

Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

E. Jove^{a,b}, J. Casteleiro-Roca^{a,*}, H. Quintián^a, J. A. Méndez-Pérez^b, J. L. Calvo-Rolle^a

^aDepartamento de Ingeniería Industrial, Univesidade da Coruña,

^bDepartamento de Ingeniería Informática y de Sistemas, Universidad de La Laguna

Resumen

Los avances tecnológicos en general, y en el ámbito de la industria en particular, conllevan el desarrollo y optimización de las actividades que en ella tienen lugar. Para alcanzar este objetivo, resulta de vital importancia detectar cualquier tipo de anomalía en su fase más incipiente, contribuyendo, entre otros, al ahorro energético y económico, y a una reducción del impacto ambiental. En un contexto en el que se fomenta la reducción de emisión de gases contaminantes, las energías alternativas, especialmente la energía eólica, juegan un papel crucial. En la fabricación de las palas de aerogenerador se recurre comúnmente a materiales de tipo bicomponente, obtenidos a través del mezclado de dos sustancias primarias. En la presente investigación se evalúan distintas técnicas inteligentes de clasificación *one-class* para detectar anomalías en un sistema de mezclado para la obtención de materiales bicomponente empleados en la elaboración de palas de aerogenerador. Para lograr los modelos inteligentes que permitan la detección de anomalías, se han usado datos reales extraídos de una planta de mezclado en operación durante su correcto funcionamiento. Los clasificadores obtenidos para cada técnica son validados a través de anomalías generadas de manera artificial, obteniéndose resultados altamente satisfactorios.

Palabras Clave: Sistemas de energías renovables, Aerogeneradores, Detección de anomalías, Diagnóstico de sistemas, Redes neuronales

Anomaly detection based on intelligent techniques over a bicomponent production plant used on wind generator blades manufacturing

Abstract

Technological advances, especially in the industrial field, have led to the development and optimization of the activities that takes place on it. To achieve this goal, an early detection of any kind of anomaly is very important. This can contribute to energy and economic savings and an environmental impact reduction. In a context where the reduction of pollution gasses emission is promoted, the use of alternative energies, specially the wind energy, plays a key role. The wind generator blades are usually manufactured from bicomponent material, obtained from the mixture of two different primary components. The present research assesses different *one-class* intelligent techniques to perform anomaly detection on a bicomponent mixing system used on the wind generator manufacturing. To perform the anomaly detection, the intelligent models were obtained from real dataset recorded during the right operation of a bicomponent mixing plant. The classifiers for each technique were validated using artificial outliers, achieving very good results.

Keywords:

Renewable energy systems, Windmills, Fault detection, System diagnosis, Neural networks

*Autor para correspondencia: jose.luis.casteleiro@udc.es

To cite this article: E. Jove, J. Casteleiro-Roca, H. Quintián, J. A. Méndez-Pérez, J. L. Calvo-Rolle. 2020. Anomaly detection based on intelligent techniques over a bicomponent production plant used on wind generator blades manufacturing. Revista Iberoamericana de Automática e Informática Industrial 17, 84-93. <https://doi.org/10.4995/riai.2019.11055>

Attribution-NonCommercial-NoDerivatives 4,0 International (CC BY-NC-ND 4,0)

1. Introducción

Los avances tecnológicos en general, y en el ámbito de la industria en particular, conllevan el desarrollo y optimización de las diferentes actividades que en ella existen, para el deseado perfeccionamiento de los procesos en su conjunto (Hobday, 1998). Con el fin de alcanzar este objetivo, un aspecto de gran importancia es la posibilidad de detectar, sobre los diferentes sistemas que conforman la producción, cualquier tipo de anomalía en su fase más incipiente. Si se consigue, este hecho contribuirá, entre otros, al ahorro energético, económico, reducción de desecho de material y reducción del impacto ambiental (Jove et al., 2018). Además, una detección precoz de una anomalía cobra mayor relevancia en procesos de alto coste y en los que la seguridad es un factor crítico (Miljković, 2011).

En cualquier proceso, una anomalía puede ser causada por el mal funcionamiento de un actuador, una mala lectura de un sensor o por la variación en los parámetros de la planta en términos generales (Chiang et al., 2000).

