

## Clasificación del deslizamiento de correas mediante algoritmo genético

Marichal, G.N.<sup>a</sup>, Hernández, A.<sup>a,\*</sup>, Ávila, D.<sup>a</sup>, J. Camacho-Espino y García-Prada, J.C.<sup>b</sup>

<sup>a</sup> Escuela Superior de Ingeniería y Tecnología, Universidad de La Laguna, España

<sup>b</sup> Escuela Técnica Superior de Ingenieros Industriales, UNED, España.

**To cite this article:** Marichal, G.N., Hernández, A., Ávila, D., Camacho-Espino, J., García-Prada, J.C. 2025. Classification of belts slippage by genetic algorithm. XX Simposio CEA de Control Inteligente, Huelva (Spain), 2025.

### Resumen

Las correas como elemento transmisor de potencia en cualquier industria suponen un factor de riesgo que para su control y mantenimiento deben ser monitorizadas. El estudio de los deslizamientos en correas es un campo que aún no se ha estudiado en profundidad y puede suponer una fuente de error importante si la maquinaria o el entorno propicia este efecto como pueden ser las desaladoras. Por lo tanto, es necesario diseñar una técnica que sea capaz de analizar las señales provenientes de mediciones en correas y estime su nivel de deslizamiento con el fin de evitar que la máquina trabaje en condiciones de desajuste, pudiendo consumir más energía o llegando a producir una rotura. En este trabajo se propone un método basado en un Sistema Neuro-Fuzzy Genético desarrollado por los autores, que es capaz de analizar las señales de vibración de la correa y determinar su nivel de deslizamiento.

*Palabras clave:* clasificador, algoritmo genético, vibración, correa

### Classification of belt slippage by genetic algorithm

#### Abstract

As a power transmission element, belts pose a risk factor in any industry, and they must be monitored. The study of belt slippage is a key area of research that has not yet been studied in depth, particularly in environments conducive to this effect, such as desalination plants. Therefore, it is necessary to design a technique capable of analyzing signals from belt measurements to estimate slip levels, in order to prevent machines from operating in misaligned conditions, which could result in increased energy consumption or even breakage. This work proposes a Neuro-Fuzzy Genetic System method developed by the authors, which can analyze belt vibration signals and determine their slip level.

*Keywords:* classifier, genetic algorithm, vibration, belt

### 1. Introducción

La industria moderna actual opera en un entorno globalizado bajo una intensa competencia, donde la eficiencia, la fiabilidad y la optimización son esenciales. El paradigma de la Industria 4.0 fomenta la digitalización, la interconexión y la inteligencia embebida en la maquinaria y las operaciones (Lopez de Lacalle & Posada, 2020). Los sistemas interconectados, el Internet de las Cosas (IoT, de sus siglas en inglés Internet of Things) y el análisis avanzado de datos están haciendo evolucionar la industria, ya que, entre otros aspectos, está modificando la gestión del mantenimiento (Perera, Zaslavsky, Christen, & Georgakopoulos, 2013). La maquinaria

industrial, y los sistemas de transmisión de potencia en particular, son la columna vertebral de la producción, y solo su funcionamiento ininterrumpido y eficiente puede garantizar la competitividad y la rentabilidad de cualquier empresa (Káta, Szendrő, & Gárdonyi, 2016).

El mantenimiento predictivo aparece para suplir las carencias de las estrategias de mantenimiento tradicionales, proporcionando un enfoque más complejo, proactivo e inteligente. Su principio se basa en detectar indicios tempranos de degradación o fallos incipientes a través de la monitorización (Zonta, y otros, 2020).

Los sistemas de transmisión por correa, incluyendo variantes como las correas planas, trapecoidales y las correas

\*Autor para correspondencia: ahernand@ull.edu.es

dentadas, son elementos fundamentales y a la vez críticos en una gran variedad de máquinas industriales. Es el ejemplo de las plantas desalinizadoras, donde suponen un factor de riesgo debido a su frecuente deterioro por factores ambientales y de alto nivel de uso ( Avila, Marichal, Cuba Arana, & Quiza, 2023). Su propósito fundamental es transmitir potencia y movimiento entre ejes, frecuentemente permitiendo cambios en la velocidad o el par transmitido, y permitiendo modificar la alineación de los ejes. Son elementos económicos, relativamente silenciosos, absorben vibraciones y choques, y toleran cierto grado de desalineación. Sin embargo, su dependencia de la fricción para la transmisión de potencia, las hacen vulnerables a ciertos tipos de fallos y degradación. Particularmente, el fenómeno del deslizamiento es uno de los problemas más comunes y dañinos, puesto que no solo compromete a la transmisión, sino que puede acelerar la degradación de la propia correa y de los elementos asociados ( Hyun, Kang , & Kim , 2021).

