo definir un umbral para la detección de anomalías, ya que si el error es mayor al establecido en el umbral, significa que hay un funcionamiento inconsistente en la máquina.

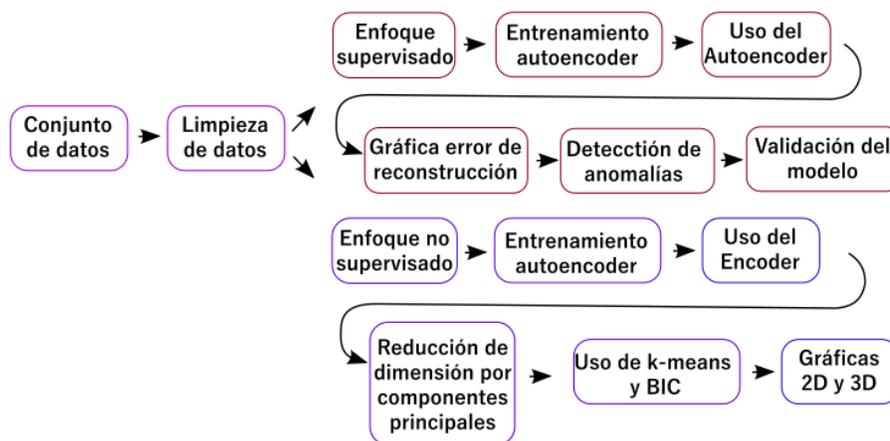


Figura 2: Metodología usada

VII. ENTRENAMIENTO DEL MODELO

Nuestro modelo de *Autoencoder*, el cual está compuesto por redes neuronales recurrentes tipo *Long Short Term Memory* (LSTM), funciona con series de tiempo, en este caso señales de sensores

industriales tomadas en el transcurso del tiempo. Para alimentar este tipo de redes LSTM es necesario un vector de tres dimensiones, en donde la tercera dimensión (adicional al vector disponible), es una ventana de tiempo en el pasado. Para este modelo se usó una ventana igual a 5 instancias en el pasado, equivalente a toma de medidas cada 5 segundos. Por otro lado, la función de activación que se usó fue la tangente hiperbólica, ya que a lo largo de las iteraciones se observó una mejoría en la curva de aprendizaje para el modelo, quitándole ruido y volviéndola más suave. En este caso se observa una convergencia a la asíntota horizontal a las 30 épocas (ver Figura 2).