Desde un punto de vista genérico, se denominan anomalías a los datos que siguen un patrón diferente al esperado en una aplicación determinada (Chandola et al., 2009).

Partiendo de esta definición, la detección de anomalías presenta una serie de retos y dificultades (Chandola et al., 2009):

- Existe la posibilidad de que el conjunto de datos obtenidos en un estado de funcionamiento anómalo del proceso sea lo suficientemente grande como para que estos no sean considerados como anomalías.
- El establecimiento de un criterio que delimite los datos correspondientes al funcionamiento normal del sistema puede resultar una tarea compleja.
- En muchas aplicaciones, el desgaste lento de los componentes debido a su uso sistemático, no implica una anomalía, siempre que éstos no superen unos límites técnicamente establecidos. Por ejemplo, un engranaje puede desgastarse debido a su uso y no por ello funcionar de manera anómala.
- Incluso aunque exista la posibilidad de registrar datos correspondientes a uno o varios tipos de anomalías concretas, esto no asegura que estén cubiertos todos los posibles tipos de anomalías que se puedan producir.
- Es posible que los datos contengan ruido que pueda acarrear una detección de anomalías errónea.

Dependiendo de la información que se tiene acerca de los datos, existen tres tipos de detección de anomalías (Chandola et al., 2009; Hodge and Austin, 2004):

- Tipo 1: para este caso, las técnicas empleadas en este tipo de detección se denominan semisupervisadas, puesto que los datos son únicamente etiquetados como buenos, dado que el conjunto de datos de partida contiene datos obtenidos en funcionamiento normal del proceso e incluso puede contener una cantidad poco significativa de anomalías. Para este tipo de detección de fallos se entrena un clasificador con los datos correspondientes al funcionamiento normal del sistema. Por tanto, se identifica una anomalía

cuando se registra un dato que difiere del patrón de entrenamiento. Dado que la naturaleza de una anomalía es desconocida en gran parte de los casos prácticos, este tipo de detección, denominada *one-class*, sirve de utilidad en infinidad de aplicaciones. Este trabajo aborda la detección de anomalías en un conjunto de datos del que se dispone únicamente información correspondiente al correcto funcionamiento del sistema.

- Tipo 2: este tipo de detección de anomalías da por hecho que los datos obtenidos en un estado de funcionamiento anómalo del proceso están separados de los obtenidos en funcionamiento normal. Es por ello que, ante la aparición de una muestra distanciada del conjunto de datos mayoritario, ésta es considerada como una anomalía. La aplicación de este tipo de técnicas es adecuada cuando el tamaño del conjunto de datos es lo suficientemente significativo.
- Tipo 3: el conjunto de datos iniciales está dividido y etiquetado entre datos obtenidos en funcionamiento normal del proceso y anomalías. Es por ello que para llevar a cabo la clasificación se emplean técnicas supervisadas. El enfoque habitual en este tipo de casos consiste en implementar un modelo predictivo para cada uno de los grupos etiquetados. Con la llegada de un nuevo dato, se identifica a qué clase pertenece según lo determinen los modelos obtenidos. Además, la clase normal puede ser dividida a su vez en diferentes subclases.

Por otra parte, según el enfoque que se le dé a los datos de entrenamiento, existen básicamente tres tipos de métodos para abordar la detección de anomalías: los métodos de estimación de densidad, los métodos de establecimiento de límites y los métodos de reconstrucción (Tax, 2001). Los primeros tratan de identificar desviaciones de los patrones en base a la distribución de los mismos. Los segundos tratan de establecer límites espaciales para separar un dato normal de una anomalía y los terceros tratan de reconstruir los patrones de entrada y detectar las desviaciones en función de dicha reconstrucción.

Las técnicas de detección de anomalías se emplean en multitud de aplicaciones, tales como la detección de fraude en tarjetas de crédito, detección de fallos en procesos industriales, intrusión en sistemas de seguridad o diagnóstico de pacientes en medicina, entre otras (Chandola et al., 2009; González et al., 2018).

