

# DetECCIÓN AUTOMÁTICA DE FALLAS DE BALEROS EN UN PROCESO DE MANUFACTURA: UN ESTUDIO COMPARATIVO

Hugo Jair Escalante<sup>A,B</sup>, Katia Espinosa Guevara<sup>C</sup>,  
Arturo Berrones Santos<sup>A</sup>, Mario A. Saucedo Espinosa<sup>A</sup>

<sup>A</sup> División de Posgrado en Ingeniería de Sistemas, FIME, UANL

<sup>B</sup> Coordinación de Ciencias Computacionales, INAOE, Tonantzintla, Puebla

<sup>C</sup> Instituto Tecnológico de El Mante, Cd. Mante, Tamaulipas

hugojair@inaoep.mx, ing.katia.guevara@gmail.com,

arturo@yalma.fime.uanl.mx, mario@yalma.fime.uanl.mx



## RESUMEN

*Se presenta un estudio comparativo de diferentes técnicas de aprendizaje computacional para la detección automática de fallas de baleros durante un proceso de manufactura. El objetivo es reducir costos por el pago de garantías e incrementar el prestigio de la marca. Mediciones recolectadas por sensores acústicos en línea de producción generan señales asociadas con el componente bajo estudio. A partir de las señales generadas se desea determinar si los baleros son defectuosos o no antes de que el producto salga a la venta. Se propone una solución basada en aprendizaje computacional y se evalúan diversas técnicas de clasificación. La mayoría de los métodos obtienen resultados aceptables, dando evidencia de la viabilidad del enfoque propuesto. Los métodos basados en similitud obtienen los mejores resultados en cuanto a efectividad de detección, además de que son fáciles de implementar y altamente eficientes.*

## PALABRAS CLAVE

DetECCIÓN de fallas, baleros, aprendizaje computacional, reconocimiento de patrones, procesamiento de señales acústicas, automatización de procesos de manufactura.

## ABSTRACT

*This paper presents a comparative study of different machine learning techniques for the automated detection of bearing faults in a manufacturing process. The goal is to reduce costs derived from the payment of guaranty policies. Measurements collected by acoustic sensors provide signals associated with bearings of a manufactured product. These signals are used to determine whether bearings are defective or not before the product is put on sale. A solution based on machine learning is proposed and diverse methods are evaluated. Most of the tested techniques obtained acceptable performance, giving evidence of the effectiveness of the proposed approach. Similarity-based methods obtained the best performance across the considered techniques, besides accuracy this type of methods are easy to implement and highly efficient.*

## KEYWORDS

Fault detection, bearings, machine learning, pattern recognition, acoustic signal processing, automation of manufacturing processes.

## INTRODUCCIÓN

En la industria manufacturera la detección temprana de fallas en los componentes del producto que se fabrica es de vital importancia. El no detectar un componente defectuoso en un producto implica que éste dejará de funcionar mucho tiempo antes de que expire la garantía del producto. Lo que a su vez tiene repercusiones económicas para la empresa, además de afectar su prestigio en el mercado.

El evaluar si un componente del producto es defectuoso o no representa un gran reto para el personal de control de calidad, puesto que un producto puede funcionar a pesar de que alguno de sus componentes tenga algún defecto de fabricación. El problema es aún más complicado en situaciones donde los componentes están localizados dentro del producto, y donde no se pueden realizar mediciones directas del componente, sino que la funcionalidad del último se juzga usando mediciones indirectas o externas.

Este trabajo presenta un estudio comparativo de los principales métodos de clasificación supervisada en la tarea de detectar baleros defectuosos instalados en cierto producto fabricado por una empresa manufacturera a partir de señales de sonido. El tipo de fallas que se desea detectar es cuando el balero falla después de que el producto se pone en funcionamiento. El tipo de producto y el proceso de fabricación hacen imposible colocar sensores en el componente bajo estudio, por lo que la única forma de evaluar la funcionalidad del componente es colocando sensores fuera del producto y realizando mediciones de señales acústicas o vibratorias cuando el producto está en funcionamiento.

