

DETECCIÓN DE PATRONES DE FALLAS UTILIZANDO TÉCNICAS DE ANÁLISIS NO SUPERVISADO

Miguel A. Carrasco, Antonio Cansado y Álvaro Soto

Departamento de Ciencia de la Computación
Pontificia Universidad Católica de Chile
Av. Vicuña Mackenna 4860(143), Santiago de Chile
E-mail: {mlcarras@puc.cl, acansado@ing.puc.cl, asoto@ing.puc.cl}

Abstract: El incremento de información disponible en las pruebas de análisis no destructivo (NDT) genera un alto grado de complejidad para detectar patrones anómalos. Las investigaciones actuales comúnmente emplean un análisis supervisado, con un conocimiento a priori sobre cada clase. Esta investigación pretende detectar anomalías de una base de datos con fallas en llantas de aluminio, utilizando un esquema no supervisado. Empleamos dos técnicas para detectarlas; Primero, aplicar una reducción de dimensionalidad con el análisis de componentes principales (PCA), y luego utilizar herramientas de clustering no supervisado con GMM-EM y K-Means; Segundo, utilizar un detector de anomalías con redes de Bayes (BNAD2) modelando la probabilidad conjunta de todos los datos. La investigación demuestra que es posible clasificar correctamente fallas reales sin conocimiento de la clase.

KeyWords: Unsupervised clustering, Principal Component Analysis (PCA), MeanShift, Gaussian Mixture Models (GMM-EM), K-Means, BNAD2.

1 Introducción

El análisis no destructivo (NDT) es la principal herramienta para medir la calidad de las estructuras y/o productos manufacturados. El proceso generalmente utiliza rayos X o Gamma, los cuales penetran las estructuras generando una imagen negativa al ser expuesta sobre una placa radiográfica. La cual posteriormente es analizada por un experto que identifica las regiones donde existen fallas (fig. 1). Sin embargo, este proceso es lento, inconsistente y subjetivo, ya que depende de las características del operador [1].

La mayoría de las investigaciones relacionadas con la detección de fallas, genera una gran cantidad de información tanto en pruebas geométricas y/o valores de intensidad para cada falla potencial [2, 3, 4]. En general, el objetivo de éstas ha sido determinar las características que separan mejor el espacio de clases “estructura regular” o “defecto” a través del uso de distintos tipos de clasificadores. Sin embargo, todas ellas tienen en común el conocimiento a priori de la clase de cada defecto potencial. En la práctica, observamos que esta información no siempre es conocida, por lo tanto, es necesaria una evaluación inicial que permita determinar la pertenencia de cada falla potencial sin el conocimiento de su clase.

Nuestra investigación pretende clasificar fallas potenciales en forma no supervisada. Utilizamos una

base de datos compuesta con registros de fallas potenciales en llantas de aluminio construida en [4]. Aunque el problema de clasificación para esta base de datos ha sido resuelto en su totalidad en [5], ésta última ha sido diseñada con un clasificador supervisado a través de redes neuronales, utilizando el conocimiento de la clase de cada falla potencial para entrenar la red.

Los problemas de clasificación son complejos cuando las clases que separan el espacio están muy interrelacionadas. Por este motivo, es necesario explorar el espacio de datos variando los atributos o utilizando una combinación de estos. Nuestra hipótesis se basa en la desigualdad que tienen las estructuras regulares respecto a las fallas reales. Empleamos dos esquemas para detectarlas. Primero, utilizamos las técnicas clásicas de clustering no supervisado tales como GMM-EM y K-Means. Éstas tienen un bajo rendimiento tanto en complejidad computacional como en clustering en problemas de gran dimensionalidad. Por este motivo, utilizamos el análisis de componentes principales (PCA) para reducir el espacio de búsqueda. Segundo, utilizamos un nuevo detector de anomalías con redes de Bayes (BNAD2), la cual no requiere reducir la dimensionalidad, ya que modela la probabilidad conjunta de todos los datos.

En el primer esquema, utilizamos PCA para reducir la dimensionalidad del problema debido a la complejidad de la base de datos.




Fig. 1. Esquema de detección de fallas a través de la radiación sobre la llanta de aluminio y posterior análisis sobre la proyección radiológica

Esta herramienta es conocida como una técnica de compresión ya que al reducir la cantidad de atributos, tiene una baja pérdida de información, eliminando los atributos que no tengan una fuerte correlación [6]. Utilizando las componentes principales con mayor varianza, aplicamos las técnicas clásicas de clustering no supervisado. El segundo esquema genera una red de Bayes que explora las dependencias e independencias entre las variables para simplificar el problema, utilizando diversas heurísticas para determinar las mejores relaciones entre las variables [7].