Este trabajo aborda la detección de anomalías a partir de los datos registrados durante el correcto funcionamiento de una planta industrial destinada a obtener el material empleado en fabricación de palas de aerogeneradores. En un contexto global en el que, tanto el incremento del consumo de energía como, el empleo de fuentes de energías derivadas de combustibles fósiles, han provocado un aumento de la contaminación ambiental, con las consecuencias nocivas que ello implica (Schwartz, 1994). Esto ha producido una expansión en el aprovechamiento de energías renovables no contaminantes, especialmente la energía eólica (de la Portilla et al., 2017; Zuo and Liu, 2012). Comúnmente, se emplea fibra de carbono como material base para la fabricación de las palas de aerogenerador. Este compuesto se obtiene mediante el mezclado de dos productos primarios, dando lugar a un compuesto final que recibe el nombre

de bicomponente (Young and Wu, 2011). Este compuesto tiene unas características completamente diferentes a las de las sustancias previamente mezcladas, otorgando a las palas de aerogenerador las cualidades físicas apropiadas para su uso.

Con el fin de asegurar la detección de cualquier tipo de anomalía en la instalación, y favorecer así el buen funcionamiento de la misma, se evalúan distintas técnicas de clasificación *one-class*. Concretamente, se emplean técnicas de establecimiento de límites, tales como las Máquinas de Vectores Soporte (Schölkopf et al., 2001) y Contornos Convexos Aproximados (Casale et al., 2011), así como técnicas de reconstrucción, como es el caso de los Autoencoders y del Análisis de Componentes Principales (Sakurada and Yairi, 2014; Tax, 2001).

Para evaluar y validar los métodos propuestos, se generan una serie de anomalías de manera artificial en cada una de las variables presentes en el proceso, obteniendo resultados satisfactorios en términos generales.

Este artículo está estructurado de la siguiente manera: tras la presente introducción, se describe el caso de estudio. Posteriormente se explican las técnicas empleadas para obtener el sistema de detección de anomalías. A continuación, se presentan los resultados obtenidos y finalmente, se exponen las conclusiones y los trabajos futuros.

2. Caso de estudio

Antes de abordar la detección de anomalías en el sistema de mezclado de bicomponentes, en la Sección 2.1 se hace una descripción previa del funcionamiento de la instalación y los componentes que la integran. La Sección 2.2 detalla la naturaleza del conjunto de datos del que se parte para realizar esta investigación.

2.1. Sistema de mezclado

Como se ha mencionado en la Introducción, el objetivo del sistema es mezclar dos componentes primarios con la proporción adecuada. Concretamente, uno de los componentes es una resina epoxy, y el otro es un catalizador. El bicomponente obtenido en este proceso presenta, entre otras ventajas, una gran resistencia específica tanto a esfuerzos de tracción como de compresión y una excelente resistencia ante agentes químicos, motivos por los cuales se convierte en un material ideal para la construcción de las palas de aerogenerador.

Ambos componentes a mezclar están almacenados en sendos tanques separados y son impulsados mediante dos bombas independientes encargadas de suministrar el caudal necesario para obtener la proporción de mezcla requerida.

Cada una de las bombas es accionada a través de motores comandados por variadores de frecuencia que controlan sus respectivas velocidades. El fluido bombeado circula a través de tuberías que conducen a una válvula de mezclado encargada de proporcionar el bicomponente final usado para la fabricación de las palas de aerogenerador. En la Figura 1 se muestra un esquema simplificado del sistema de mezclado en el que se aprecian los componentes de la instalación, así como los sensores presentes en ella.