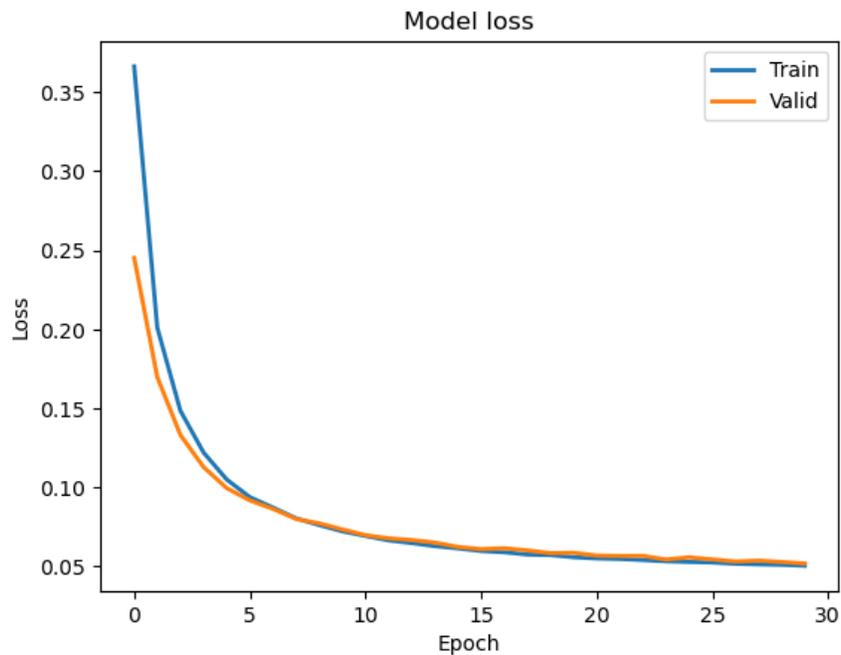


Figura 2. Curva de aprendizaje

La calibración de estos hiper parámetros se hace de manera iterativa observando mejorías en el comportamiento de la curva de aprendizaje, evaluando la diferencia de la función de pérdida entre la curva de validación y la de entrenamiento. Por otro lado, las épocas dan cuenta de las veces que se quiere entrenar el modelo con el conjunto de datos y se pueden variar a conveniencia. En este caso, dado que las curvas han alcanzado una asíntota horizontal, quiere decir que el modelo aprendió lo máximo que pudo, y eso sin ocurrir un sobre entrenamiento (*overfitting*).

Es importante obtener una curva de calibración de este estilo, es decir, donde las curvas de validación y entrenamiento se mantengan lo más juntas posibles, y su valor de pérdida disminuya lo más rápido posible en el transcurso de las épocas, ya que esto indica la capacidad del modelo de aprender las características más importantes de los datos.

Clustering (Agrupamiento)

Una vez el modelo de *Autoencoder* está entrenado y listo para usar con datos de test o de operación, se procede a usar únicamente el *encoder* para aprovechar sus capacidades de reducción no lineal de dimensiones. Sin embargo, para hacer una visualización en 2 o 3 ejes, es necesario tener este número de dimensiones, para lo cual se utiliza la técnica de análisis de componentes principales. Posteriormente se procede a usar el modelo K-means para generar una cantidad de grupos de datos (*clusters*), junto al criterio Bayesiano o mezcla gaussiana para identificar el número apropiado de *clusters* (ver Figuras 3 y 4).