El deslizamiento en una transmisión por correa supone la pérdida de sincronía entre la velocidad lineal de la correa y la velocidad tangencial de las poleas sobre las que se asienta. Este fenómeno ocurre cuando la fuerza de fricción desarrollada entre la correa y la superficie de la polea no es suficiente para transmitir el par requerido y se produce un movimiento relativo entre ambas superficies ( Zhang, Rajagopalan, & Salman, 2010). Generalmente produce una disminución del coeficiente de rozamiento dando lugar a una pérdida de par de transmisión y aumento de la temperatura en el contacto correa-polea, lo que degrada la correa, reduciendo su capacidad de agarre y a su vez produce más deslizamiento y desgaste. Por esto es crucial detectar el deslizamiento en sus etapas más tempranas.

La aplicación de mantenimiento predictivo en la detección de deslizamiento en correas se centra en la monitorización. Las técnicas de monitorización de condición ( Ali & Abdelhadi, 2022) suelen centrarse en el análisis de vibraciones (Zamorano, Ávila, Marichal, & Castejón, 2022), monitorización de temperatura ( Bagavathiappan, Lahiri, Philip, & Jayakumar, 2013), medición de velocidad angular ( Lin, Tan, Ma, & Mathew, 2014), monitorización acústica (Jombo & Zhang, 2022) o el análisis de corriente del motor (Mehala, 2010). El papel de la Inteligencia Artificial (IA), y sobre todo los modelos de Aprendizaje Automático (Machine Learning-ML), es clave para el análisis de grandes volúmenes de datos complejos, pero su principal ventaja es que es capaz de identificar patrones ocultos, correlaciones no lineales y anomalías incipientes.

Dentro del amplio espectro de técnicas de IA y ML, las más aplicadas para el diagnóstico de fallos en maquinaria rotativa, siendo directamente relevantes para la detección del deslizamiento en correas, son las Redes Neuronales Artificiales (RNA) (Abiodun, y otros, 2018), las Máquinas de Vectores Soporte (SVM) (Laouti, Sheibat-Othman, & Othman, 2011), modelos basados en Lógica Difusa ( Li, y otros, 2019), los Árboles de Decisión (Abdallah, y otros, 2018) y Bosques Aleatorios ( Cao, Ji, Sun, & Su, 2023). Sin embargo, en muchos casos se buscan los enfoques híbridos con el fin de combinar las fortalezas de diferentes algoritmos (Nobre, 1995), (Rajasekaran & Pai, 2003). Es en este contexto los Algoritmos Genéticos (AG) ofrecen un potencial significativo (Cordón, Herrera, Gomide, Hoffmann, & Magdalena, 2001),.

Los AG son técnicas de búsqueda y optimización diseñados para encontrar soluciones aproximadas de alta calidad a problemas complejos. El funcionamiento se basa en la evolución iterativa de una población de "individuos", donde cada individuo representa una posible solución al problema, codificada generalmente como una cadena de parámetros (análoga a un cromosoma). La calidad o "aptitud" de cada individuo (solución) se evalúa mediante una función (fitness function) definida específicamente para el problema en cuestión. La población evoluciona a lo largo de sucesivas "generaciones" mediante la aplicación de operadores genéticos inspirados en la biología (selección, cruce o mutación) durante un número determinado de generaciones o hasta que se cumple un criterio de parada (por ejemplo, se alcanza una solución suficientemente buena, o la mejora entre generaciones se estanca). Los AG son muy adecuados como herramientas de aprendizaje automático integrados con otros modelos de ML, como las RNA, y para optimizar conjuntos de reglas en sistemas basados en conocimiento como la Lógica Difusa (Marichal, Hernández, Ávila, & García-Prada, 2024).

El presente trabajo aborda la problemática crítica de la detección temprana del deslizamiento o el sobreajuste en sistemas de transmisión por correa, un fenómeno que impacta negativamente la eficiencia energética, la fiabilidad operativa y la vida útil de componentes industriales clave. El Mantenimiento Predictivo (PdM), potenciado por las capacidades de análisis de datos de la Inteligencia Artificial (IA), ofrece un marco prometedor para abordar este desafío. Particularmente se ha optado por la hibridación de Redes Neuronales Artificiales, junto con Lógica Difusa y Algoritmos Genéticos (GNF) como metodología para construir un clasificador de deslizamiento a partir de datos de vibración obtenidos sobre la maquinaria.

Este artículo se organiza de la siguiente manera: la Sección 2 describe la configuración experimental utilizada para la adquisición de los datos. La Sección 3 presenta el pre-procesado de las señales y la implementación del algoritmo. La Sección 4 expone y analiza los resultados obtenidos, evaluando el rendimiento del método propuesto. Finalmente, la Sección 5 resume las principales conclusiones del trabajo y sugiere posibles líneas futuras de investigación.