Para medir el rendimiento de una clasificación, se ha utilizado la curva ROC. Los grupos a clasificar están constituidos por el conjunto de registros con “estructura regular” y “defecto”. Para ello se debe determinar la prueba de “Sensibilidad” y la “1-especificidad” [8, 9].

El estudio utiliza una base de datos compuesta por 22.936 regiones segmentadas con 28 atributos preseleccionados por cada región disponible en [4]. Ésta dispone un atributo que identifica la clase de cada registro, permitiendo así, evaluar el rendimiento de las técnicas aplicadas en nuestra investigación. Utilizando ésta información, comprobamos la existencia de 60 fallas reales. El resto de los registros corresponden a falsas alarmas.

Este documento se divide en las siguientes secciones. La sección 2 incluye los trabajos relacionados sobre la extracción de características y los clasificadores no supervisados. La sección 3 se incluye una descripción de la metodología desarrollada. La sección 4 incluye los resultados experimentales. Finalmente, la sección 5 presenta las conclusiones y líneas de trabajo futuro.

2 Antecedentes

El proceso que permite utilizar la visión por computador de forma automatizada es conocido como Inspección

Visual Automática (AVI) y su objetivo consiste en determinar si un producto se encuentra dentro o fuera del rango de aceptación en el proceso de fabricación [10]. Una de las principales líneas de investigación de la AVI es el proceso de reconocimiento de fallas en forma automática, debido a que la automatización permite establecer políticas y formas de control precisas y objetivas. Existen dos condiciones básicas que un sistema AVI debe cumplir para mejorar la calidad de los productos. Primero, eficiencia: tiene relación con la disminución en la cantidad de falsos positivos y negativos detectados por la AVI. Segundo, rapidez: permitir que el proceso de producción no se vea afectado por el tiempo que toma la inspección y por lo tanto aumente o mantenga al menos la velocidad de producción. Nuestra investigación tiene como objetivo cumplir la primera condición de la AVI, utilizando diferentes técnicas de análisis no supervisado. La idea consiste en clasificar correctamente las regiones segmentadas con “estructuras regulares” y “defectos”, disminuyendo las falsas alarmas sin el conocimiento de su clase. Basamos nuestra hipótesis en la desigualdad de los defectos respecto a las estructuras regulares.

2.1 Selección de características

El método de reconocimiento de patrones de fallas propuesto en [4], utiliza clasificadores supervisados sobre un conjunto de 22,936 regiones segmentadas en 50 imágenes de radiológicas de llantas de aluminio. Inicialmente se utilizaron 405 características, de las cuales fueron seleccionadas 28 utilizando el discriminador de Fisher y curvas ROC para determinar las características no correlacionadas. Según los resultados de la investigación, existen características que proveen de mayor información para la clasificación, por lo tanto, seleccionando un conjunto mínimo de características, es posible obtener una buena separación de las clases. Por este motivo, se ha empleado una herramienta de reducción de dimensionalidad respecto a

las variables independientes conocido como análisis de componentes principales (PCA). Esto permite identificar patrones en los datos de tal forma de encontrar similitudes y diferencias [6]. Una de las grandes ventajas de esta técnica, es la baja pérdida en información ya que maximiza la varianza entre todas las posibles transformaciones, es decir, es una técnica de compresión. Puede ser utilizada en cualquier conjunto de datos donde sea necesaria la reducción de dimensionalidad, incluyendo las aplicaciones en el procesamiento de imágenes [11, 12, 13].

2.2 Clustering no supervisado

Para clasificar un conjunto de datos en los cuales no es conocida la clase o pertenencia de cada registro, podemos aplicar herramientas de clustering no supervisado. Estas técnicas permiten estimar los parámetros del modelo de clasificación y además determinar la clase de cada registro. Dependiendo del tipo de problema, el rendimiento varía de acuerdo a la técnica aplicada. En muchos casos, es conocido el número de clases del problema, sin embargo, en la mayoría de las aplicaciones reales los espacios son complejos, y cualquier intento de clasificación con técnicas donde compitan agrupamientos de datos, la clasificación falla [14]. Dentro de los más conocidos están K-Means y GMM-EM [15], los cuales generan una clasificación actualizando en cada iteración los parámetros del modelo. Estos algoritmos son útiles, pero tienen desventajas ya que requieren de una configuración inicial para comenzar a iterar, lo cual los hace susceptible a encontrar óptimos locales, y además es necesario indicar el número de clases a priori. Por el contrario, MeanShift permite determinar el número de óptimo de clases ya que se mueve en la dirección del máximo del gradiente [14]. Inicialmente genera una gran cantidad de centroides distribuidos en forma uniforme, y en cada iteración, cada centroide se mueve en forma independiente hasta llegar a las zonas donde la densidad es máxima. La convergencia del algoritmo está dada por la distancia mínima entre los centroides. La mayor ventaja, es que genera como resultado el número de clases y la posición de cada centroide.