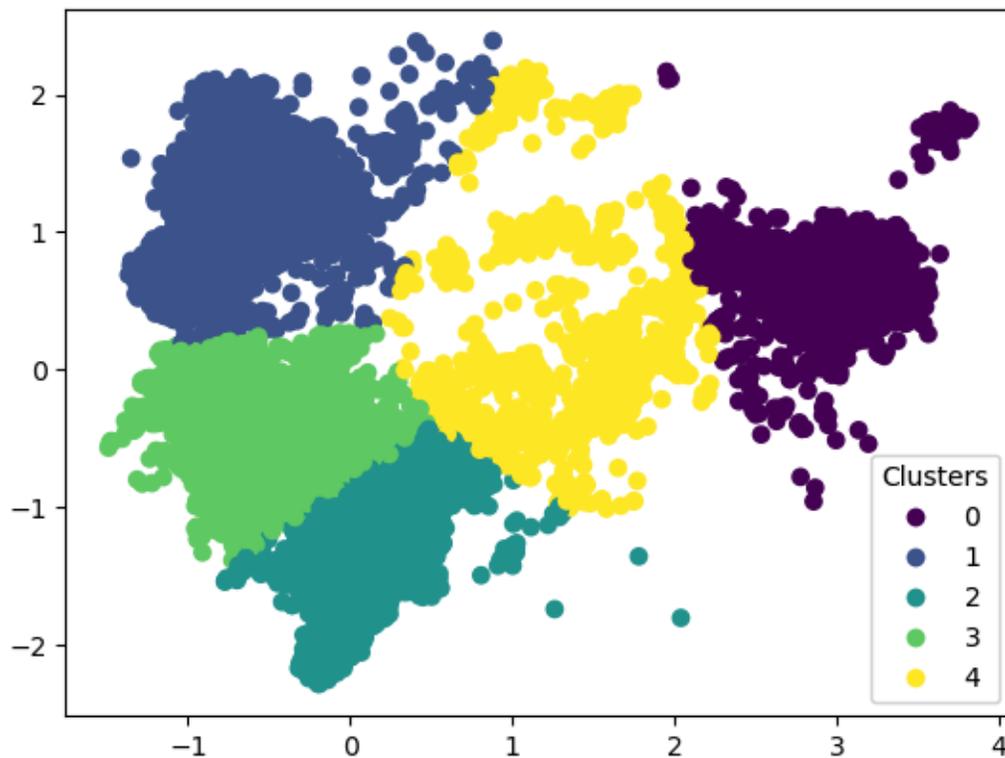


Figura 3. Gráfica de clusters en 2D

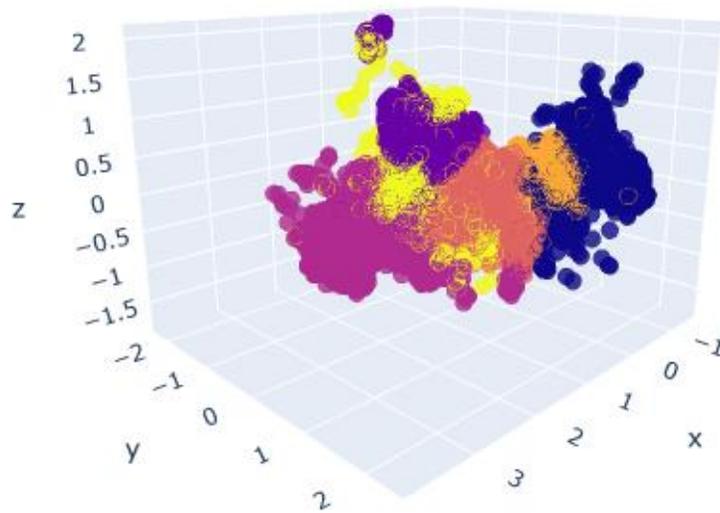


Figura 4. Gráficas de clusters en 3D

Este enfoque permitirá al ingeniero encargado de la operación visualizar el vector inicial, el cual cuenta con demasiadas dimensiones, además de interpretar el movimiento de estos cúmulos de puntos en el transcurso de los días que ejecute el modelo. Es decir que, si se ejecuta este modelo cada día a las 12 del medio día, con datos recolectados desde las 6 hasta las 11 de la mañana, se podrá ver reflejado el movimiento de estos clústeres y si cambian de regiones dentro del plano de la representación gráfica.

Además, cabe resaltar la importancia de reducción de dimensionalidad, ya que existen fenómenos que se deben a varias variables. En este caso puede ser cavitación debido a ciertas condiciones de régimen de giro, presión, temperatura, vibraciones, etc. En otro caso, por ejemplo, el salto entálpico en la cámara de combustión de una turbina de gas, en el cual intervienen fenómenos de transferencia de calor, de masa y donde las propiedades del combustible son también importantes. Por tal motivo, los clústeres pueden llegar a ser en cierta medida la representación de estos tipos de fenómenos.

Enfoque supervisado

Por otro lado, aprovechando que el *dataset* con el que se entrenó el modelo disponía de *labels* para identificación de operación “Normal” en la máquina, se entrenó el *autoencoder* con referencia a estos, para que aprendiera a identificar este estado de operación con ayuda de la métrica llamada “Error de reconstrucción”. De esta manera cuando, se use el modelo en condiciones de operación real, y este error sea mayor a un umbral determinado, se podrá generar una alerta para que el ingeniero encargado del mantenimiento esté atento a deterioros de funcionamiento que puedan eventualmente detonar una falla o paro inminente.

Métricas del modelo

Error de reconstrucción

El error de reconstrucción es simplemente la medida del error medio absoluto o en inglés Mean Absolute Error “MAE”, entre el vector inicialmente alimentado al *autoencoder* y el generado por éste. De esta manera, como el modelo está entrenado para reconstruir los datos en estado de funcionamiento “Normal”, si los datos corresponden a un funcionamiento de operación estable, el valor de esta métrica debería ser bajo. Por otro lado, si la máquina presenta un funcionamiento diferente, este error debería a ser alto, lo cual ayudará al ingeniero de mantenimiento a identificar la anomalía. . De esta manera, en la siguiente figura se puede observar como la mayoría del *dataset* de prueba corresponde a funcionamiento normal, y sólo unas pocas instancias corresponden a un funcionamiento anómalo visible en su alto error de reconstrucción.