## 2. Montaje experimental

Tal y como se muestra en la *Figura 1*, el módulo de bomba de alta presión de transmisión por correas está compuesto por una bomba de baja y alta presión, las cuales pueden alimentar una batería de membranas de una planta desaladora por RO de agua de mar a pequeña escala. Este módulo está diseñado para trabajar con agua de mar, que se toma a través de una tubería conectada a una bomba de baja presión que eleva las presiones del sistema entre 0.2-0.3 MPa. El agua marina pasa a través de un sistema de filtro de cartucho para eliminar cualquier partícula que pueda afectar a la bomba de alta. Esta bomba de alta presenta una transmisión por correas, siendo capaz de elevar la presión del sistema hasta los 7.0 MPa.

En el diseño experimental de este estudio se detectó la necesidad de emplear dos tipos de equipos especializados para las mediciones, uno para la medición de velocidades angulares ( $\omega$ ) y otro para la toma de vibraciones del sistema.

El instrumento utilizado para realizar la medición de velocidades angulares es un Tacómetro Digital de la marca Limit con una precisión de  $\pm 0,05\% + 1$  rpm. Estas mediciones se llevaron a cabo de forma manual, colocando un indicativo en cada una de las poleas, para poder realizar la lectura con el tacómetro digital.

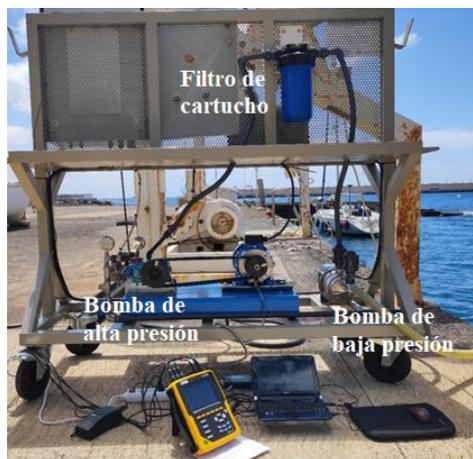


Figura 1. Módulo de bomba de alta presión de transmisión por correas

Las mediciones de vibraciones se llevaron a cabo con instrumental de la casa Bruel & Kjaer, para las cuales se empleó un acelerómetro piezoeléctrico triaxial tipo 4504 A y un conmutador de señales analógico digital (Photon +). Las señales enviadas por el conmutador se envían a un ordenador portátil para su procesamiento y almacenamiento.

Los datos utilizados en este estudio fueron tomados a partir de la desaladora experimental mostrada en la Figura 1. Para la realización de las mediciones se mantuvo constante la presión de la bomba a 5.5 MPa y la frecuencia de trabajo de la planta desaladora a 50 Hz en el sistema bombas para la alimentación de agua a alta presión.

Una vez prefijados los valores de trabajo nominal del sistema, se propone tomar como base para el estudio, el análisis de las vibraciones, a partir de diferentes estados de deslizamiento de la correa. Los tres valores de deslizamiento (S) que se asumirán en el estudio son: 0.01%, 0.48% y 1.05%, donde, según ( Arntz Optibelt Group, 2024) el deslizamiento en una correa de transmisión no debe superar 1% bajo carga nominal. Una pretensión insuficiente de la correa o una sobrecarga prolongada con un deslizamiento superior al 2%, puede traer consigo una reducción de la vida útil de la correa.

Los valores de deslizamiento (S) no se pueden obtener directamente del equipo en cuestión, sino que se obtiene indirectamente, a través de la ecuación 1 ( Arntz Optibelt Group, 2024).

$$S = \left( 1 - \frac{n1L/n2L}{n1B/n2B} \right) * 100 \quad (1)$$

Donde:

n1L: frecuencia de rotación de polea matriz en vacío (rpm)

n2L: frecuencia de rotación de polea accionada en vacío (rpm)

n1B: frecuencia de rotación de polea motriz bajo carga (rpm)

n2B: frecuencia de rotación de polea accionada bajo carga (rpm)

Tanto la frecuencia de rotación de las poleas accionadas bajo carga como al vacío fueron tomados a tres diferentes ajustes de la correa. El experimento se llevó a cabo partiendo de bajos niveles de ajuste en la correa hasta llegar al valor aproximado de 1%, valor recomendado técnicamente. En cada uno de los tres casos analizados, primeramente, se realiza una toma de la velocidad angular (rpm) de las dos poleas (motriz y accionada) en vacío. Tomadas las velocidades angulares ( $\omega$ ) de cada una de las poleas al vacío, se procede a someter a carga nominal a la bomba, lo cual se logra elevando la presión del sistema hasta los 5.5 MPa, lo cual somete a la correa a la carga de trabajo del sistema. Una vez estabilizado el sistema a la presión de trabajo, se procede a realizar las mediciones de frecuencia de rotación de las poleas bajo carga (rpm) y de las vibraciones que se producen en el mismo. La Figura 2 muestra cómo se lleva a cabo la toma de frecuencia de rotación de las poleas (rpm) en cada caso.