2.3 Metodología de comparación

La curva ROC se utiliza para medir el rendimiento de una clasificación de dos clases [8, 9]. La principal característica, es la independencia en la comparación respecto a la muestra. Para esta investigación, las clases están constituidas por los conjuntos de registros “estructuras regulares” y “defectos”, para ello se debe determinar la prueba de “Sensibilidad” y la “1-especificidad” como

$$S_p = \frac{VP}{VP + FN} \quad 1 - S_p = \frac{FP}{FP + VN}, \quad (1)$$

donde VP es el número de verdaderos positivos (clasificado correctamente como defecto), VN es el número de verdaderos negativos (clasificado correctamente como estructura regular), FP es el número de falsos positivos (clasificado incorrectamente como defecto o falsas alarmas) y FN es el número de falsos negativos (clasificados incorrectamente como estructura regular).

La curva ROC debe ser evaluada en distintos puntos dado un conjunto de pruebas sobre las menores probabilidades de clasificar como defecto. El área bajo la curva A_z indica el rendimiento de la prueba. Un valor de $A_z=1$ indica que la clasificación ha sido ideal, es decir, se ha detectado la totalidad de defectos sin falsas alarmas.

3 Método propuesto

3.1 Reducción de dimensionalidad con PCA

El método propuesto utiliza la reducción de dimensionalidad, para disminuir el espacio de búsqueda de las fallas reales a través de PCA. Empleamos sólo los vectores propios que contengan un 99.9% de explicación sobre los datos para reducir el espacio de atributos. Luego utilizamos las herramientas de clustering no supervisado, para encontrar la probabilidad de cada punto sobre la proyección de las bases de PCA. MeanShift es aplicado sobre el resultado anterior para encontrar el número óptimo de centroides y su posición. En comparación con otras técnicas, aseguramos encontrar zonas de densidad máxima, lo cual permite obtener un punto de inicio para otras técnicas que requieren conocer a priori el número de clases.

Utilizamos GMM-EM para determinar la probabilidad de pertenencia de cada registro, luego de conocer el número de cluster y la posición de cada centroide con MeanShift. Suponemos que los puntos que estén más distantes de la gaussiana, tienen una menor explicación sobre ésta, por lo tanto, tienen una baja probabilidad de pertenecer a la clase “estructura regular”. Debido a que empleamos la proyección de PCA sobre los datos, suponemos que la representación en el espacio tiene una estructura lineal, para las primeras componentes principales.

Evaluamos el rendimiento de GMM-EM con la curva ROC. Para esto, necesitamos ordenar las probabilidades de los registros de menor a mayor. Luego construimos cada punto de la curva a base de la variación en la selección de grupos con menor probabilidad, es decir,

seleccionamos los primeros n registros con menor probabilidad, a medida que variamos el parámetro de la distribución de clases θ [2].

K-Means es otra de las técnicas utilizadas en nuestro estudio para determinar el rendimiento de la clasificación. Se emplearon diferentes configuraciones, variando el número de clases sobre la proyección de PCA. Debido a que el espacio definido por los datos no necesariamente tiene una representación para cada clase, variamos la cantidad de clusters definida en cada caso. Esto significa que pueden existir regiones del espacio de propiedades, donde puede estar mejor definida la clase “defecto”. Para determinar el rendimiento de esta técnica, utilizamos la curva ROC con los mismos registros utilizados en GMM-EM, sobre los diferentes grupos seleccionados con menor probabilidad. Luego evaluamos la Eq.1 sobre las diferentes configuraciones y comparamos los resultados de todas las técnicas (fig. 2).

Los algoritmos para la reducción de dimensionalidad, K-Means y ROC han sido implementados utilizando Matlab 6.5 [16]. Para GMM-EM se ha empleado el software Fast EM Clustering de AutonLab, desarrollado en Carnegie Mellon University [17]. Finalmente BNAD2 se ha implementado en C++ [7].

3.2 Redes de Bayes (BN)

El método propuesto en 3.1 utiliza la proyección de PCA para disminuir la complejidad computacional para luego ocupar técnicas de clustering tradicionales. Un método alternativo es modelar la probabilidad conjunta de todos los atributos dada una base de datos y calcular la verosimilitud de cada falla hipotética. Utilizando el supuesto que las fallas (verdaderos positivos) representan una minoría entre todas las fallas hipotéticas, es posible intuir que un modelo razonable concentra sus recursos (parámetros) en explicar la gran mayoría de los datos, por lo tanto, las fallas quedarían muy mal explicadas por el modelo creado. Esto se ve reflejado en una muy baja verosimilitud dado el modelo.