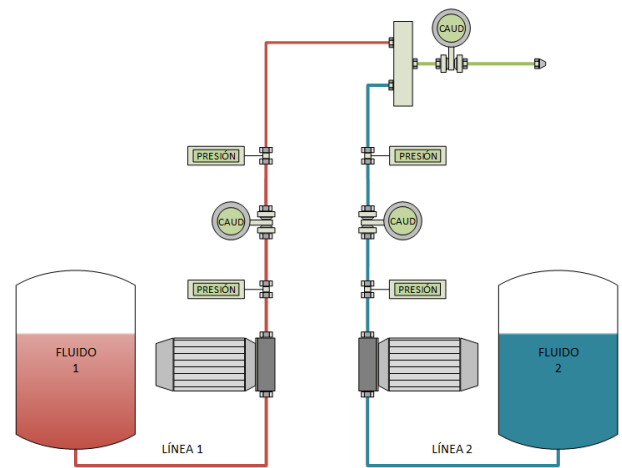


Figura 1: Diagrama del proceso

Una de las principales características del sistema radica en el hecho de que los componentes a mezclar son fluidos no newtonianos, es decir, sus propiedades mecánicas varían en función de los esfuerzos a los que se ven sometidos (Fan et al., 2006). Un ejemplo de ello se puede observar en la Figura 2, donde se representa la variación de la viscosidad en el fluido catalizador en función de los esfuerzos cortantes a los que se ve sometido. Además de las características no newtonianas de los fluidos con los que se trabaja, aspectos como, por ejemplo, el comportamiento no lineal de la bomba, aumentan la complejidad del sistema. En consecuencia, todo ello hace que la tarea de detectar una anomalía suponga un reto.




Figura 2: Variación de la viscosidad del catalizador con el esfuerzo cortante al que se ve sometido

2.2. Conjunto de datos

Durante el correcto funcionamiento del sistema se han registrado diferentes variables que conforman el conjunto de datos a partir del cual se pretende implementar el sistema de detección de anomalías. Las variables registradas son las siguientes:

- Consigna del caudal de salida: representa el caudal, en l/min de bicomponente deseado a la salida de la válvula de mezclado. Según la parte de la pala que esté siendo fabricada, el caudal a entregar varía.

- Caudales de los componentes 1 y 2: representan los caudales de salida medidos en cada una de las bombas, en l/min .
- Caudal de salida real: representa la suma de las variables descritas en el apartado anterior. Su valor varía en función de la consigna deseada para el caudal de salida (l/min).
- Velocidades de las bombas 1 y 2: representan las revoluciones por minuto a las que giran las bombas (rpm).
- Presión a la salida de las bombas 1 y 2: estas variables representan la presión medida, en bares, a la salida de cada una de las bombas que impulsan ambos fluidos (bar).
- Presión a la salida de los caudalímetros 1 y 2: son variables similares a las anteriores, pero en lugar de medirse a la salida de la bomba, se miden a la salida de los caudalímetros (bar).

En total, son 10 variables monitorizadas con una frecuencia de muestreo de 2 Hz. El conjunto de datos inicial se compone de 9511 muestras registradas durante el correcto funcionamiento de la instalación. Se ha llevado a cabo un preprocesado inicial de los datos, que consiste en eliminar aquellas muestras, en las que al menos una de las variables no está disponible. Tras este paso, el conjunto final está compuesto por 8549 muestras. Dado que los datos nulos representan casos aberrantes, se evaluará el rendimiento de las técnicas *one-class* generando una serie de anomalías artificiales en un 5 % de las muestras del conjunto preprocesado.

Para ello, se modifica en un 25 % el valor leído en únicamente una de las variables por muestra. Se ha escogido este valor en base a la experiencia de los usuarios de la instalación, que han determinado éste, como un umbral lo suficientemente significativo como para considerar el dato como anomalía. En cada una de las muestras anómalas, la variable alterada es escogida de manera aleatoria. Se considera esta situación, en la que la anomalía ocurre únicamente en un punto de la instalación, como el peor de los escenarios. Dado que la detección se realiza sobre muestras puntuales, sin tener en cuenta los estados anteriores, se identificarían las anomalías en cualquiera de las partes del sistema antes de que el lazo de control tratase de compensarlas, evitando así el fenómeno conocido como "smearing effect" (Westerhuis et al., 2000).

La Figura 3 muestra en trazo continuo azul y en trazo discontinuo rojo las variables registradas y las alteradas artificialmente para evaluar el comportamiento de los clasificadores a la hora de detectar las anomalías, respectivamente.

3. Técnicas empleadas

En esta sección se describirán las diferentes técnicas utilizadas para obtener el sistema de detección de anomalías.