En cuanto a la medición de las vibraciones, se coloca un acelerómetro en el motor eléctrico lo más cerca posible del rodamiento (Figura 3), realizándose cinco mediciones consecutivas de vibración durante 2 segundos, con una frecuencia de muestreo de 2560 Hz, en cada uno de los diferentes valores de deslizamientos (S) asumidos en el estudio (0.01%, 0.48% y 1.05%).



Figura 2. Fotografía de medición de frecuencia de rotación de las poleas (rpm). a) accionada; b) motriz

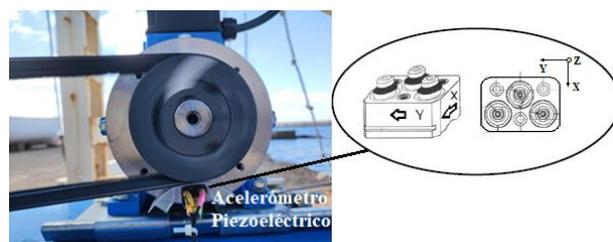


Figura 3. Ubicación del acelerómetro piezoeléctrico para la medición de vibraciones.

### 3. Aplicación de IA

El primer paso para construir un clasificador es proporcionar al sistema los datos que debe analizar, es decir, establecer lo que se va a considerar como parámetros de entrada, por lo tanto, se deben extraer los datos característicos de las señales medidas. Como se indicó en el apartado anterior, en este trabajo, de cada medición de vibración se obtiene una señal formada por 307200 valores para cada uno de los ejes cartesianos. En esta investigación, se ha optado por un análisis

del espectro de frecuencia de las vibraciones, concretamente con la aplicación de la Transformada Rápida de Fourier (FFT), lo que da lugar a tres señales de 262145 valores cada una. A continuación, se ha realizado un estudio por bandas, concretamente se calcula la media cada 500 Hz de ancho de banda, de las señales de los tres ejes concatenados. De esta forma, cada una de las medias obtenidas en cada banda, se convierte en la entrada al clasificador. Cada vector de entrada consta de 1575 valores de frecuencias.

Puesto que el propósito de este trabajo es lograr un clasificador que proporcione el grado de deslizamiento de una correa, a cada conjunto de entradas se le debe asignar una salida que sea identificativa. En esta investigación se ha tratado como primer paso, la identificación de tres niveles de deslizamiento, por lo que el sistema, una vez entrenado, deberá proporcionar tres salidas. El algoritmo Neuro Fuzzy Genético (GNF) desarrollado, que se detalla a continuación, emplea salidas de tipo binario, por lo que el clasificador solo activará una de las tres salidas, que será la identificativa del deslizamiento correspondiente para la señal de vibración particular que se esté analizando. La tabla 1 muestra la salida activada en función de la etiqueta de clasificación correspondiente.

Tabla 1. Salida activada del GNF en función de la etiqueta de clasificación.

Nivel de deslizamiento	Número de salida del GNF		
	1	2	3
1º nivel (0.01%)	1	0	0
2º nivel (0.48%)	0	1	0
3º nivel (1.05%)	0	0	1

Una vez que se cuenta con el conjunto de datos de entrada-salida se lleva a cabo el proceso de entrenamiento. Concretamente se propone un Sistema Neuro-Fuzzy Genético de tres capas (Cordón, Herrera, Gomide, Hoffmann, & Magdalena, 2001), (Rajasekaran & Pai, 2003) con la estructura ANFIS (Jang, 1993) desarrollado por los autores (Marichal, Hernández, Ávila, & García-Prada, 2024). Las entradas del sistema  $U_{ij}$  se corresponden con las entradas a la primera capa. Como se mencionó anteriormente, cada señal se ha convertido al espacio de frecuencias a través de la FFT y a continuación se analiza por bandas de 500 datos de frecuencias, por lo que cada señal de entrada estará compuesta 1575 valores. Por otro lado, las salidas de cada neurona  $X_{ij}$  dependen del centro ( $\mu_{ij}$ ) y del ancho ( $\eta_{ij}$ ) de la función de pertenencia. La ecuación (2) representa esta relación, donde  $N_1$  es el número de entradas y  $N_2$  es el número de nodos de la capa intermedia.

