



DIAGNÓSTICO DE ENGRANAJES EN SISTEMAS DE PROPULSIÓN MARINOS UTILIZANDO TÉCNICAS ANFIS

G.N. MARICHAL^{1,2}, M.L. DEL CASTILLO¹, J. LÓPEZ³, I. PADRÓN², M. ARTÉS¹

¹Universidad Nacional de Educación a Distancia (UNED)
Departamento de Mecánica

C/ Juan del Rosal 12, 28040 Madrid. España

²Universidad de La Laguna. Escuela Superior de Ingeniería
Av. Astrofísico Francisco Sánchez s/n, 38206 La Laguna, Tenerife. España

³Universidad Carlos III de Madrid

Departamento de Ingeniería Mecánica
Av. Universidad, 30, 28911 Leganés, Madrid. España

(Recibido 5 de febrero de 2016, para publicación 24 de febrero de 2016)

Resumen – En este trabajo se aplican nuevas técnicas de diagnóstico para el mantenimiento basado en condición de diferentes sistemas de propulsión de pequeños vehículos marinos que utilizan hélices para el desplazamiento y que se utilizan de forma habitual en entornos marinos. En todos estos casos uno de los elementos de mayor interés es el análisis del correcto funcionamiento de las cajas reductoras. El determinar con suficiente anticipación posibles fallos es de vital importancia en ambientes marinos, donde las averías se pueden producir en condiciones muy adversas. Concretamente el estudio se ha centrado en el diagnóstico de defectos incipientes en los engranajes utilizando técnicas basadas en inteligencia artificial con la finalidad de determinar la aparición del defecto incipiente y el tipo de defecto. Se ha realizado la toma de datos de un conjunto de engranajes defectuosos y normales para, posteriormente, realizar ensayos con las técnicas citadas. Los resultados obtenidos muestran la potencialidad de estas nuevas técnicas, presentándose en este artículo resultados satisfactorios en los ensayos realizados.

Palabras clave – Vibraciones, diagnosis, inteligencia artificial, monitorización basada en condición, engranajes.

1. INTRODUCCIÓN

La presencia de un sistema de propulsión basado en hélices es muy habitual en cualquier tipo de vehículo marino [1]. Uno de los elementos esenciales en este tipo de propulsión son las cajas reductoras, encargadas de transmitir potencia entre ejes y que permiten acondicionar de forma efectiva la relación velocidad-par a las condiciones de operación. En la Fig. 1 y la Fig. 2 se pueden ver dos ejemplos de estos sistemas. En el primer caso se trata de un sistema de propulsión de tamaño reducido diseñado para aumentar la operatividad de los buceadores y en el segundo se observa una caja reductora de una embarcación de pequeño calado. Tanto en los dispositivos de pequeño tamaño como en los más grandes surge la necesidad de utilizar técnicas que permitan detectar con suficiente antelación los fallos en los dispositivos. Con esta finalidad, se ha introducido el denominado mantenimiento basado en condición (MBC), también conocido, por sus siglas en inglés, como *condition-based maintenance* (CBM) [2] [3] [4]. Este tipo de mantenimiento tiene la ventaja de necesitar un menor nivel de intervención humana permitiendo automatizar el proceso e influyendo en el nivel de acierto.

En este artículo le prestamos especial atención a las técnicas de diagnóstico de los engranajes de las cajas reductoras. Obsérvese, que dado el ambiente marino en el que estos dispositivos están inmersos, a pesar de realizar operaciones de mantenimiento de forma habitual, tal como el comprobar que todos los componentes se hayan correctamente lubricados, el ambiente tan adverso supone una constante amenaza respecto al deterioro de estos elementos. Adicionalmente, al estar estos vehículos navegando en zonas marítimas de difícil acceso, resulta de gran importancia el conservar al máximo el grado de autonomía de




Fig. 1. Dispositivo de propulsión basado en hélice de ayuda al submarinismo.




Fig. 2. Eje y reductora de la hélice de un barco de pequeña eslora.

los mismos desde el punto de vista del mantenimiento dado que, entre otras consideraciones, únicamente se dispone en la embarcación de los repuestos de los componentes más críticos y en cantidad mínima siempre y cuando las dimensiones del vehículo marino lo permitan.

Estas consideraciones llevan a elaborar estrategias de mantenimiento predictivo [5-10] que permitan determinar con suficiente antelación posibles defectos incipientes, de tal forma que se puedan reponer o reparar con suficiente anticipación los elementos dañados, evitando que en un estadio más avanzado del defecto se produzca una avería que merme considerablemente la operatividad del vehículo marino.