Un conjunto de mediciones recolectadas y etiquetadas por personal de la empresa se usa para implementar diversos métodos de aprendizaje

computacional capaces de detectar fallas automáticamente. El conjunto de datos original es procesado para tratar de disminuir los niveles de ruido inherentes al proceso de medición. Se presentan resultados experimentales de la evaluación de diversos métodos de clasificación. El estudio muestra que se pueden obtener resultados aceptables con algunos de los métodos evaluados, aunque existen ciertos clasificadores que ofrecen mayores beneficios en términos de efectividad de detección e interpretación. El aplicar métodos de procesamiento de datos incrementa la efectividad de detección de la mayoría de las técnicas evaluadas.

## PROCESO DE MANUFACTURA

Se considera el proceso de manufactura de un producto P, el cual cuenta, entre otros, con un balero, que es colocado en el producto en las primeras etapas del proceso de producción. Por la forma en que P es armado, no se tiene acceso al balero una vez que se ha ensamblado el producto. Para detectar fallas, se coloca un sensor en una cámara de pruebas donde el producto se pone a funcionar y se recopilan señales de sonido. Cada señal representa la potencia de sonido medida en decibeles a diferentes frecuencias. La figura 1 ilustra el enfoque abordado para la recopilación de datos.

Las señales generadas mediante el sensor son etiquetadas por expertos en detectar diferentes tipos de fallas del componente de manera empírica (e.g., escuchando el ruido generado por el producto en funcionamiento). Así, cada señal es etiquetada como señal de componente con falla o sin falla. La figura 2 muestra un subconjunto de señales etiquetadas generadas por el proceso que se ha descrito. En total se generaron 120 señales medidas en 24 frecuencias,




Fig. 1. Diagrama del enfoque abordado para la detección de fallas.