$$X_{ij} = e^{\left(\frac{-(U_{ij}-\mu_{ij})^2}{\eta_{ij}^2}\right)}; i = 1, \dots, N_1; j = 1, \dots, N_2 \quad (2)$$

Las salidas de la segunda capa  $I_i$  están relacionadas con las reglas; eso significa que  $N_2$  también es indicativo del número de reglas.

$$I_{ij} = \min\{X_{1j}, \dots, X_{N_1j}\} j = 1, \dots, N_2 \quad (3)$$

Finalmente, las salidas del sistema  $Z_k$ , que corresponden a las salidas de la tercera capa, se calculan con las salidas de la segunda capa y la salida estimada  $\delta_{jk}$  de cada nodo  $j$ .

$$Z_k = \frac{\sum_{j=1}^{N_2} \delta_{jk} Y_j}{\sum_{j=1}^{N_2} Y_j} k = 1, \dots, N_3 \quad (4)$$

El número de salidas del sistema se indica en  $N_3$ , que en este trabajo es 3, como se puede observar en la Tabla 1.

Las dos primeras fases del algoritmo de aprendizaje están dedicadas a la obtención de los parámetros de estas ecuaciones. Particularmente en la primera fase, un mapa de Kohonen bidimensional autoorganizado (Kohonen, 1990) permite establecer valores para  $\mu_{ij}$  y  $\delta_{jk}$ , cuyo vector se compone del conjunto de valores de entrada-salida del sistema.

El punto de partida es un mapa bidimensional  $10 \times 10$ , lo que significa que se comienza con 100 nodos y consecuentemente, también con 100 reglas. Cada nodo comienza con un vector de peso asociado que está vinculado a una etiqueta de clasificación. Estos vectores se actualizan durante la fase de aprendizaje no supervisado, y una vez finalizada se asignan valores iniciales para  $\mu_{ij}$  y  $\delta_{jk}$ . Estos valores se ajustarán a otros más convenientes durante la siguiente fase.

La implementación del Sistema Neuro-Fuzzy Genético ocurre en la segunda fase del algoritmo propuesto. En esta etapa se ajusta el conjunto de parámetros obtenidos en la fase anterior, y se reduce el número de nodos de la capa oculta, y, por tanto, también se reduce el número de reglas. Para la aplicación del algoritmo genético, en este trabajo se ha tomado el individuo como un vector, donde sus componentes son sus genes. De esta forma, cada solución posible está compuesta por un vector de dimensión  $N_1 \times N_2$ . Los primeros  $N_2$  elementos son valores binarios, que son indicativos de la activación de la regla asociada. Esto significa que, si el elemento se activa, esta regla se tiene en cuenta, pero si es 0, esta regla se descarta. Por otro lado, el resto de los componentes del vector están ligados al ancho de la función de pertenencia, y, por lo tanto, aquellos elementos con un valor de 0 son reglas que no se incluyen en el resultado final. Con este tipo de algoritmo, cada vector se convierte en un candidato del sistema GNF y sus componentes no nulos participan en el proceso de aprendizaje. En esta investigación se ha utilizado el operador de cruce en el 60% de las iteraciones y el operador de mutación en el 40% de las iteraciones restantes. En cuanto a la función fitness, se ha tomado como el error cuadrático medio de cada individuo.

Una vez concluida la fase de aprendizaje, se realiza un ajuste del número de reglas y del ancho de la función de pertenencia

#### 4. Resultados

Como se indicó anteriormente, en esta primera fase de la investigación se han medido tres niveles de deslizamientos en correas, teniendo cuatro mediciones para el primer nivel, cinco mediciones para el segundo nivel y tres para el último nivel. Entonces, se entrena el GNF con el 75% de los patrones de frecuencia, reservando el resto para comprobar la capacidad de generalización del sistema entrenado.

En este trabajo se ha optado por el uso de la matriz de confusión como método de visualización de resultados de un clasificador, puesto que permite comprobar la capacidad de aprendizaje del algoritmo comparando las clases predichas con las reales. Esta matriz muestra los éxitos y los errores del clasificador. En este caso, dado que hay tres niveles de deslizamiento para clasificar, y, por tanto, tres etiquetas para

predecir, la matriz tiene una dimensión de  $3 \times 3$ . Los elementos diagonales corresponden a los verdaderos positivos, es decir, identificaciones correctas del clasificador, y el resto de los elementos son clasificaciones erróneas. La Figura 4 corresponde a la matriz de confusión construida con los patrones de entrenamiento, y muestra que el clasificador obtiene 100% de precisión para las tres etiquetas de clasificación. La Figura 5 muestra el comportamiento del clasificador con los patrones de generalización, es decir, con aquellos datos que no se han introducido en el sistema durante el entrenamiento, y que por tanto son desconocidos para el clasificador. Como se observa, la precisión ha descendido hasta el 66.7%, puesto que, de los 3 únicos patrones reservados, existe uno mal clasificado, que es de clase 2 y se ha clasificado como de clase 1.