En este trabajo nos hemos centrado en la determinación de fallos incipientes basándonos en la adquisición y análisis de señales de vibración [11]. Concretamente, diferentes investigadores han propuesto diversas técnicas de procesamiento basadas en diferentes aspectos de las señales [2] [9]. En el caso expuesto en este artículo nos hemos centrado en técnicas basadas en Inteligencia Artificial [12-16].

2. ADQUISICIÓN DE SEÑALES DE VIBRACIÓN

Tal como se ha indicado en el apartado anterior, el objetivo de este estudio se centró en la determinación del estado de los engranajes de las reductoras mediante la adquisición de señales de vibración y en su análisis posterior. Al objeto de realizar los experimentos se utilizó una bancada como la que se muestra en la Fig. 3, para permitir el montaje de un par de engranajes y realizar la adquisición de las señales de vibración sobre este conjunto. Los ensayos se realizaron con diferentes pares de engranajes de material polimérico a los que se le produjeron diferentes defectos en el laboratorio mediante un punzón eléctrico. Concretamente, los defectos considerados fueron el rayado de un diente del engranaje y la rotura parcial del mismo.




Fig. 3. Bancada de prueba de engranajes.

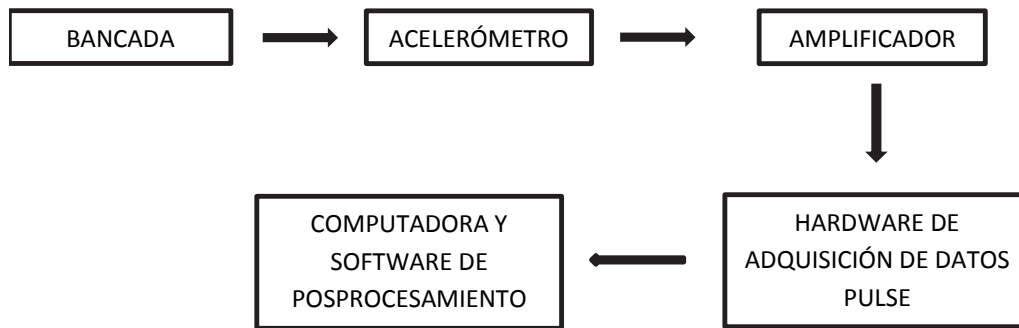


Fig. 4. Esquema de las diferentes partes del sistema de captura y procesamiento.

En la captura de la señal se ha empleado un acelerómetro conectado a un amplificador acondicionador de señal y al sistema de adquisición de datos y tratamiento de la señal PULSE, específicamente el Sistema Multianalizador Tipo 3560 (*Multi-analyzer System Type 3560*) de Brüel & Kjaer. El acelerómetro BK 4383 utilizado es un acelerómetro piezoeléctrico de propósito general, empleado frecuentemente para la medida y análisis de vibraciones. Este acelerómetro se montó sobre el portarrodamientos, al objeto de posicionarlo lo más cerca del engranaje en estudio y se conectó al sistema de captura y procesamiento de señales PULSE antes indicado. Este sistema consiste en un computador, conectado mediante una interface LAN a un sistema de adquisición hardware.

Adicionalmente se incluye un software PULSE de procesamiento que opera sobre sistemas operativos Microsoft Windows. El sistema de adquisición hardware es un dispositivo alimentado por corriente continua o batería, que incluye un modelo de interface de comunicaciones LAN tipo 7533 y un módulo de entrada/salida con 4 canales de entrada y dos de salida tipo 3109. Dichas entradas se conectan a los acelerómetros. El sistema soporta señales en el rango de frecuencia de 0 a 25.6 KHz, además de poder operar con acelerómetros DeltaTron y ICP a través de la tecnología CCLD (*Constant Current Line Drive*).

En la Fig. 4 se muestra un esquema funcional donde se ilustran las diferentes partes del sistema de captura y procesamiento de las señales de vibración:

3. PROCESAMIENTO DE LAS SEÑALES

3.1. Selección de la técnica

El primer paso en el procesamiento de las señales obtenidas es expresarlas en alguna forma, ya sea en el dominio del tiempo, en el dominio de la frecuencia o, en su caso, en el dominio tiempo-frecuencia. En este sentido, diferentes investigadores optan por varias formas de representación. En el caso presentado en este trabajo se ha optado por expresar las señales en el dominio de la frecuencia. Si bien caben otras

representaciones, la elección viene determinada por el objetivo de pre-procesar las señales de la forma menos compleja posible con el fin de no restringir las posibilidades de procesamiento del algoritmo de Inteligencia Artificial. Por ello en este caso se ha optado por tomar el espectro de cada señal en el dominio de la frecuencia. Este es un tipo de pre-procesamiento de las señales bastante extendido, lo cual permite disponer de muchas herramientas tanto a nivel de hardware como de software.