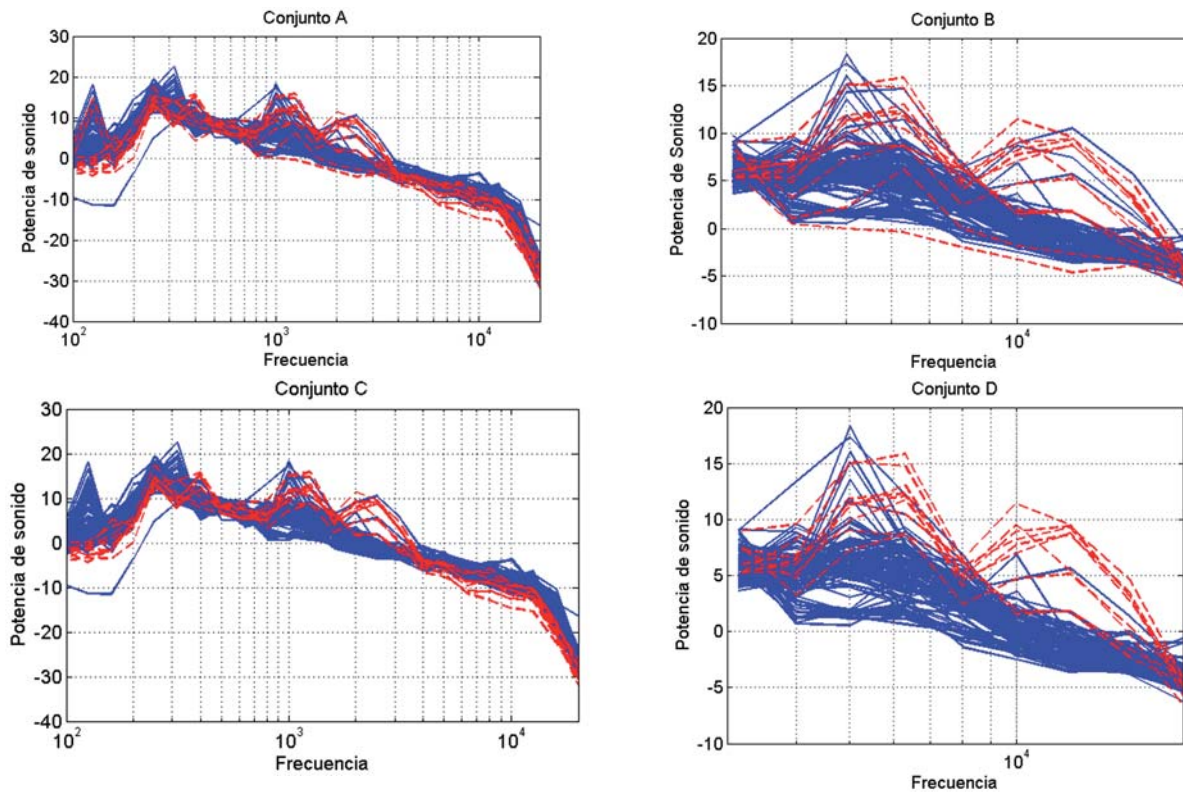


Fig. 2. Señales del componente bajo estudio. Se muestran los conjuntos considerados para experimentación, véase la tabla I. En azul (línea sólida) señales de componentes sin falla, en rojo (línea punteada) señales de componentes con falla.

109 de las señales fueron etiquetadas como no-falla y 11 con falla. Cabe mencionar que la recopilación de las señales se llevó a cabo en una cámara aislada de fuentes de ruido externas. Aunque, es imposible eliminar el ruido inherente al funcionamiento del producto. Por otro lado, cabe mencionar que los baleros son analizados visualmente antes de ser instalados en el producto, por lo que el tipo de falla que se desea detectar es aquel que ocurre cuando el balero entra en operación.

### DETECCIÓN AUTOMÁTICA DE FALLAS

El problema de detección de fallas se aborda como uno de clasificación o reconocimiento de patrones.<sup>1</sup> El objetivo es construir o aprender una función que permita asociar las señales con su etiqueta de estatus correcta (i.e., falla o no-falla). Dicha función se aprende usando el conjunto  $D$  compuesto por  $n$ -pares formados por las señales etiquetadas  $D = \{(\mathbf{x}_i, y_i)\}_n$ . Cada señal  $\mathbf{x}_i$  es un vector en  $\mathbb{R}^d$ , siendo  $d$  la dimensión de las señales y cada etiqueta  $y_i$  es un 1 o un 0, dependiendo si la señal presenta falla ( $y_i=1$ ) o no ( $y_i=0$ ). Entonces,

la función a aprender es de la forma:

$$f : \mathbb{R}^d \rightarrow \{0,1\} \tag{1}$$

El objetivo del reconocimiento de patrones consiste en aprender la función  $f$  de manera que se clasifiquen correctamente los ejemplos de entrenamiento  $D$ , véase la figura 3. Además  $f$  deberá ser capaz de mostrar una capacidad de generalización aceptable, esto es, la habilidad de clasificar ejemplos no vistos durante la construcción del modelo. La capacidad de generalización es lo que garantiza que la función se comportará bien en datos generados en la línea de producción.

Existen varias opciones para definir  $f$ , por ejemplo  $f$  puede ser una función lineal de la forma  $f(\mathbf{x})=w\mathbf{x}+b$ , o bien puede tratarse de un clasificador basado en los vecinos más cercanos,  $f(\mathbf{x}) = \frac{1}{k} \sum_{\mathbf{x}_i \in N_k(\mathbf{x})} y_i$ ,

donde  $N_k(\mathbf{x})$  es el conjunto de vecinos más cercanos a  $\mathbf{x}$ . Otros métodos populares incluyen las redes neuronales artificiales, los árboles de decisión, clasificadores Bayesianos, meta clasificadores, ensambles, entre otras opciones.<sup>1,2</sup>