Encontrar la probabilidad conjunta de atributos desde una base de datos es un problema combinatorio y por lo tanto requiere de heurísticas que simplifiquen el problema. Para ello es posible utilizar BN que exploren las dependencias e independencias entre las variables para simplificar el problema. Dada la naturaleza continua de los atributos, se utilizó el algoritmo Bayesian Network Anomaly Detector 2 (BNAD2) [7] para crear un modelo probabilístico de los datos y ordenar los datos de menor a mayor verosimilitud. El algoritmo BNAD2 utiliza diversas heurísticas para determinar las relaciones entre los atributos y GMM-EM

para calcular las probabilidades conjuntas locales. Gracias a la factorización provista por la BN, es posible evitar el problema de dimensionalidad característica de GMM-EM y así explorar problemas de muchas dimensiones sin tener que utilizar reducción de variables. Es importante señalar que el algoritmo fue diseñado para encontrar anomalías en bases de datos de astronomía de gran tamaño, por lo que esta optimizado para obtener una gran velocidad y no necesariamente una alta precisión.

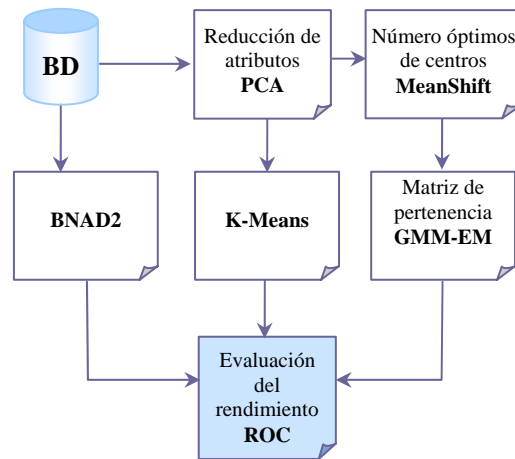


Fig. 2. Esquema general de preprocesamiento, detección de matriz de pertenencia y rendimiento de la detección de la clase defecto.

4 Resultados

4.1 Rendimiento de GMM-EM y K-Means con PCA

Los resultados indican que PCA reduce considerablemente la cantidad de atributos la base de datos analizada. En efecto, las tres primeras componentes explican la variación con un 99.92% de los datos (fig. 3). Para el conjunto de pruebas, utilizamos hasta la quinta componente principal considerando un 99.98% de la varianza explicada.

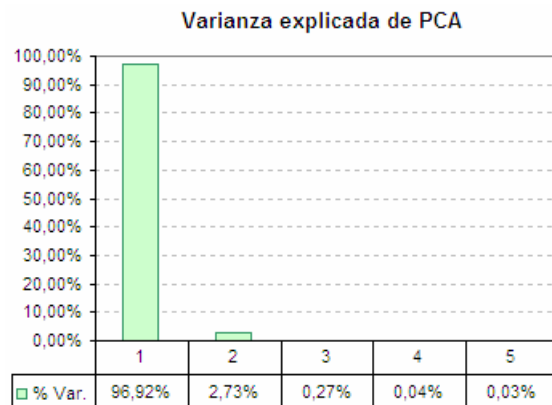


Fig. 3. Explicación de las primeras cinco componentes principales de BD con 28 atributos desarrollada en [4].

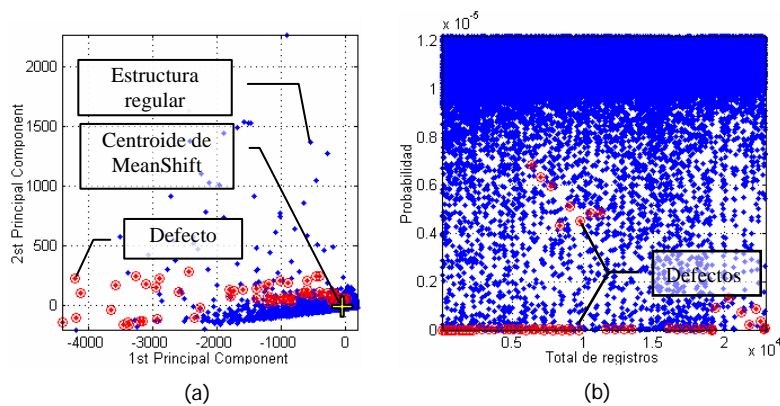


Fig. 4. (a) Proyección de las bases de las primeras dos componentes principales sobre el conjunto de datos, (b) Distribución de probabilidad de cada registro, utilizando GMM-EM.