Adicionalmente, se ha de seleccionar la técnica, dentro del campo de la Inteligencia Artificial, que se va a aplicar a estos primeros datos. En el caso presentado en este trabajo se ha elegido un una técnica de tipo ANFIS utilizando un sistema neuro-fuzzy dado que aglutina por un lado la capacidad de aprendizaje inherente a las redes neuronales y la capacidad de expresión de la solución en forma de reglas, concretamente reglas de carácter borroso (fuzzy). Los sistemas *borrosos* y las redes neuronales son diferentes formas de presentar una solución. Ambos paradigmas se pueden considerar sendas aproximaciones a la modelización de sistemas expertos. Si el conocimiento es más susceptible de ser representado mediante reglas, la opción más acertada parece ser la de los sistemas *borrosos*. Sin embargo, en los casos en los que disponemos de datos, ya sean provenientes de la simulación o del modelo real, las redes neuronales parecen la solución más acertada. Hayashi and Buckley [16] concluyeron que cualquier sistema *borroso* basado en reglas se puede aproximar por una red neuronal y que cualquier red neuronal *feedforward* puede ser aproximada por un sistema *borroso* basado en reglas.

Como primera consideración en la aplicación de este tipo de sistemas se ha de buscar una forma conveniente de expresar los datos de espectro obtenidos para ser usados como entradas al sistema neuro-fuzzy. Un aspecto que se ha de considerar es que el número de entradas de los sistemas neuro-fuzzy suele tener una limitación, dado que un alto número de entradas hace más compleja la fase de aprendizaje, además de hacer que el sistema neuro-fuzzy presente un número muy elevado de nodos. Estas consideraciones hacen conveniente reducir en lo posible el número de datos del espectro de cada tipo de engranaje defectuoso o normal. No obstante, el número no ha de ser tan pequeño como para correr el riesgo de perder información esencial para el proceso de detección y clasificación. Tomando en consideración este compromiso, el número de entradas se ha seleccionado inferior a ciento diez, dado que los resultados obtenidos para estos casos han avalado esta elección. Determinado el número de entradas, se ha de buscar una forma de transformar la señal espectral en un número de valores que correspondan a ese número de entradas del sistema neuro-fuzzy. Para ello, se ha optado por dividir la señal vibratoria en bandas de unas pocas frecuencias, de tal forma que en cada banda tomemos un valor significativo. Concretamente se han utilizado bandas de 15 o 25 frecuencias. En las primeras fases del trabajo se optó por tomar la media de la densidad espectral de la banda, sin embargo, posteriormente se ha optado por tomar el valor máximo de la banda, en la suposición de que el máximo sería un valor más significativo en la determinación de posibles zonas resonantes. Por tanto, se han considerado estos valores como entradas al sistema neuro-fuzzy y no la señal espectral de datos original, al objeto de reducir el número de entradas resultante.

El sistema neuro-fuzzy utilizado es similar al conocido como sistema de inferencia *borroso* basado en una red adaptativa. Respondiendo en la terminología inglesa al término *Adaptive-Network-Based Fuzzy Inference System (ANFIS)* [17]. El planteamiento consiste en utilizar un método de aprendizaje adaptativo, es decir, partiendo de un conjunto de datos de entrada/salida, se elabora un Sistema de Inferencia Borroso (FIS). En este caso, solamente se han considerado tres capas. En la Fig. 5 se muestra esta estructura.

La primera capa o capa de entrada está constituida por varios nodos, cada uno consistente en una neurona de base radial. Las entradas a las neuronas de base radial son las entradas del sistema neuro-fuzzy. En el caso estudiado, son los máximos de las diferentes bandas del espectro de vibraciones. Las salidas de estos nodos responden a las siguientes ecuaciones:

$$s_{ij} = \exp \left(- \frac{(I_i - m_{ij})^2}{\sigma_{ij}^2} \right) \quad \begin{array}{l} j = 1, 2, \dots, \text{Num}_2 \\ i = 1, 2, \dots, \text{Num}_1 \end{array} \quad (1)$$

siendo:

m_{ij} = Centro de la Función de Pertenencia correspondiente a las entrada i -ésima y la neurona j -ésima de la neurona de la segunda capa.