3.1. Contornos Convexos Aproximados

Esta técnica de clasificación *one-class* (tipo 1) se ha revelado como una herramienta efectiva a la hora de detectar anomalías en diversas disciplinas (Casale et al., 2011; Fernández-Francos et al., 2018). Además, ofrece resultados satisfactorios en relación con otras técnicas *one-class* aplicadas a conjuntos

de datos de repositorios UCI (Universidad de California en Irvine) (Casale et al., 2014). La idea principal de esta técnica de clasificación consiste en modelar el límite de un conjunto de datos $D \in R^n$ a partir su contorno convexo. El contorno convexo $CC(S)$ de un grupo finito de puntos $S \subseteq R^n$ es el mínimo conjunto convexo que contenga a S y se define como la combinación convexa de los puntos en S según la Ecuación 1.

$$CC(S) = \sum_{i=1}^{|S|} \beta_i x_i \mid \forall i : \beta_i \geq 0 \wedge \sum_{i=1}^{|S|} \beta_i x_i = 1, x_i \in S \quad (1)$$

Dado que en esta técnica se delimita el conjunto de datos objetivo, es posible ampliar o reducir los vértices v desde el centroide $c = (1/|S|) \sum_i x_i, \forall x_i \in S$ a partir de un parámetro $\lambda \in [0, +\infty)$, de acuerdo con la Ecuación 2.

$$v^\lambda : [\lambda v + (1 - \lambda)c \mid v \in CC(s)] \quad (2)$$

De esta forma, un valor de λ menor que uno implica la contracción del contorno convexo, mientras que un valor mayor que uno provoca la expansión del mismo. Dependiendo de la naturaleza del conjunto de datos a tratar, puede resultar conveniente establecer unos límites más restrictivos ($\lambda < 1$) o unos límites más laxos ($\lambda > 1$).

Sin embargo, el proceso de obtención del contorno convexo dado un conjunto de datos con N muestras y d variables, tiene un coste computacional de $O(N^{(d/2)+1})$ (Casale et al., 2011). Para evitar este inconveniente, se plantea una alternativa que consiste en realizar p proyecciones aleatorias de conjunto de datos original sobre planos $2D$ y de esta forma determinar su contorno convexo aproximado.

Según este procedimiento, una vez se ha determinado el contorno convexo aproximado con los datos de entrenamiento, el criterio para determinar la naturaleza de los datos de test es el siguiente: si el dato está fuera en al menos una de las p proyecciones, se considera una anomalía. Un ejemplo simplificado se puede observar en la Figura 4, donde una anomalía en un conjunto de datos en R^3 se encuentra fuera en una de las proyecciones $2D$.