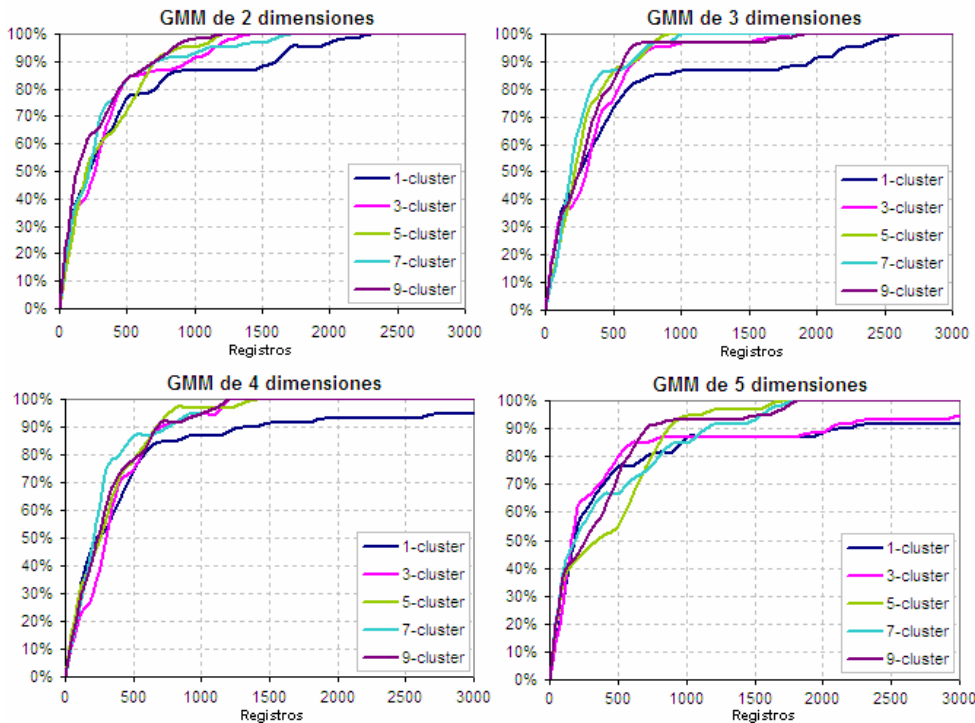


Fig. 5. Rendimiento en la detección de las 60 fallas reales utilizando GMM, desde dos hasta cinco dimensiones de la proyección de PCA, y generando 1, 3, 5 y 9 cluster por cada proyección.

4.1.1 GMM-EM con inicialización de MeanShift

Al aplicar MeanShift sobre la proyección de PCA, encontramos la posición del centroide donde la densidad es máxima (fig. 4a). El algoritmo se inicializó con 100 centroides distribuidos en forma uniforme, y una ventana de radio $r=900$. Verificamos en cada iteración si el centroide contiene registros en su ventana de acción, en caso contrario, eliminamos la posición si éste no contiene algún registro. Luego de 14 iteraciones, encontramos sólo un centroide al final del proceso. Probamos el algoritmo con otras configuraciones respecto a la cantidad de centroides iniciales (con 225, 400, 625 y 900 distribuidos en forma uniforme),

comprobando en todas ellas el mismo número y posición final. Sin embargo, si disminuimos la ventana de acción de MeanShift, podemos determinar una mayor cantidad de centroides. Más detalles de la variación del radio de la ventana se encuentran en [14].

Además, nuestra investigación realizó pruebas variando el número de proyección en el espacio de PCA, y modificando el número de cluster en cada dimensión. En cada proyección de PCA (desde la segunda hasta la quinta dimensión), inicializamos con {1, 3, 5, 7 y 9} clusters.