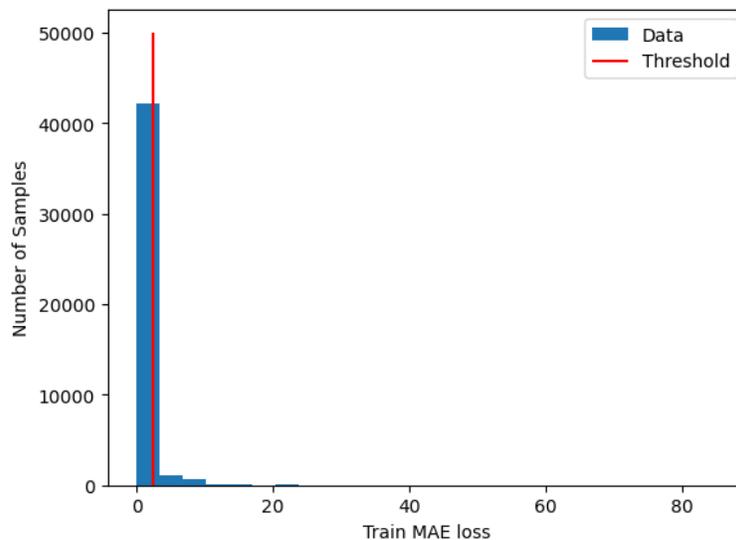


Figura 5. Erro de reconstrucción

Matriz de confusión y curva ROC

La matriz de confusión es una gráfica que clasifica los resultados del modelo entre verdaderos y falsos, y después evalúa cuáles son verdaderamente verdaderos, verdaderamente falsos, falsamente verdaderos y falsamente falsos. En este caso el valor más importante es el de verdaderamente verdaderos o verdadero positivo, ya que el modelo, al entrenarse con los datos de funcionamiento normal, debe estar en la capacidad primordial de identificar este estado de operación y después, los estados anómalos.

Por otro lado, la curva ROC, grafica la tasa de detección de verdaderos positivos, (la cual es la métrica objetivo) con respecto a un promedio.

Estás métricas en conjunto ayudan a identificar la capacidad del modelo para aprender a identificar el estado de la máquina “Normal”, es decir que la tasa de identificación de verdaderos positivos debe ser la más alta para que se cumpla el objetivo. En este caso se cumple, ya que se obtiene una exactitud en la identificación de verdaderos positivos del 99.9% visible en ambas gráficas (ver Figura 6).