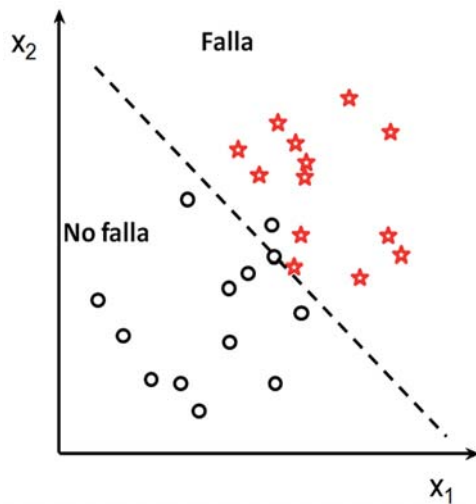


Fig. 3. Ilustración del problema de clasificación para las clases: falla (círculos) vs. no-falla (estrellas), para datos en dos dimensiones  $x_1$  y  $x_2$ .

### MÉTODOS DE CLASIFICACIÓN Y PROCESAMIENTO CONSIDERADOS

Como se menciona en la sección anterior, existe una gran variedad de alternativas para definir la función  $f$  en la ecuación (1). La pregunta que se quiere responder con este estudio es ¿Cuál es el mejor método de clasificación para implementarlo en un sistema automático para detección de fallas?

Para responder tal pregunta se seleccionó la herramienta WEKA,<sup>2</sup> la cual contiene implementaciones de algoritmos de aprendizaje altamente efectivos y muy conocidos en el área de aprendizaje automático.<sup>1,3</sup> Se consideraron todos los métodos de clasificación presentes en WEKA por lo que en total se consideraron 67 algoritmos de aprendizaje divididos en 5 grupos:

1. Métodos Bayesianos. (e.g., *naïve Bayes*, redes Bayesianas). Métodos probabilistas que se basan en teoría Bayesiana para hacer la clasificación.
2. Funciones. (e.g., Máquina de soporte vectorial, redes neuronales) Clasificadores que infieren una función (lineal o no lineal) que separa los datos de ambas clases.
3. Métodos basados en distancia. (e.g., *knn*). Métodos que se basan en similitud para asignar la clase a una instancia.
4. Meta clasificadores. (e.g., *Boosting*, *stacking*, *bagging*). Ensamblés y otro tipo de técnicas que

incorporan información de varios métodos de clasificación.

5. Árboles de decisión. (e.g., *ID3*, *J48*). Métodos de clasificación basados en árboles de decisión.
6. Reglas. (e.g., *Conjunctive rule*). Métodos de aprendizaje que se basan en la extracción de reglas para clasificación.

Tanto la división de métodos de aprendizaje en grupos como los mismos nombres de los grupos está dada por WEKA. Los métodos difieren en la forma de la función  $f$  y en la forma en que se aprende dicha función a partir de los datos en  $D$ , véanse<sup>2,3</sup> para mayores detalles.

El estudio comparativo consiste en evaluar la efectividad de los 67 métodos de clasificación. Para llevar a cabo la evaluación se utilizó validación cruzada tipo *leave-one-out* (LOO). Bajo este enfoque los datos disponibles,  $D$ , se dividen en  $n$ -partes (siendo  $n$  el número de observaciones en  $D$ ). Posteriormente el método de clasificación se entrena y prueba  $n$ -veces. En cada iteración de entrenamiento-prueba, se usan  $(n-1)$  observaciones para construir (entrenar) el clasificador y la efectividad del clasificador entrenado se evalúa en la  $n$ -ésima instancia (no usada para entrenar). Cada vez se reemplaza la instancia que se usa para evaluar. El desempeño del clasificador es el promedio de las evaluaciones en cada observación.

El uso de validación cruzada es recomendable para la evaluación y comparación de métodos de aprendizaje debido a que el usar la efectividad de los métodos de clasificación en el conjunto de entrenamiento puede llevar a conclusiones erróneas debido al problema del sobre ajuste de datos (3). En particular, validación cruzada tipo LOO es recomendable cuando el número de observaciones es pequeño.