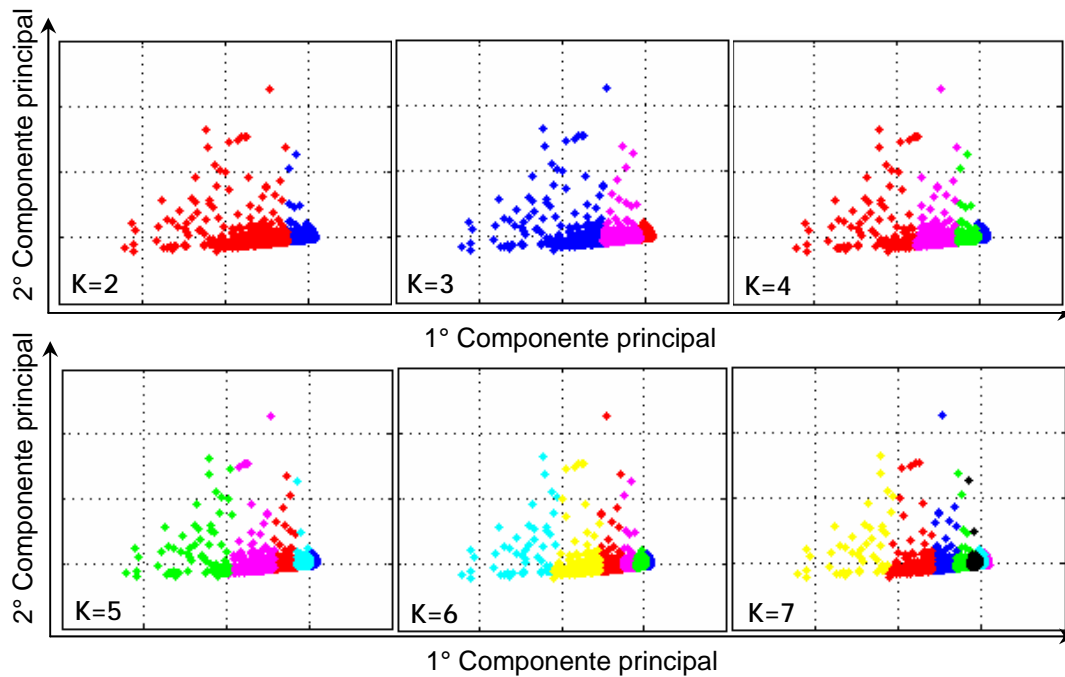


Fig. 6. Clasificación de K-Means con 2, 3, 4, 5, 6 y 7 clases sobre los datos proyectados con las bases principales de PCA, utilizando métrica de distancia euclidiana.

Tabla 1. Resultados de clasificación con K-Means y número de registros por cada clase.

# Cluster	K2		K3		K4		K5		K6		K7	
	Fallas	FP.	Fallas	FP.	Fallas	FP.	Fallas	FP.	Fallas	FP.	Fallas	FP.
Clase 1	45	901	34	340	24	145	20	80	20	56	20	52
Clase 2	15	22035	6	19250	2	17567	10	4822	12	622	10	202
Clase 3			20	3346	13	4472	18	340	9	2145	0	12430
Clase 4					21	752	11	1342	6	5198	6	1237
Clase 5							1	16352	0	14662	2	5625
Clase 6									13	253	14	450
Clase 7											8	2940

FP: Falso Positivo o Falsa Alarma (clasificado incorrectamente como defecto)

Los resultados indican que un incremento en el número de clusters no mejora la detección de fallas, esto se ve reflejado al utilizar la cuarta y quinta componente principal (fig. 5). En promedio, el mejor rendimiento se obtuvo con cinco clusters, y el mejor resultado global requirió de las tres primeras componentes principales, detectando 52 / 60 fallas en los 500 registros de menor verosimilitud y la totalidad de las fallas en los primeros 900 registros. Los resultados demuestran que la utilización de un único cluster no es suficiente para modelar la probabilidad conjunta de los datos. En problemas de mayor dimensionalidad, existen regiones (en el espacio de PCA) donde las fallas puedan tener una mejor explicación por parte de cada cluster, no obstante, notamos como un aumento en su número disminuye la detección de las fallas reales.

4.1.2 K-Means

Los resultados demuestran que las clases separadas tienen directa relación con las densidades de los registros (fig. 6). Principalmente por la utilización de la métrica de distancia euclidiana al ejecutar el algoritmo. Sin embargo, la posición espacial de la clase “defecto” no permite obtener una separación ideal, ya que la mayoría de los datos se encuentran dispuestos en el eje de la primera componente principal (fig. 4a). Además, los resultados indican que un aumento en el número de clases no mejora la clasificación. Sin embargo se han identificado algunas clases que contienen una mayor cantidad de defectos, pero con una baja cantidad de registros (tabla 1, K7-Clase 1). Para esta técnica, el mejor rendimiento se obtiene en K=2, debido a la alta

cantidad de defectos encontrados con una baja cantidad de falsas alarmas (tabla 1). Para construir la curva ROC y comparar todas las técnicas, utilizamos un atributo de la base de datos que identifica cada registro como “estructura regular” o “defecto”. Esta información nos permite evaluar el rendimiento comparando los registros seleccionados como fallas hipotéticas, respecto a las fallas reales. El proceso selecciona 30 grupos desde 100 hasta 3,000 registros con las fallas de menor probabilidad de la matriz resultante de GMM-EM (fig. 4b). Para cada grupo, evaluamos si los registros están contenidos en el conjunto de fallas reales. Utilizando el mismo conjunto, comparamos si estos están contenidos en la clase de mayor porcentaje de K-Means y BNAD2.