		Muestras de Entrenamiento			
		1	2	3	
Clases predichas	1	3 33.3%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	3 33.3%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	3 33.3%	100% 0.0%
		Clases reales			
		1	2	3	
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%

Figura 4. Matriz de confusión con patrones de entrenamiento

		Muestras de generalización			
		1	2	3	
Clases predichas	1	1 33.3%	1 33.3%	0 0.0%	50.0% 50.0%
	2	0 0.0%	1 33.3%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	0 0.0%	NaN% NaN%
		Clases reales			
		1	2	3	
		100% 0.0%	50.0% 50.0%	NaN% NaN%	66.7% 33.3%

Figura 5. Matriz de confusión con patrones de generalización

Con el fin de complementar la información proporcionada por las matrices de confusión, lo habitual es representar también las curvas ROC. Se trata de una representación gráfica de la relación de verdaderos positivos (TPR, True Positive Rate) y la relación de falsos positivos (FPR, False Positive Rate) bajo diferentes umbrales de clasificación. Para conocer la medida del rendimiento en todos los umbrales de clasificación posibles, se calcula el área bajo la curva (AUC, Area Under Curve). Una forma de interpretar el AUC es como la probabilidad de que el modelo clasifique un ejemplo

positivo aleatorio más alto que un ejemplo negativo aleatorio. Esto implica que cuanto más cerca de 1 esté este valor, mejor será el clasificador. El peor resultado para un clasificador sería un AUC cercano a 0,5, porque significaría que la identificación es aleatoria.

Con el fin de complementar la información proporcionada por las matrices de confusión, lo habitual es representar también las curvas ROC. Se trata de una representación gráfica de la relación de verdaderos positivos (TPR, True Positive Rate) y la relación de falsos positivos (FPR, False Positive Rate) bajo diferentes umbrales de clasificación. Para conocer la medida del rendimiento en todos los umbrales de clasificación posibles, se calcula el área bajo la curva (AUC, Area Under Curve). Una forma de interpretar el AUC es como la probabilidad de que el modelo clasifique un ejemplo positivo aleatorio más alto que un ejemplo negativo aleatorio. Esto implica que cuanto más cerca de 1 esté este valor, mejor será el clasificador. El peor resultado para un clasificador sería un AUC cercano a 0,5, porque significaría que la identificación es aleatoria.

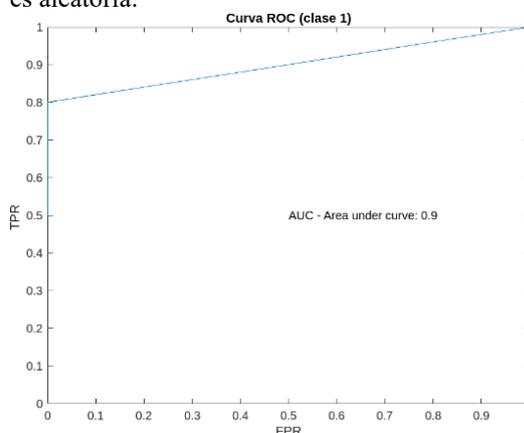


Figura 6. Curva ROC para etiqueta de clasificación 1

En este trabajo se ha obtenido para la etiqueta de clasificación 1 un valor del área bajo la curva de 0.9, como se observa en la Figura 6, para la etiqueta de clasificación 2 también de 0.9 y en la Figura 7 se observa que el AUC es de 0.875 para la etiqueta de clasificación 3.

Como se puede comprobar, a pesar del número reducido de muestras, el método propuesto ha sido capaz de generar un clasificador para el deslizamiento de correas considerablemente bueno, puesto que proporciona valores de AUC muy elevados para todas las clases a etiquetar.

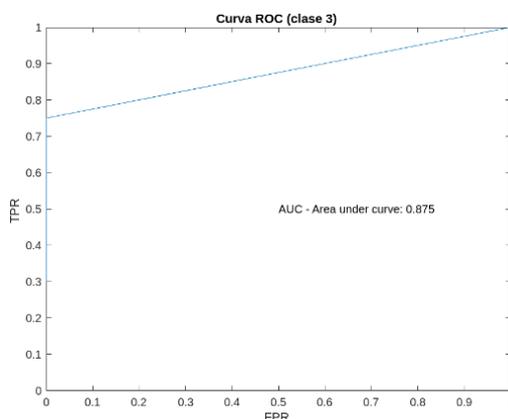


Figura 7. Curva ROC para etiqueta de clasificación 3.