Las medidas de evaluación consideradas son la exactitud (i.e., porcentaje de señales clasificadas correctamente), el área bajo la curva ROC, la tasa de ciertos positivos (TP) y falsos positivos (FP), la precisión, cobertura (i.e., *recall*) y medida  $f_1$  para la clase minoritaria. Todas las medidas anteriores están en el intervalo  $[0,1]$ . Entre mayor el valor de la medida más efectivo es el método de clasificación en evaluación.

### PREPROCESAMIENTO DE SEÑALES

Debido a la forma en que se recopilan las señales, éstas están sujetas a contener distintos niveles de ruido. Aunado a lo anterior, el proceso de etiquetado es completamente empírico, por lo que puede haber errores en el etiquetado provisto por el personal de la empresa. Por las razones anteriores el conjunto de datos provisto por la empresa fue pre-procesado antes de realizar el estudio comparativo.

La primera estrategia de pre-procesamiento consistió en identificar aquellas frecuencias en que señales con falla y sin falla eran indistinguibles. Esta etapa de procesamiento es común en aprendizaje automático y se conoce como selección de atributos.<sup>4</sup> Para hacer esta identificación se realizó un análisis estadístico complementado con inspección visual. De esta forma algunas frecuencias fueron identificadas como potencialmente ruidosas. En total se eliminaron 15 frecuencias por lo que la dimensionalidad de los datos se redujo de 24 a 9 frecuencias.

La segunda estrategia de pre-procesamiento consistió en identificar aquellas señales que potencialmente fueron mal etiquetadas por el personal de la empresa. Este tipo de procesamiento se conoce como selección de instancias. Se usó como criterio para detectar señales potencialmente ruidosas el coeficiente silueta (*silhouette coefficient*), véase la referencia<sup>5</sup> para una descripción del uso de este coeficiente en problemas de clasificación, dicho coeficiente esta dado por:

$$S(\mathbf{x}) = \frac{a(\mathbf{x}) - b(\mathbf{x})}{\max\{a(\mathbf{x}), b(\mathbf{x})\}} \quad (2)$$

donde  $a(x)$  es la distancia promedio de la señal  $x$  con todas las señales de su misma etiqueta (falla o no-falla) y  $b(x)$  es la distancia promedio de la señal  $x$  con todas las señales de la clase opuesta. El criterio  $S(x)$  se calcula para todas las señales y aquellas señales que cumplen:

$$-th \geq S(\mathbf{x}) \geq th \quad (3)$$

para un umbral  $th$  se consideran ruidosas. Se eliminarán instancias  $x$  que son más cercanas a la etiqueta opuesta cuando  $S(\mathbf{x}) \leq -th$  y se eliminarán instancias redundantes (que son muy parecidas al resto de los ejemplos de la clase) cuando  $S(\mathbf{x}) \geq th$ . La figura 4 ilustra el coeficiente silueta para un problema de clasificación binario en 2D.

Un total de 6 señales se eliminaron del conjunto de datos (2 de la clase con falla y 4 de la clase sin falla).




Fig. 4. Coeficiente silueta normalizado al intervalo [0,1] para un problema de 2 clases (rombos y círculos). En nivel de gris es proporcional al valor normalizado del coeficiente.

### RESULTADOS EXPERIMENTALES

Se realizó el estudio comparativo procesando los datos con los métodos ya descritos. Específicamente, se realizaron pruebas con los conjuntos de datos que se indican en la tabla I.

Tabla I. Descripción de los conjuntos de datos considerados.

Conjunto de datos	Descripción
A	Conjunto de datos original.
B	Conjunto A sin las frecuencias ruidosas.
C	Conjunto A sin señales ruidosas.
D	Conjunto C sin frecuencias ruidosas.