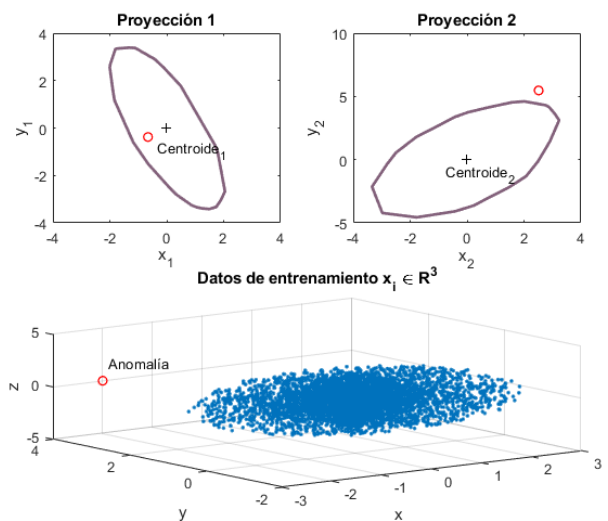


Figura 4: anomalía en R^3

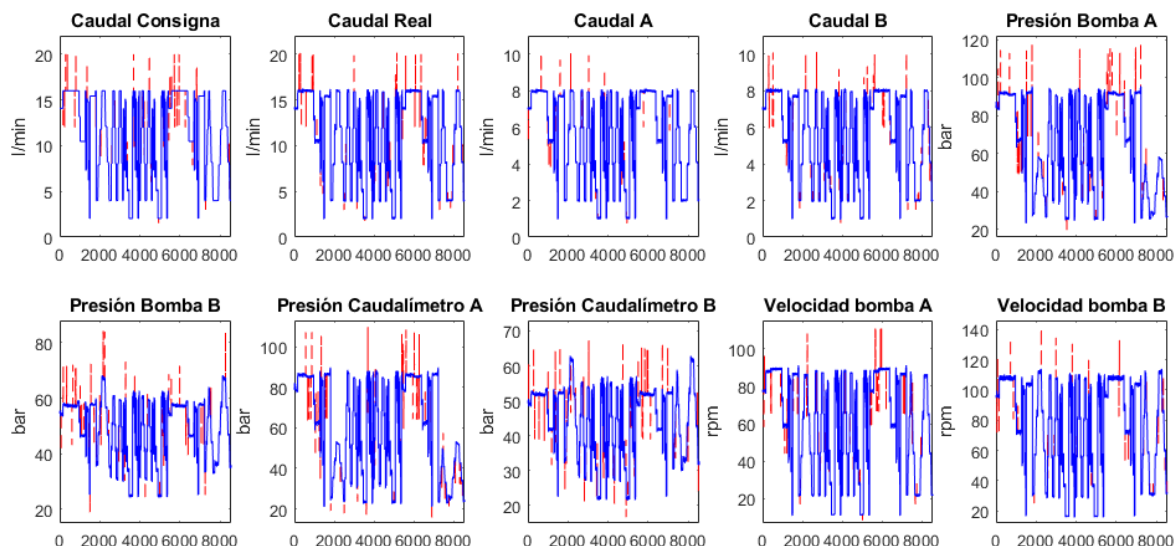


Figura 3: Variables originales y modificadas artificialmente

3.2. Autoencoders

Esta técnica perteneciente al tipo 1 se ha empleado de manera frecuente (Sakurada and Yairi, 2014) en diferentes tareas, tales como reducción de ruido en datos, detección de anomalías o aprendizaje profundo (Goodfellow et al., 2016; Vincent et al., 2010).

La clasificación *one-class* mediante Autoencoders se basa en la reducción dimensional no lineal del conjunto de datos mediante el uso de redes neuronales artificiales. Concretamente, la red neuronal artificial empleada en este tipo de tareas es el Perceptron Multicapa (Hwang and Cho, 1999; Segovia et al., 2018), cuyo comportamiento ha demostrado ser muy robusto (Zeng and Wang, 2010).

La configuración típica del Perceptron Multicapa presenta una capa de entrada, una de salida y una o más capas intermedias. Cada una de las capas está compuesta por neuronas, que a su vez presentan conexiones ponderadas con las neuronas de capas contiguas. Los pesos de las conexiones se autoajustan durante el proceso de entrenamiento de la red para reducir el error resultante de restar la salida obtenida y la deseada. Cada neurona cuenta con una función de activación y comúnmente se le asigna la misma a todas las neuronas de una capa. Esta función puede ser lineal, tangencial-sigmoidal o logarítmica-sigmoidal.

La principal idea del Autoencoder es la de entrenar una red neuronal capaz de reconstruir un conjunto de datos de entrada $x_i \in R^a$ en la salida \hat{x}_i , habiéndose producido una reducción dimensional en la capa intermedia. Por tanto, el número de neuronas de la capa de entrada es el mismo que el de neuronas a la salida, mientras que la capa intermedia debe tener al menos una neurona menos que éstas.

La red se configura de manera que el vector de entrada $x_i \in R^a$ se convierta en un vector de dimensión menor $v_i \in R^b$, de acuerdo con la Ecuación 3. Esta reducción dimensional en la capa intermedia tiene como objetivo filtrar aquellos datos que la red interprete como espurios, es decir, las anomalías.

$$v_i = f_1(W_1 x_i + b_1) \quad (3)$$

Donde:

- f_1 - Función de activación de la capa de entrada
- W_1 - Matriz de pesos entre la capa de entrada y la capa intermedia
- b_1 - Vector bias

Una vez realizada la reducción dimensional se produce la descompresión y se proyectan los datos en la salida, que debe replicar el patrón de entrada de acuerdo con la Ecuación 4.

$$\hat{x}_i = f_2(W_2 v_i + b_2) \quad (4)$$

Donde:

- f_2 - Función de activación de la capa intermedia
- W_2 - Matriz de pesos entre la capa de intermedia y la capa de salida
- b_2 - Vector bias

Una vez entrenada la red, el error de reconstrucción de un dato de test se calcula como la diferencia entre los vectores x_i y \hat{x}_i . Este parámetro se puede emplear para determinar si un dato de test tiene una naturaleza anómala o no: si dicho dato no es consistente con el modelo entrenado, el error presenta un valor elevado.