## 5. Conclusiones

Este trabajo pone de manifiesto que la medición de vibraciones en maquinarias con correas puede ser útil para determinar el nivel de deslizamiento. El estudio de estas mediciones en el espectro de frecuencias permite extraer características significativas que el algoritmo GNF entrenado es capaz de identificar y asociar a su nivel de deslizamiento. Este hecho supone una gran ventaja en la detección temprana de defectos y proporciona la información necesaria para poder aplicar un mantenimiento predictivo efectivo. Esto implica poder conocer si el grado de deslizamiento que sufre la correa no es adecuado para su funcionamiento y así poder realizar ajustes antes de que se produzca algún fallo o incluso evitar que haya altos consumos energéticos por esos desajustes mecánicos.

Es importante destacar que este trabajo supone un primer paso para el estudio del deslizamiento en correas, su parametrización y clasificación. Se pretendía realizar una primera prueba para verificar la relación entre vibraciones y deslizamiento, de ahí el bajo número de mediciones. Por lo tanto, los investigadores pretenden continuar desarrollando este trabajo realizando más mediciones de deslizamientos en correas, así como analizar los comportamientos en diferentes tipos de correas y maquinarias.

## Agradecimientos

A los fondos FEDER, Programa Interreg MAC 2021-2027, en el marco del proyecto IDIWATER (1/MAC/1/1.1/0022), el cual se integra dentro de la plataforma DESAL+ Living Lab (<https://www.desalinationlab.com>) y también gracias al apoyo de El Gobierno de España, Programa I+D+I orientada a los retos de las Sociedad, Proyecto Nacional PID2020-116984RB-C21.