Los resultados para los 67 métodos evaluados y los cuatro conjuntos de datos se muestran en la figura 5. De esta figura podemos observar que la mayoría de los resultados son competitivos. El 96% de todos los resultados se encuentra arriba del 90% de exactitud; mientras que el 41% de resultados se encuentra arriba del 95%. Estos resultados dan evidencia de la efectividad del enfoque basado en clasificación para la detección de fallas. Como es de esperarse, los resultados son mejores para los conjuntos de datos pre-procesados: B, C, y D. En particular, se obtuvieron mejores resultados cuando se eliminaron tanto frecuencias como señales ruidosas (i.e., conjunto D). Después del conjunto

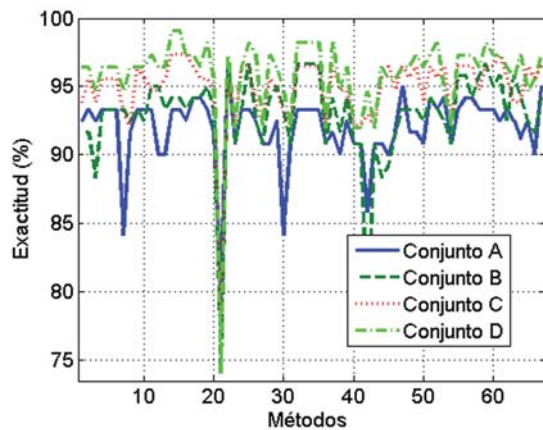


Fig. 5. Exactitud obtenida por los distintos métodos evaluados en los 4 conjuntos de datos considerados.

D, los mejores resultados son obtenidos para el conjunto C, esto es, cuando sólo se remueven señales ruidosas. Comparando los resultados obtenidos para los conjuntos A-B y C-D, podemos observar que el eliminar frecuencias ruidosas mejoró el desempeño de la mayoría de los métodos de clasificación.

Por restricciones de espacio no es posible mostrar a que método corresponde cada valor de exactitud mostrado en la figura 5. Sin embargo, en la tabla II se presenta la exactitud promedio por familia de métodos para cada uno de los conjuntos de datos. Así mismo, la tabla III presenta una descripción de los mejores métodos (en términos de promedio de área bajo la curva ROC) de clasificación por familia.

En la tabla II se puede observar que los métodos basados en similitud obtienen el mejor resultado promedio a través de todos los conjuntos de datos. Los resultados obtenidos en términos del área bajo la curva ROC fueron similares. Por otro lado, el mejor método por familia difiere notablemente como se muestra en la tabla III. El mejor clasificador en promedio sobre los conjuntos de datos considerados es AD-Tree un método basado en ensambles de árboles

Tabla II. Exactitud promedio por familia de métodos.

ID	Familia	A	B	C	D
1	Bayes	93.06	91.94	95.03	96.13
2	Funciones	90.83	93.57	94.61	96.30
3	Similitud	93.33	93.96	97.15	98.21
4	Meta	91.13	91.96	93.98	94.80
5	Reglas	92.59	92.78	95.32	96.03
6	Árboles	92.97	94.62	95.88	96.77

Tabla III. Mejor método en promedio sobre conjuntos de datos por familia. Considerando el área bajo la curva ROC.

ID	Método	Descripción
1	Naive Bayes (91.4%)	Método probabilista que asume independencia entre atributos dada la clase.
2	Red neuronal (86.7%)	Perceptron multi-capas capaz de generar superficies altamente no-lineales.
3	K-star (94.7%)	KNN que usa medida de similitud basada en entropía
4	Decorate (95.1%)	Técnica que combina múltiples añadiendo ejemplos sintéticos
5	PART (92.8%)	Método para generar reglas basado en árboles de decisión
6	AD-Tree (95.5%)	Método basado en boosting para la generación de árboles de decisión

de decisión. La efectividad de este método es muy similar a la obtenida por K-star y Decorate. Aunque cabe destacar en este punto que K-star es mucho más fácil de implementar que los otros métodos.