3.3. Máquinas de Vector Soporte

El uso de Máquinas de Vector Soporte (SVM, por sus siglas en inglés) para clasificación se ha implementado en gran cantidad de disciplinas, tales como reconstrucción de imágenes, clasificación de documentos o detección de anomalías (Li et al., 2003; Chen et al., 2001).

La técnica SVM empleada para *one-class* es considerada de tipo 1, y tiene como objetivo, mapear el conjunto de datos a través de una función denominada *kernel* en un espacio multi-dimensional, para luego construir un hiperplano que maximice

la distancia entre los puntos mapeados y el origen (Wei et al., 2007).

Se desea minimizar la expresión mostrada en la Ecuación 5 (Schölkopf et al., 2001; Heller et al., 2003) con respecto a los multiplicadores de Lagrange $\alpha_1, \dots, \alpha_n$ sujetos a las restricciones de la Ecuación 6 y Ecuación 7.

$$0,5 \sum_{jk} \alpha_j \alpha_k K(x_j, x_k) \quad (5)$$

$$\sum_j \alpha_j = 1 \quad (6)$$

$$0 \leq \alpha_j \leq \frac{1}{\nu l} \quad (7)$$

Donde:

- α_j - Multiplicadores de Lagrange
- $K(x_j, x_k)$ - Función *kernel*
- ν - Parámetro de aprendizaje $\in (0, 1]$
- l - Número de puntos del conjunto de datos

Valores bajos de ν implican un menor número de vectores soporte y, por tanto, un hiperplano de decisión más suave. Por otra parte, valores elevados provocan un hiperplano más curvo y ajustado al conjunto de datos, con el riesgo de producir sobreentrenamiento.

Una vez se ha confeccionado el clasificador SVM con los datos de entrenamiento, éste ofrece una puntuación ante cada dato de test. Esta puntuación se corresponde con la distancia al hiperplano de decisión. Si la distancia es positiva, el dato se encuentra dentro de la clase objetivo, mientras que si es negativa, se identifica una anomalía.

3.4. Análisis de Componentes Principales

La técnica de Análisis de Componentes Principales (PCA, por sus siglas en inglés) se ha empleado tanto para tareas de reducción dimensional como para clasificación (Chiang et al., 2000; Tax, 2001; Wu and Zhang, 2001).

Su aplicación en clasificación *one-class* (Tipo 1) trata de mapear los datos de entrada en un subespacio lineal definido por los autovectores de la matriz de covarianzas. Si el conjunto de datos es de dimensión d y se usan n autovectores, éstos se almacenan en una matriz W de dimensiones $d \times k$ (Tax, 2018). El parámetro n , conocido como el número de componentes, ha de ser menor o igual que la dimensión d del conjunto de datos inicial.

El criterio para comprobar si un nuevo dato pertenece a la clase objetivo está basado en el error de reconstrucción. Éste se computa como la diferencia entre el punto original x y su proyección en el subespacio x_{proxy} . El procedimiento para obtener la proyección y el error de reconstrucción se reflejan en las ecuaciones 8 y 9, respectivamente (Tax, 2018).

$$x_{\text{proxy}} = W \cdot (W^T \cdot W)^{-1} \cdot W^T \cdot x \quad (8)$$

$$e(x) = \|x - x_{\text{proxy}}\|^2 \quad (9)$$

El uso de esta técnica da lugar a buenos resultados cuando el subespacio es claramente lineal (Tax, 2001). Además, dado que el PCA únicamente utiliza la varianza de los datos de la clase objetivo, es necesario eliminar las muestras correspondientes al funcionamiento anómalo del proceso durante el entrenamiento (Tax, 2001).