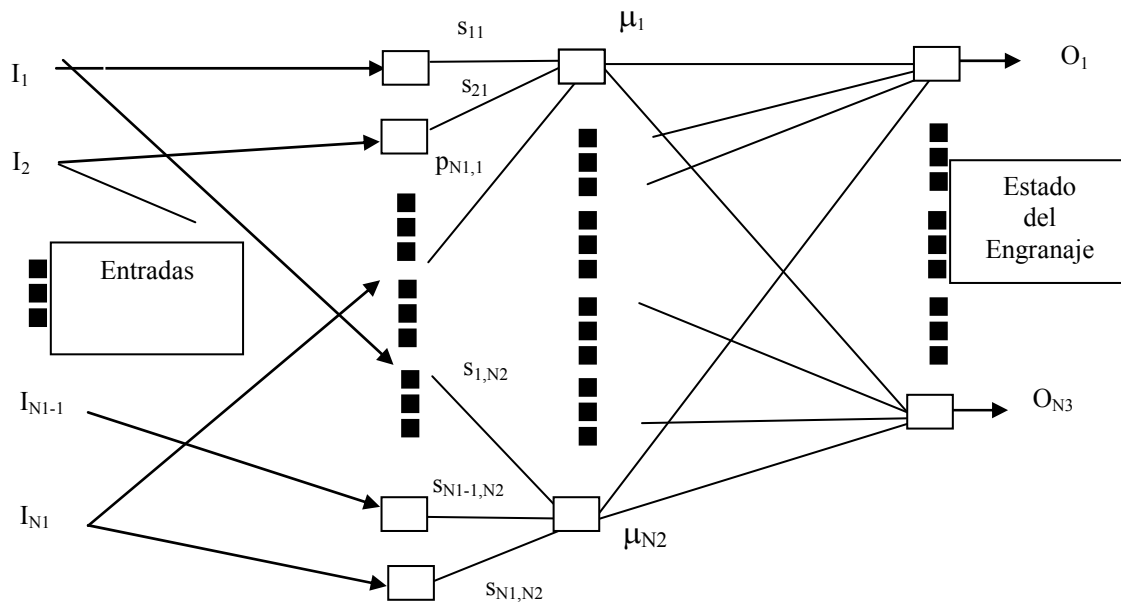


Fig. 5. Estructura del Sistema neuro-fuzzy.

I_i = Entrada i -ésima al sistema neuro-fuzzy.

σ_{ij} = Anchura de la función de correspondencia de la entrada i -ésima y la neurona j -ésima de la segunda capa.

s_{ij} = Salida de la neurona de base radial (o grado de pertenencia para la entrada i -ésima, correspondiente a la neurona j -ésima).

Num2 = Número de nodos en la segunda capa.

Num1 = Número de entradas del sistema neuro-fuzzy.

Por otro lado, las salidas de los nodos de la segunda capa o capa oculta se calculan de esta forma:

$$\mu_j = \min[s_{1j}, s_{2j}, \dots, s_{ij}, \dots, s_{N1j}] \quad j = 1, 2, \dots, Num_2 \quad (2)$$

Siendo:

μ_j = Salida del nodo j -ésimo de la capa oculta.

Finalmente, la tercera capa o capa de salida se podría considerar como una capa de neuronas con una función de activación lineal, donde los pesos de conexión entre la capa oculta y la capa de salida son lo que denominaremos valores estimados de las salidas. Las salidas de estos nodos pueden ser calculadas según la siguiente fórmula:

$$O_k = \frac{\sum_j \eta_{jk} \mu_j}{\sum_j \mu_j} \quad \begin{matrix} j = 1, 2, \dots, Num_2 \\ k = 1, 2, \dots, Num_3 \end{matrix} \quad (3)$$

donde:

O_k = k -ésima salida del sistema neuro-fuzzy.

η_{jk} = Valor estimado de la k -ésima salida proporcionado por la k -ésima salida del nodo j -ésimo en la capa oculta.

Num3 = Número de salidas del sistema neuro-fuzzy.

El sistema neuro-fuzzy viene determinado por tres grupos de parámetros que son: los centros de las funciones de pertenencia, las anchuras de las funciones de pertenencia y los denominados valores estimados de las salidas. Una vez definidos estos parámetros, se pueden aplicar las ecuaciones descritas previamente, al objeto de obtener las salidas del sistema neuro-fuzzy para cualquier entrada. El proceso de elección de estos parámetros es lo que denominamos proceso de aprendizaje.