4.2 Rendimiento de BNAD2

Las pruebas realizadas utilizando el método propuesto en 3.2 indican una gran mejoría con respecto a los obtenidos en 4.1. Se entrenó la red con la totalidad de los datos y atributos sin introducir ningún tipo de información adicional. Es interesante que el algoritmo fue capaz de detectar 56 / 60 fallas tomando los 500 objetos de menor verosimilitud y que la totalidad de fallas se encuentra entre los 900 objetos de menor verosimilitud. Estos resultados corroboran que el supuesto probabilístico señalado en 3.2 puede ser utilizado en este tipo de aplicaciones con gran éxito y que efectivamente existen patrones en las fallas vistas. Una característica importante de esta técnica es que, una vez entrenada la BN, el algoritmo puede funcionar como un filtro en tiempo real para determinar posibles fallas con una tasa de acierto muy cercana a las obtenidas por [4] pero con la diferencia que no requiere una clasificación previa de los datos.

Tabla 2. 1000 objetos de menor verosimilitud de GMM evaluado en los mejores rendimientos de cada dimensión y rendimiento de la red BNAD2

Reg.	2 Dim.	3 Dim.	4 Dim.	5 Dim.	BNAD2
100	42%	22%	28%	35%	28%
200	62%	47%	43%	43%	80%
300	67%	70%	57%	48%	85%
400	77%	78%	72%	52%	87%
500	83%	87%	78%	55%	93%
600	87%	88%	85%	65%	93%
700	90%	92%	92%	77%	93%
800	93%	97%	97%	85%	98%
900	97%	100%	97%	92%	100%
1000	98%	100%	97%	95%	100%

El mejor rendimiento de GMM-EM para todas las proyecciones de PCA, se obtiene al utilizar las primeras

tres componentes, y al clasificar el espacio con cinco clusters (tabla 2). Los resultados indican que en los primeros 500 objetos, se encuentran 52 / 60 defectos, y la totalidad de las fallas en los primeros 900 objetos de menor verosimilitud.

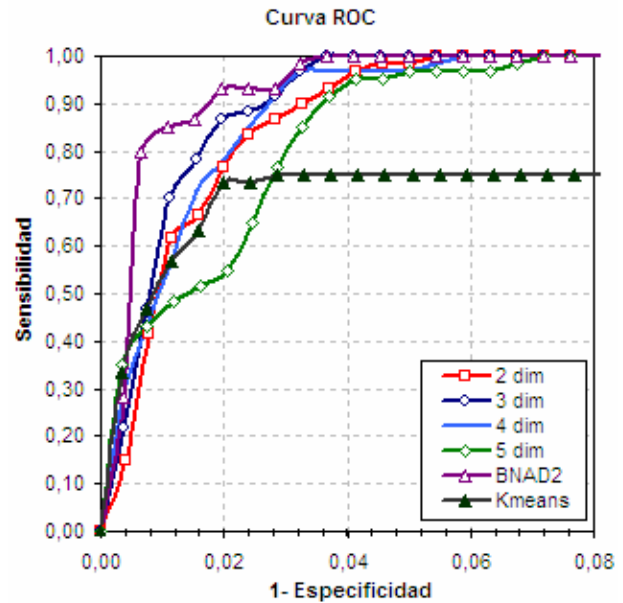


Fig. 7. Curva ROC evaluada en 30 puntos de control utilizando la clasificación en las mejores cinco dimensiones de GMM, K-Means sobre la proyección de PCA y clasificación de la red de Bayes BNAD2.

Los resultados de la investigación, indican que la red BNAD2 obtiene el mejor rendimiento en la clasificación de las clases “estructura regular” y “defecto” respecto de las técnicas clásicas de clustering no supervisado (fig. 7). Tanto en la menor detección de falsas alarmas, como la mayor área bajo la curva ROC. Los resultados de la curva ROC indican los siguientes rendimientos (tabla 3).

Tabla 3. Mejores rendimientos de las técnicas aplicadas según el criterio de ROC de las áreas bajo la curva ROC

Técnica	Área A_z	S_n	$1-S_p$
BNAD2	99.1%	100%	3.46%
GMM-EM (3dim)	98.8%	100%	3.68%
K-Means (2 dim)	74.2%	75%	2.8%

5. Conclusiones

Este trabajo presenta la comparación de diversas técnicas de análisis no supervisado sobre un conjunto de 22,936 registros y 28 atributos con fallas hipotéticas construida en [4]. Se realizaron diversos experimentos utilizando clasificadores estadísticos muy utilizados en la actualidad como herramientas de clasificación.

Además, se aplicó una reducción de dimensionalidad con el análisis de PCA debido a la complejidad de base de datos original. Los resultados indican que es factible detectar un gran número de fallas reales, sin embargo, existe una gran cantidad de falsas alarmas que no han podido ser eliminadas con las técnicas aplicadas ($S_n=100\%$, $1-S_p=3.44\%$). Recordemos que no conocemos a priori la clase de cada registro y los límites que separan el espacio donde se encuentran los defectos. Las falsas alarmas son considerablemente altas, pero pueden ser eliminadas utilizando un procedimiento basado en el análisis de secuencias de imágenes [18].