La tabla IV muestra los resultados obtenidos en todas las medidas de evaluación consideradas para los mejores métodos por cada conjunto de datos. Los resultados en términos de ciertos positivos (TP), falsos positivos (FP), precisión y cobertura se miden con respecto a la clase minoritaria (i.e., las señales con falla). Cuando la exactitud era igual para métodos de clasificación el segundo criterio

Tabla. IV. Resultados obtenidos por los mejores métodos para cada conjunto de datos.

Conjunto	Método	Exactitud	Área ROC	TP	FP	Precisión	Cobertura	F1
A	Clasificación vía regresión	96.67	93.90	72.70	0.90	88.90	72.70	80
B	Clasificación vía regresión	96.67	87.40	63.60	0	100	63.60	77.80
C	K-star	97.37	98.10	88.90	1.90	80	88.90	84.20
D	IB1	99.10	94.40	88.90	0	100	88.90	94.10

para identificar a los mejores métodos fue el área bajo la curva ROC.

Se puede observar que para el conjunto de datos D se obtiene una exactitud arriba del 99% (i.e., en promedio una señal no fue clasificada correctamente), lo que nos hace pensar que el enfoque automático de detección de fallas (incluyendo los métodos de pre-procesamiento) podría implementarse en línea de producción. Para el conjunto D el mejor algoritmo fue el IB1 (1-vecino más cercano), mientras que para el conjunto C el mejor método fue *K-star* (k-vecinos más cercanos), ambos métodos se basan en la similitud entre instancias, la eliminación de atributos ruidosos mejora los estimados de similitud para ambos métodos, mientras que la eliminación de señales ruidosas reduce los errores de clasificación para estos métodos. Para los conjuntos de datos A y B el mejor clasificador fue uno basado en regresión. Un resultado interesante de este estudio es que los métodos que mejor funcionan para los conjuntos de datos considerados (i.e., IB1, *K-star*, regresión) son muy sencillos de implementar y altamente eficientes, lo cual es ventajoso si se piensa aplicar estos métodos para la detección de fallas en línea de producción.

## DISCUSIÓN

La detección de fallas en baleros es un tópico ampliamente estudiado en la literatura. Existen enfoques exactos que permiten determinar si un balero presenta una falla o no. Sin embargo, tales métodos requieren de hacer mediciones directamente del componente (i.e., el sensor se coloca en el balero, lo que reduce la variabilidad de los datos y el nivel de ruido inherente a la medición). El aplicar tales técnicas para el escenario considerado (véase la figura 1) no fue posible debido a que no se tiene acceso al balero una vez que el producto es armado. La detección de fallas con técnicas de aprendizaje computacional es un área que ha tenido auge recientemente.<sup>6-8</sup> Lo anterior debido a que el área de aprendizaje automático se ha aplicado exitosamente en otros dominios, lo que ha dado confianza a las empresas para explorar estas alternativas. Los autores esperan que el estudio presentado en este artículo motive a otras empresas a considerar al aprendizaje automático como una herramienta más en el proceso de toma de decisiones.

## CONCLUSIONES

Se presentó un estudio comparativo de diferentes métodos de aprendizaje automático para la detección de fallas en procesos de manufactura. El problema consiste en determinar si un componente de cierto producto es defectuoso usando señales de sonido recopiladas cuando se pone en funcionamiento el producto que se fabrica.

El estudio comprendió 67 métodos de clasificación y dos métodos para el pre-procesamiento de datos. Interesantes conclusiones se obtuvieron del estudio. Primero, la mayoría de los métodos obtuvieron resultados aceptables bajo el enfoque propuesto. Segundo, la aplicación de métodos para la selección de atributos y selección de instancias redujo el ruido en el problema de detección, lo que a su vez provocó que los métodos mejoraran su efectividad. Tercero, se identificó a las familias de métodos que mejores resultados obtienen en la tarea estudiada, a saber, la familia de los métodos basados en similitudes. Cuarto, se identificaron a los mejores métodos de clasificación para los cuatro conjuntos de datos. Los métodos identificados son IB1, *K-star*, y métodos basados en regresión, además de su efectividad, los métodos anteriores son altamente eficientes y de fácil implementación.