3.2. Proceso de aprendizaje

En los sistemas neuro-fuzzy, es habitual aplicar el algoritmo de aprendizaje en dos fases [18] [19]. La primera fase se focaliza en la obtención de unos valores iniciales para los parámetros indicados en la sección previa. De hecho, en algunas aproximaciones esta fase se aprovecha para realizar un proceso de optimización que nos permita minimizar el número de nodos en la capa oculta. Es decir, se termina realizando una reducción del número de reglas asociada al sistema neuro-fuzzy. Realizada esta primera fase de aprendizaje se obtiene un sistema borroso tipo Sugeno [20] de orden cero. Los sistemas *borrosos* tipo Sugeno se caracterizan por una estructura de reglas con antecedentes en la forma *borrosa*, mientras que los consecuentes responden más a una expresión funcional. Por tanto, podemos ilustrar las reglas de este tipo de sistema *borroso*, de la siguiente forma:

$$R: \text{ Si } x_1 \in A_1^i \text{ y } x_2 \in A_2^i \dots \text{ y } x_n \in A_n^i \text{ entonces } s^i = a_0^i + a_1^i x_1 + a_2^i x_2 + \dots + a_n^i x_n$$

Posteriormente, la segunda fase se concentra en el refinamiento de este conjunto de parámetros, tomando como base los valores obtenidos en la primera fase. En [12] [13] se detalla este proceso de aprendizaje para la red tipo Jang [17], presentada en el apartado 2.1.

4. RESULTADOS

Tal como se indicó anteriormente, se han realizado los experimentos sobre una muestra de engranajes a los que se les ha provocado manualmente defectos. Se partió de los datos espectrales recogidos a partir del sistema de captura y procesamiento mostrado en la Fig. 4. Se procedió a dividir el espectro en bandas de unas pocas frecuencias tomando el máximo de la banda. Concretamente, se probaron bandas de 15 y 25 frecuencias, respectivamente. De este modo, el número de entradas se redujo aproximadamente a 108 en el caso de 25 frecuencias. En principio, se ha abordado el problema de la detección de fallos diseñando un sistema neuro-fuzzy con tres salidas, correspondientes cada una de ellas a las diferentes situaciones posibles del estado de los engranajes (normal, rayado, rotura parcial de diente) utilizados en los experimentos. De tal forma que la salida correspondiente daría un valor cercano a uno, si dicha situación se diese para el engranaje particular sometido a evaluación. Sin embargo, los primeros ensayos mostraron la gran dificultad del sistema neuro-fuzzy para llegar a un buen resultado, manifestándose claramente en un comportamiento muy lento del algoritmo de aprendizaje o en ocasiones en producir situaciones de divergencia en los mismos. Estos primeros resultados plantearon la posibilidad de llevar a cabo el proceso de diagnóstico en forma de árbol. Es decir, inicialmente se determinaría si el engranaje es normal o defectuoso. Si efectivamente, fuese defectuoso, se consideraría la posibilidad de que el defecto se produjese por rayado del diente o por rotura parcial del diente. Como se puede observar el sistema de diagnóstico se reduce a la determinación de dos sistemas neuro-fuzzy que realicen la tarea específica de diagnóstico en forma de árbol.

Inicialmente se utilizó para el conjunto de entrenamiento un 60% por ciento de los datos, reservándose un conjunto del 40% de los datos para probar la generalización. Concretamente, se ha intentado clasificar entre engranajes defectuosos o normales. En particular el ensayo que se muestra en la tabla 1 corresponde a un entrenamiento donde se ha comenzado con 300 reglas para acabar después del entrenamiento con 149 reglas. Obsérvese que en este caso se ha obtenido un error cuadrático medio de 0.012105 para los patrones utilizados en el entrenamiento que implica que todos los patrones son clasificados de forma correcta.

Tabla 1. Resultados del sistema neuro-fuzzy para un conjunto del 60% del total de patrones utilizados en el proceso de aprendizaje, clasificando entre engranajes normales y defectuosos.

Señales espectrales de vibración (tipo de Engranaje)	Salida 1ª del Sistema Neuro-Fuzz	Salida 2ª del Sistema Neuro-Fuzzy
Normal	0.99237	0.007627
Normal	0.91329	0.086709
Normal	0.97701	0.022987
Normal	0.80697	0.19303
Normal	0.99955	0.00045197
Normal	0.96057	0.039431
Rayado	0.018209	0.98179
Rayado	0.28611	0.71389
Rayado	1.4328e-007	1
Rayado	2.2462e-008	1
Rayado	0.28906	0.71094
Rayado	0.0045712	0.99543
Rotura parcial diente	6.0193e-146	1
Rotura parcial diente	8.913e-015	1
Rotura parcial diente	7.0463e-160	1
Rotura parcial diente	2.2737e-015	1
Rotura parcial diente	0.037682	0.96232
Rotura parcial diente	0.061496	0.9385

Tabla 2. Resultados del sistema neuro-fuzzy para el conjunto de patrones de señal de vibración de engranajes reservados, siendo el 40% de los patrones totales.