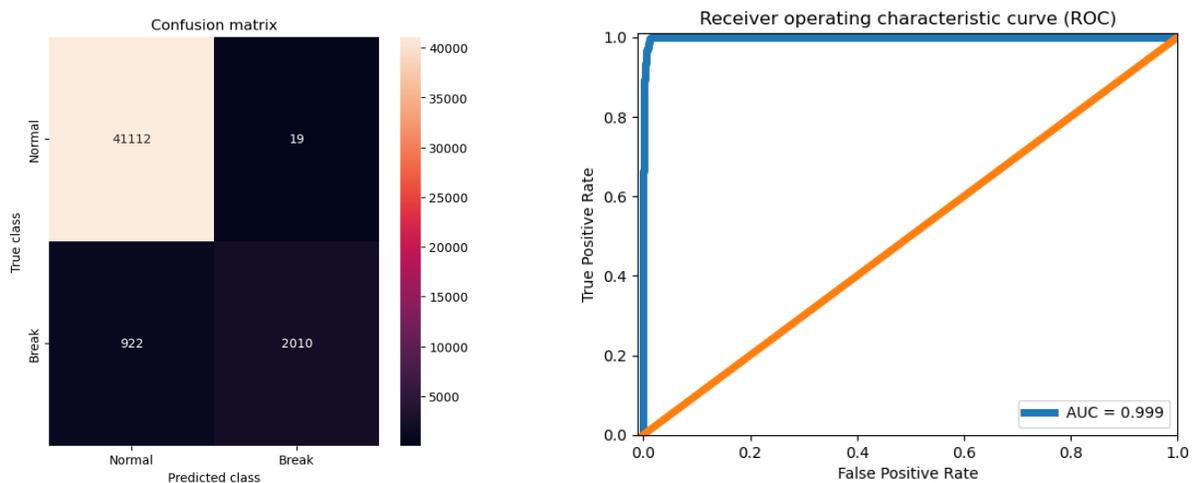


Figura 6. Matriz de confusión y Curva ROC/AUC

VIII. CONCLUSIONES

- Se comprobó la validez de los métodos aplicados a un componente electromecánico: Una bomba centrífuga la cual es un dispositivo ampliamente usado en la industria.
- Se implementó un modelo con arquitectura de Autoencoder, constituido por redes neuronales recurrentes de tipo Long Short Term Memory (LSTM), y con función de activación tangente

hiperbólica. El cuál probó haber aprendido las características más importantes de los datos, lo cual se vio reflejado en las gráficas de clústeres, así como en la matriz de confusión y en la curva ROC.

- Se implementó un método NO supervisado de tipo clustering, que permitió la visualización de los datos en 2D y 3D, para que en una eventual implementación del modelo, el ingeniero de mantenimiento pueda interpretar gráficamente la gran cantidad de señales obtenidas.

- Se usó un conjunto de datos para una bomba centrífuga, el cual cuenta con señales de instrumentación, tales como presión, temperatura, régimen de giro, etc, además de datos intrínsecos de la máquina como consumo de potencia eléctrica, torque y régimen de giro, entre otros. Además, se cuenta con labels, los cuales indican el estado de operación, en este caso se usa en mayor medida el estado “Normal”, para efectos de entrenamiento y validación del modelo.

- La validación mediante la matriz de confusión y la curva ROC, mostró que el modelo aprendió las características del estado de operación normal de la máquina satisfactoriamente, y que es capaz de identificar anomalías con respecto a estados de operación diferentes al normal

- Por lo tanto, se comprobó la utilidad de utilizar métodos avanzados de análisis de datos de operación en la industria energética, para predecir de forma satisfactoria estados atípicos de operación de equipos, lo cual mejora el concepto de los ingenieros responsables de la operación de la planta para programar los mantenimientos de una manera más óptima y eficaz.

IX REFERENCIAS

- [1] Alécio Silva y Gilberto F. M. Prognosis Smart System AI-based Applied to Equipment Health Monitoring in 4.0 Industry Scenario: Publicado en el Institute of Electrical and Electronics Engineers IEEE en mayo del 2021.
- [2]. Chuang Fu, Luqing Ye, Yongqian Liu, Ren Yu, Benoit Iung, Yuanchu Cheng, and Yuming Zeng , Predictive Maintenance in Intelligent-Control-Maintenance-Management System for Hydroelectric Generating Unit. Publicado en el Institute of Electrical and Electronics Engineers IEEE en mayo del 2021 en Marzo del 2004.
- [3]. Timothy Wong junto a Zhiyuan Luo Recurrent Auto-Encoder Model for Large-Scale Industrial Sensor Signal Analysis: Publicado en la Royal Holloway, University of London publicado el 10 de Julio del 2018 .
- [4]. Conjunto de datos, obtenido del sitio web “Medium”. Artículo escrito por Jan Wert y miembro de comunidad de científicos de datos que escriben artículos de libre acceso: Disponible en el sitio web: <https://towardsdatascience.com/lstm-for-predictive-maintenance-on-pump-sensor-data-b43486eb3210>
- [5]. Imagen 1. Deepak Birla . Arquitectura de Autencoder, tomadal del artículo “Basics of Autoencoders”, escrito por el científico de datos Deepak Birla en el blog de científico de datos Medium. Y disponible en la dirección web: <https://medium.com/@birla.deepak26/autoencoders-76bb49ae6a8f>