Con base en los resultados reportados en este artículo podemos concluir que es factible la implementación de un método de detección automática de fallas que pueda obtener resultados aceptables en línea de producción.

Trabajo actual y futuro incluye la implementación de los mejores métodos de clasificación para su uso en producción y una validación de tales métodos. Además, se pretende desarrollar métodos de sobremuestreo para lidiar con el problema de desbalance de clases.

## AGRADECIMIENTOS

Los autores agradecen el apoyo de la Academia Mexicana de Ciencias a través de la beca otorgada para Katia Guevara. Se agradece también el apoyo otorgado por la FIME-UANL, así como los útiles comentarios de la Dra. Yasmín Ríos. Mario A. Saucedo-Espinosa agradece al CONACyT por la beca de estudios de maestría 237561.

## BIBLIOGRAFÍA

1. Mitchell, T. M. Machine Learning. s.l.: McGraw Hill, 1997.
2. The WEKA Data Mining Software: An Update. M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann, I. H. Witten. 1, s.l.: ACM, 2009, SIGKDD Explorations, Vol. 11, pp. 10--18.
3. Bishop, C. Pattern Recognition and Machine Learning. s.l.: Springer, 2006.
4. An Introduction to Variable and Feature Selection. I. Guyon, A. Elisseeff. 2003, Journal of Machine Learning Research, Vol. 3, pp. 1157--1182.
5. Instance Selection in Text Classification using the Silhouette Coefficient Measure. D. Dey, T. Solorio, M. Montes, H. J. Escalante. s.l.: LNCS, Vol. 7094, pp. 357--369, Springer, 2011.
6. Fault detection of a vibration mechanism by spectrum classification with a divergence-based kernel. T. Ishigaki, T. Higuchi, K. Watanabe. 5, s.l.: IEEE, 2010, IET Signal Processing, Vol. 4, pp. 518--529.
7. Bearing Fault Detection Using Artificial Neural Networks and Genetic Algorithm. B. Samanta, Khamis R. Al-Balushi, Saeed A. Al-Araimi. [ed.] Hindawi. 3, 2010, EURASIP Journal on Applied Signal Processing, Vol. 2004, pp. 366--377.
8. A Machine Learning Approach for Fault Detection in Multivariable. Y. Guo, J. Wall, J. Li, S. West. 2011. Second International Workshop on Agent Technologies for Energy Systems.



**LLAMADO A LOS AUTORES**



**CONGRESO NACIONAL 2012 DE LA  
ASOCIACIÓN DE MÉXICO DE CONTROL AUTOMÁTICO  
AMCA 2012**  
DEL 17 AL 19 DE OCTUBRE DEL 2012  
CIUDAD DEL CARMEN, CAMPECHE

La *Asociación de México de Control Automático* y la *Facultad de Ingeniería de la Universidad Autónoma del Carmen (UNACAR)* convocan a investigadores, profesores, estudiantes de posgrado y de licenciatura y a los profesionales de la ingeniería a participar en su congreso anual.

**Tópicos:**

- Control de sistemas lineales y no lineales
- Control Inteligente
- Control de procesos
- Robótica y vehículos autónomos
- Sistemas biomédicos
- Control de sistemas electromecánicos
- Control de procesos químicos
- Sistemas electrónicos de potencia
- Caos
- Modos deslizantes y estructura variable
- Sistemas mecánicos discontinuos
- Detección y aislamiento de fallas
- Otros tópicos afines

Presidente de la AMCA: Dr. Alejandro Rodríguez Ángeles (CINVESTAV)  
aangeles@cinvestav.mx

Presidente del congreso: Dr. José Antonio Ruz Hernández (Facultad de Ingeniería UNACAR)  
jruez@delfin.unacar.mx

Presidente del Comité de Programa: Dr. Edgar N. Sánchez Camperos (CINVESTAV-IPN, Unidad Guadalajara)  
sanchez@gdl.cinvestav.mx