Señales espectrales de vibración (tipo de Engranaje)	Salida 1ª del Sistema Neuro-Fuzzy	Salida 2ª del Sistema Neuro-Fuzzy
Normal	1.6463e-055	1
Normal	0.94526	0.054738
Normal	0.37214	0.62786
Normal	0.8606	0.1394
Rayado	0.50851	0.49149
Rayado	6.026e-132	1
Rayado	0.17753	0.82247
Rayado	0	1
Rotura parcial diente	0.71869	0.28131
Rotura parcial diente	0.030914	0.96909
Rotura parcial diente	0.052122	0.94788
Rotura parcial diente	0.19629	0.80371

En la tabla 2 se muestran los valores cuando se toman los patrones no utilizados en la fase de entrenamiento. Es decir, el cuarenta por ciento de los patrones reservados para estudiar las propiedades de generalización del sistema de diagnóstico resultante. En este caso se producen tres errores de clasificación indicados mediante un sombreado en la tabla, siendo el valor del error cuadrático medio para estos patrones de generalización igual a 0.18879.

Por su parte, en la tabla 3 se muestran los resultados correspondientes a la determinación entre engranajes defectuosos y normales tomando en consideración un 70% de patrones para el entrenamiento y un 30% para la generalización, llevando el algoritmo de aprendizaje a unas 10000 iteraciones. El error cuadrático medio se sitúa en 0.045157. Como se puede observar una vez concluido el proceso de aprendizaje sólo uno de los patrones produce un error de clasificación en el sistema neuro-fuzzy. En la tabla 3 se ha señalado en sombreado.

Adicionalmente, en la tabla 4 se muestran los valores obtenidos una vez que el sistema neuro-fuzzy ha concluido su proceso de aprendizaje para patrones no utilizados en el proceso de aprendizaje. Es decir, el

Tabla 3. Resultados del sistema neuro-fuzzy para un conjunto de patrones de señal de vibración de engranajes utilizados en el proceso de aprendizaje, clasificando entre engranajes normales y defectuosos.

Señales espectrales de vibración (tipo de Engranaje)	Salida 1ª del Sistema Neuro-Fuzzy	Salida 2ª del Sistema Neuro-Fuzzy
Normal	0.96283	0.037171
Normal	0.99998	2.0403e-005
Normal	0.8094	0.1906
Normal	0.84977	0.15023
Normal	0.96715	0.032849
Normal	0.99954	0.00045978
Normal	0.94284	0.057155
Rayado	0.0077273	0.99227
Rayado	0.41138	0.58862
Rayado	6.6267e-013	1
Rayado	9.9886e-010	1
Rayado	2.3398e-005	0.99998
Rayado	0.2066	0.7934
Rayado	0.057522	0.94248
Rotura parcial diente	1.2842e-011	1
Rotura parcial diente	4.2748e-012	1
Rotura parcial diente	1.7359e-011	1
Rotura parcial diente	0.70036	0.29964
Rotura parcial diente	0.4212	0.5788
Rotura parcial diente	0.0068461	0.99315
Rotura parcial diente	0.97954	0.97954

Tabla 4. Resultados del sistema neuro-fuzzy para un conjunto de patrones de señal de vibración de engranajes reservados para observar las propiedades de generalización del sistema.

Señales espectrales de vibración (tipo de Engranaje)	Salida 1ª del Sistema Neuro-Fuzzy	Salida 2ª del Sistema Neuro-Fuzzy
Normal	0.89738	0.10262
Normal	0.97032	0.029678
Normal.	0.60428	0.39572
Rayado	0.71154	0.28846
Rayado	0.007967	0.99203
Rayado	1.1312e-027	1
Rotura parcial diente	1.871e-019	1
Rotura parcial diente	5.9818e-006	0.99999

treinta por ciento de los patrones se han reservado para comprobar las propiedades de generalización del sistema de diagnóstico resultante. Como se puede apreciar en este caso se produce únicamente un error de clasificación que en la tabla se ha indicado en sombreado. Siendo en este caso el error cuadrático medio de 0.074929.