## Referencias

- Abdallah, I., Dertimanis, V., Mylonas, H., Tatsis, K., Chatzi, E., Dervili, N., . . . Maguire, E. (2018). Fault diagnosis of wind turbine structures using decision tree learning algorithms with big data. In *Safety and Reliability – Safe Societies in a Changing World*. Taylor & Francis Group.
- Abiodun, O., Jantan, A., Omolara, A., Dada, K., Mohamed, N., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11). doi:<https://doi.org/10.1016/j.heliyon.2018.e00938>
- Ali, A., & Abdelhadi, A. (2022). Condition-Based Monitoring and Maintenance: State of the Art Review. *Applied Sciences*, 12(2):688. doi:<https://doi.org/10.3390/app12020688>
- Arntz Optibelt Group. (2024). *Optibelt Power Transmission. Manual técnico para correas trapeciales*.
- Avila, D., Marichal, G., Cuba Arana, Y., & Quiza, R. (2023). Indirect Condition Monitoring of the Transmission Belts in a Desalination Plant by Using Deep Learning. In *Progress in Artificial Intelligence and Pattern Recognition* (Vol. 14335, pp. 167-176). Springer. doi:[https://doi.org/10.1007/978-3-031-49552-6\\_15](https://doi.org/10.1007/978-3-031-49552-6_15)
- Bagavathiappan, S., Lahiri, B., Philip, J., & Jayakumar, T. (2013). Infrared thermography for condition monitoring – A review. *Infrared Physics & Technology*, 60, 35-55. doi:<https://doi.org/10.1016/j.infrared.2013.03.006>
- Cao, Y., Ji, Y., Sun, Y., & Su, S. (2023). The Fault Diagnosis of a Switch Machine Based on Deep Random Forest Fusion. *IEEE Intelligent Transportation Systems Magazine*, 15(1), 437-452. doi:<https://doi.org/10.1109/MITS.2022.3174238>
- Chen, J., & Liu, Y. (2022). Fatigue modeling using neural networks: A comprehensive review. *Fatigue & Fracture of Engineering Materials & Structures*, 45(4), 945-979. doi:<https://doi.org/10.1111/ffe.13640>
- Chen, S., Cowan, C., & Grant, P. (1991). Orthogonal Least Squares Learning Algorithm for Radial. *IEEE Trans. Neural Networks*, 302-309.
- Cordón, O., Herrera, F., Gomide, F., Hoffmann, F., & Magdalena, L. (2001). Ten years of genetic fuzzy systems: current framework and new trends. In IEEE (Ed.), *Proceedings joint 9th IFSA world congress and 20th NAFIPS international conference* (Cat. No. 01TH8569), 3, pp. 1241-1246.
- Doyle, T., & Samavi, R. (2022). MLCM: Multi-Label Confusion Matrix. *IEEE Access*, 10, 19083-19095. doi:<https://doi.org/10.1109/ACCESS.2022.3151048>
- He, Q., Zheng, H., Ma, X., Wang, L., Kong, H., & Zhu, Z. (2022). Artificial intelligence application in a renewable energy-driven desalination system: A critical review. *Energy and AI*, 7, 100-123.
- Hoo, Z., Candlish, J., & Teare, D. (n.d.). What is an ROC curve? *Emergency Medicine Journal*, 34(6). doi:<https://doi.org/10.1136/emmermed-2017-206735>
- Jang, J. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
- Jombo, G., & Zhang, Y. (2022). Acoustic-Based Machine Condition Monitoring—Methods and Challenges. *Eng*, 4(1), 47-79. doi:<https://doi.org/10.3390/eng4010004>
- Kátaí, L., Szendrő, P., & Gárdonyi, P. (2016). The power transmission stability and efficiency of V-belts. In *Progress in Agricultural Engineering Sciences* (Vol. 12, pp. 25-49). doi:<https://doi.org/10.1556/446.12.2016.2>
- Kohonen, T. (1990). The Self-Organizing Map. *IEEE*, (pp. 1464-1480).
- Laouti, N., Sheibat-Othman, N., & Othman, S. (2011). Support Vector Machines for Fault Detection in Wind Turbines. *IFAC Proceedings Volumes*, 44(1), 7067-7072. doi:<https://doi.org/10.3182/20110828-6-IT-1002.02560>
- Li, C., Valente de Oliveira, J., Cerrada, M., Cabrera, D., Sánchez, R., & Zurita, G. (2019). A Systematic Review of Fuzzy Formalisms for Bearing Fault Diagnosis. *IEEE Transactions on Fuzzy Systems*, 27(7), 1362-1382. doi:<https://doi.org/10.1109/TFUZZ.2018.2878200>
- Liang, J. (2022). Confusion matrix: Machine learning. *POGIL Activity Clearinghouse*, 3(4).
- Lin, T., Tan, A., Ma, L., & Mathew, J. (2014). Condition monitoring and fault diagnosis of diesel engines using instantaneous angular speed analysis. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 229(2). doi:<https://doi.org/10.1177/0954406214533253>
- Lopez de Lacalle, L., & Posada, J. (Eds.). (2020). *New Industry 4.0: Advances in Industrial IoT and Visual Computing for Manufacturing Processes*. Applied Sciences. MDPI. Retrieved from [https://mdpi-res.com/bookfiles/book/2109/New\\_Industry\\_40\\_Advances\\_in\\_Industrial\\_IoT\\_and\\_Visual\\_Computing\\_for\\_Manufacturing\\_Processes.pdf?v=1743469326](https://mdpi-res.com/bookfiles/book/2109/New_Industry_40_Advances_in_Industrial_IoT_and_Visual_Computing_for_Manufacturing_Processes.pdf?v=1743469326)
- Marichal, G., Hernández, Á., Ávila, D., & García-Prada, J. (2024). Classification of Belts Status Based on an Automatic Generator of Fuzzy Rules Base System. *applied sciences*, 14(5), 1831. doi:<https://doi.org/10.3390/app14051831>
- Mehala, N. (2010). *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*. A Ph. D Thesis submitted to the Electrical Engineering Department, National Institute of Technology, Kurushetra, India.
- Nobre, F. (1995). Genetic-neuro-fuzzy systems: A promising fusion. *IEEE International Conference Fuzzy Systems*, (pp. 259-266).
- Perera, C., Zaslavsky, A., Christen, P., & Georgakopoulos, D. (2013). Context Aware Computing for The Internet of Things: A Survey. *IEEE Communications Surveys & Tutorials*, 16, 414-454. doi:<https://doi.org/10.1109/SURV.2013.042313.00197>
- Rajasekaran, S., & Pai, G. (2003). *Neural Networks, Fuzzy Logic and Genetic Algorithm: Synthesis and Applications*. PHI Learning Pvt. Ltd.
- Zamorano, M., Ávila, D., Marichal, G., & Castejón, C. (2022). Data preprocessing for vibration analysis: Application in indirect monitoring of ship centrifuge lube oil separation systems. *10(9)*, 1199. doi:Journal of Marine Science and Engineering
- Zhang, Y., Rajagopalan, S., & Salman, M. (2010). A practical approach for belt slip detection in automotive electric power generation and storage system. *2010 IEEE Aerospace Conference* (pp. 1-7). Montana: IEEE. doi:<https://doi.org/10.1109/AERO.2010.5446832>
- Zonta, T., da Costa, C., da Rosa Righi, R., de Lima, M., da Trindade, E. S., & Pyng Li, G. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. In *Computer & Industrial Engineering* (Vol. 150). Elsevier. doi:<https://doi.org/10.1016/j.cie.2020.106889>