Al utilizar una mayor cantidad de componentes principales, el rendimiento general se reduce considerablemente. Los resultados indican que sólo basta emplear las componentes principales con mayor explicación. Sin embargo, las variaciones en la selección de clusters afectó el rendimiento de la clasificación. Por este motivo, BNAD2 es el mejor clasificador para la detección patrones poco probables, ya que evita ingresar al sistema nuevas heurísticas, como el número de clusters y dimensiones a utilizar.

Respecto al estudio realizado en [4], los modelos creados con clustering supervisado tienen un mejor rendimiento, ya que están basados en el conocimiento de la clase de cada registro, y un rendimiento óptimo al aplicar redes neuronales [5]. No obstante, en muchas aplicaciones reales, esta información está oculta o es desconocida siendo imposible determinar la clasificación real. En este sentido, el estudio realizado ha determinado que es posible detectar patrones de fallas sólo utilizando un análisis estadístico, sin un reconocimiento visual por parte de un experto.

6. Referencias

- [1] Liao, T.W., Li, Y.: "An Automated radiographic NDT system for weld Inspection: Part II--Flaw detection", NDT&E International, Vol. 31, No. 3, pp.183-192, 1998.
- [2] Mery D., Jaeger T., Filbert, D.: "A Review of Methods for Automated Recognition of Casting Defects", INSIGHT, Journal of The British Institute of Non-Destructive Testing, 44(7):428-436. ISSN 1354-2575, 2002.
- [3] Mery, D.; Filbert, D.; Jaeger, T.: "Image Processing for Fault Detection in Aluminum Castings". In "Analytical Characterization of Aluminum and Its Alloys", Ed.C S MacKenzie and G Y Totten, Marcel Dekker Inc., New York in Press, 2003.
- [4] Mery, D., da Silva, R.; Caloba, L.P.; Rebello, J.M.A.: "Pattern Recognition in the Automatic Inspection of Aluminium Castings". Insight, 45(7):475-483. ISSN 1354-2575, 2003.
- [5] Carvajal K., Chacón M., Mery D., Acuña G.: "Neural network method for failure detection with skewed class distribution". Insight, 7(46): 399-402, 2004.
- [6] Smith L.I.: "A tutorial on Principal Components Analysis". Department of Computer Science. University of Otago, New Zealand, February, 2002.
- [7] Cansado, A., Soto, A.: "Unsupervised Anomaly Detection in Large Databases Using Bayes Networks". Applied Artificial Intelligence, 2005.
- [8] Egan, J.: "Signal detection theory and ROC analysis". Academic Press, New Cork, 1975.
- [9] Provost F., Fawcett T.: "Robust Classification for Imprecise Environments". In: Machine Learning, vol. 42, no. 3, pp. 203-231, 2001.
- [10] Newman, T.S., Jain, A.K.: "A survey of automated visual inspection". Computer Vision and Image Understanding, 61(2): 231-262, 1995.
- [11] Vidal C., Malassidis E., García-Gómez J.M., Martí-Bonmatí L., Robles M., Mollet J.: "El análisis de componentes principales como método de clasificación y visualización de tumores de partes blandas". IX Congreso Nacional de Informática Médica, 2002.
- [12] Hancock, P.J.B., Bruce, V., Burton, A.M.: "Testing principal component representations for faces". In Proceedings of 4th Neural Computation and Psychology Workshop, J.A. Bullinaria, D.W.Glasspool and G. Houghton (Eds), London: Springer-Verlag, p84-97, 1997.
- [13] Yambor, W.S.: "Analysis of PCA-based and fisher Discriminant-based image recognition Algorithms". Thesis of Master of Science. Department of Computer Science. Colorado State University, 2000.
- [14] Comaniciu D., Meer P.: "Mean shift: A robust approach toward feature space analysis". IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 24, no. 5, pp. 603-619, 2002.
- [15] H. Permuter, J. Francos, Ian H.J.: "Gaussian Mixture Models of Texture and Colour for Image Database Retrieval". Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing, Hong Kong, April, 2003.
- [16] Mathworks: "Statistics Toolbox for Use with MATLAB: Users Guide, version 2". The MathWorks Inc, 1999.
- [17] Wong W. K., Moore A., Hsiung P., Sand P.: "Fast EM Clustering". Auton Lab, Carnegie Mellon University's School of Computer Science. [http://www.autonlab.org/autonweb], 2004.
- [18] Mery, D.; Carrasco, M.A.: "Automated multiple view inspection based on uncalibrated image sequences". Lecture Notes in Computer Science, LNCS 3540: 1238-1247, 2005.