Obsérvese que en este caso el número de fallos en la clasificación en la generalización ha disminuido considerablemente, lo cual pudiera justificarse por el hecho de al utilizar una mayor número de patrones en el entrenamiento, las propiedades de generalización se han aprendido de mejor forma por parte del sistema neuro-fuzzy resultante.

De igual forma, en los estudios realizados se ha tomado en consideración la clasificación una vez determinado que el patrón corresponde a una situación de fallo, para establecer si dicho patrón corresponde a un engranaje con rayado en el mismo o a la rotura parcial de un diente. Se tomaron en este caso un 80% de patrones para el entrenamiento y un 20% para comprobar las propiedades de generalización. En la tabla 5 se muestran los resultados obtenidos en el caso de los patrones de entrenamiento, donde se ha

Tabla 5. Resultados del sistema neuro-fuzzy para el conjunto de patrones de señal de vibración correspondientes a los defectos de rayado y rotura de diente de engranajes, siendo el 80% de los patrones totales.

Señales espectrales de vibración (tipo de Engranaje)	Salida 1ª del Sistema Neuro-Fuzzy	Salida 2ª del Sistema Neuro-Fuzzy	Señales espectrales de vibración (tipo de Engranaje)
1	Rayado	0.99327	0.0067324
2	Rayado	0.99993	6.7822e-005
3	Rayado	0.90891	0.091085
4	Rayado	0.9585	0.041501
5	Rayado	1	1.0404e-007
6	Rayado	0.99508	0.0049167
7	Rayado	0.99431	0.0056916
8	Rayado	0.99999	5.5006e-006
9	Rotura parcial diente	3.7963e-008	1
10	Rotura parcial diente	0.00431	0.99569
11	Rotura parcial diente	9.3677e-007	1
12	Rotura parcial diente	0.082756	0.91724
13	Rotura parcial diente	2.626e-007	1
14	Rotura parcial diente	0.040314	0.95969
15	Rotura parcial diente	3.3112e-005	0.99997
16	Rotura parcial diente	0.01307	0.98693

Tabla 6. Resultados en generalización una vez que el sistema neuro-fuzzy ha sido entrenado y se ha probado con el 20% de patrones no utilizados en el entrenamiento.

Señales espectrales de vibración (tipo de Engranaje)	Salida 1ª del Sistema Neuro-Fuzzy	Salida 2ª del Sistema Neuro-Fuzzy	Señales espectrales de vibración (tipo de Engranaje)
1	Rayado	0.99756	0.0024413
2	Rayado	1	1.4304e-035
3	Rotura parcial diente	0.036254	0.96375
4	Rotura parcial diente	8.8261e-006	0.99999

partido de 200 reglas y finalmente el sistema neuro-fuzzy se ha simplificado a 103 reglas. De hecho el error cuadrático medio alcanzado es de 0.001174, sin detectarse ningún error en la clasificación.

Por su parte en la tabla 6 se presentan los resultados en generalización una vez que el sistema neuro-fuzzy ha sido entrenado y se ha probado con el 20% de patrones no utilizados en el entrenamiento. Como se puede observar las propiedades de generalización son adecuadas al no observarse ningún fallo en la clasificación, de hecho en este caso el error cuadrático medio se sitúa en 0.00033007.

5. CONCLUSIONES

En este artículo se ha presentado un esquema de clasificación basado en una técnica de inteligencia artificial, concretamente un tipo de sistema neuro-fuzzy. La aplicación de dicha técnica ha permitido la clasificación de engranajes entre normales y defectuosos así como a la determinación del tipo de defecto. En particular, el estudio se ha orientado a su aplicación en engranajes de sistemas de propulsión marinos, donde las condiciones de operación están afectadas de manera particular por ese ambiente. En los experimentos de laboratorio realizados en esta primera fase de la investigación se han obtenido resultados satisfactorios, mostrando un bajo índice de fallos por parte del sistema de diagnosis propuesto, y poniendo de manifiesto la influencia de disponer de un número suficiente de patrones para el entrenamiento en el resultado obtenido. Si bien en esta primera etapa del trabajo se han tomado en consideración únicamente dos tipos de fallos de carácter incipiente, los buenos resultados obtenidos sugieren que en futuros trabajos

se deberían abordar otros tipos de fallos incipientes, relacionados con la corrosión y otros fenómenos propios de los entornos marinos.

REFERENCIAS

- [1] Hodge, C., Williamson, S., Smith, S., Direct drive marine propulsion motors, International Congress on Electrical Machines (ICEM'02) (2002)
- [2] Rasmussen, M., Lippe, J., "Condition Monitoring on Ships," International Cooperation on Marine Engineering Systems Symposium (ICMES'87) 4th. (1987)
- [3] Jardine, A.K., Lin, D., Banjevic, D., "A review on machinery diagnostics and prognostics implementing condition-based maintenance", *Mechanical systems and signal processing*, **20**(7), 1483-1510 (2006)
- [4] Rafiee, J. *et al.*, "Intelligent condition monitoring of a gearbox using artificial neural network", *Mechanical systems and signal processing*, **21**(4), 1746-1754 (2007)
- [5] Tavner, P.J., "Review of condition monitoring of rotating electrical machines", *Electric Power Applications, IET*, **2**(4), 215-247 (2008)
- [6] Guiling, Ch. *et al.*, Modeling prognostic and health management system for shipboard electromechanical platform. In Robotics and Applications (ISRA), 2012 IEEE Symposium on. IEEE, 952-954 (2012)
- [7] Charchalis, A., "Diagnosing elements of ship propulsion of vibration measurement", *Journal of KONES*, **14**, 81-89 (2007)
- [8] Roemer, M.J. *et al.*, *Prognosis of rotating machinery components. Damage Prognosis: For Aerospace, Civil and Mechanical Systems*, Published Online (2005)
- [9] Rafiee, J., Rafiee, M.A., Tse, P.W., "Application of mother wavelet functions for automatic gear and bearing fault diagnosis", *Expert Systems with Applications*, **37**(6), 4568-4579 (2010)
- [10] Peng, Z.K., Chu, F.L., "Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography", *Mechanical systems and signal processing*, **18**(2), 199-221 (2004)
- [11] Smith, J.D., *Gear noise and vibration*, CRC Press (2003)
- [12] Marichal, G.N., Artes, M., Garcia-Prada, J.C., "An intelligent system for faulty bearing detection based on vibration spectra," *Journal of Vibration and Control*, **17**(6), 931-942 (2010)
- [13] Marichal, G.N. *et al.*, "Extraction of rules for faulty bearing classification by a neuro-fuzzy approach", *Mechanical Systems and Signal Processing*, **25**(6), 2073-2082 (2011)
- [14] Saxena, A., Saad, A., "Evolving an artificial neural network classifier for condition monitoring of rotating mechanical systems", *Applied Soft Computing*, **7**(1), 441-454 (2007)
- [15] Saravanan, N., Cholairajan, S., Ramachandran, K.I., "Vibration-based fault diagnosis of spur bevel gear box using fuzzy technique", *Expert systems with applications*, **36**(2), 3119-3135 (2009)
- [16] Hayashi, Y., Buckley, J.J., "Approximations between fuzzy expert systems and neural networks", *Int. J. Approx. Reas.*, **10**, 63-73 (1994)
- [17] Jang, J.-S.R., "ANFIS: Adaptive-Neuro-network-based Fuzzy Inference Systems", *IEEE Trans. on Systems, Man, and Cybernetics*, **23**, 665-685 (1993)
- [18] Chen, C.H., *Fuzzy Logic and Neural Networks Handbook*, Mc. Graw-Hill. Computer Engineering Series
- [19] (1996)
- [20] Mitra, S., Hayashi, Y., "Neuro-fuzzy rule generation: survey in soft computing framework", *IEEE Trans. Neural Networks*, **11**, 748-768 (2000)
- [21] Sugeno, M., *Industrial applications of fuzzy control*, Elsevier Science Pub. Co. (1985)

AGRADECIMENTOS

Este trabajo se ha financiado en el marco de los proyectos DPI2015-69325-C2-1-R, DPI2015-69325-C2-2-R del Ministerio de Economía y Competitividad y de la ETSII-UNED (ref. 2016-MEC25).

DIAGNOSIS OF GEARS IN MARINE PROPULSION SYSTEMS BY USING ANFIS TECHNIQUES

Abstract – In this work, new diagnostic techniques of condition based maintenance of different propulsion systems of small marine vehicles that use propellers for movement and are used widely in marine environments are applied. Determining potential failures well in advance is vital in marine environments where failures can occur in very adverse conditions. Specifically, the study has focused on the diagnosis of incipient faults in the gears using artificial intelligence techniques in order to determine the occurrence of an incipient defect and the type of defect. It has made data collection from a set of defective gear and a normal one to then carry out tests with those techniques. In this paper satisfactory tests results are presented that show the potential of these new techniques.

Keywords – Vibrations, Diagnostic, Artificial intelligence, Condition Based Monitoring, Gears.