4. Experimentos y resultados

Tal y como se comentó con anterioridad, las cuatro técnicas explicadas se aplican sobre el conjunto de datos obtenido durante el funcionamiento normal de la planta. En este trabajo se aborda la detección de anomalías provocadas de manera artificial en cada una de las variables de manera individual. En concreto, un 5 % de las muestras son transformadas en anomalías. La transformación de una muestra consiste en variar en un ± 25 % una sola de las variables elegidas aleatoriamente.

Independientemente de la técnica aplicada, ésta ha sido validada utilizando una validación cruzada *k-fold* con un valor $k = 10$. A su vez, se ha repetido dos veces esta validación, con el objetivo de evaluar, para una configuración determinada, la desviación entre los resultados de cada una de las iteraciones (Krstajic et al., 2014). El comportamiento de los clasificadores es evaluado a través del parámetro Área Bajo la Curva (%) (AUC por sus siglas en inglés). Este parámetro, que compara el ratio de verdaderos positivos y falsos positivos, ha demostrado ser un indicador representativo en este tipo de tareas (Bradley, 1997). Además, se evalúa la Desviación Típica (DT) del AUC obtenido en las distintas repeticiones, así como el tiempo de entrenamiento t_e y el tiempo de cómputo t_{comp} , es decir, el tiempo que necesita el clasificador para detectar la anomalía.

Los procesos de entrenamiento y comprobación de los clasificadores obtenidos se han llevado a cabo en un computador equipado con un procesador *Intel Core i7-8550U 1.80 GHz* y 8 GB de memoria RAM.

4.1. Clasificador mediante Contornos Convexos Aproximados

Este método fue implementado a través de Matlab, calculando los contornos convexos de cada proyección a través de la función '*convhull*'. Los parámetros definidos para determinar la configuración de esta técnica son los siguientes:

- Número de proyecciones 2D: se ha comprobado los valores: 5, 10, 50, 100, 500, 1000, 5000 y 10000.
- Parámetro λ : se ha ajustado a 0,9 (contracción de los contornos convexos), 1 (el contorno convexo no presenta modificación) y 1,1 (expansión de los contornos convexos).

Debido a que este método realiza una clasificación en función de la posición geométrica de cada uno de los puntos, no se ha optado por realizar una normalización de los datos. Los resultados, en términos de AUC, DT, tiempo de entrenamiento y tiempo de cómputo, según el número de proyecciones y el parámetro λ se representan en la Tabla 1.

Se puede apreciar a partir de la tabla que un valor de $\lambda = 0,9$ no ofrece buenos resultados. Por otra parte, se observa cómo un aumento en el número de proyecciones implica una mejora del AUC, así como un incremento significativo del tiempo de entrenamiento y de cómputo. A pesar de obtener el mayor AUC

con 10000 proyecciones y $\lambda = 1$, el clasificador con 5000 proyecciones ofrece prácticamente el mismo resultado en prácticamente una tercera parte de tiempo de entrenamiento.

Tabla 1: Resultados obtenidos con Contornos Convexos Aproximados

λ	Pro.	AUC (%)	DT (%)	$t_e(\text{min})$	$t_{\text{comp}}(\text{ms})$
0,9	5	62,90	0,74	0,01	0,15
	10	64,41	0,73	0,01	0,29
	50	65,03	0,72	0,04	2,19
	100	65,38	0,90	0,08	2,44
	500	65,53	0,81	0,41	15,67
	1k	65,49	0,65	0,83	44,89
	5k	65,08	1,08	4,27	235,52
	10k	64,91	0,84	10,78	552,68
	1	5	85,57	0,13	0,01
10		89,30	0,15	0,01	0,55
50		94,79	0,21	0,05	2,27
100		95,58	0,22	0,09	5,17
500		96,56	0,33	0,44	13,04
1k		96,95	0,40	0,93	42,17
5k		98,14	0,29	5,84	249,63
10k		98,15	0,36	14,97	525,54
1,1		5	80,97	0,04	0,00
	10	86,00	0,05	0,01	0,26
	50	92,38	0,07	0,05	2,03
	100	93,06	0,06	0,08	4,65
	500	95,00	0,09	0,48	29,20
	1k	95,43	0,08	0,96	53,02
	5k	97,12	0,13	6,29	253,50
	10k	97,78	0,13	17,43	546,60

4.2. Clasificador mediante Autoencoder

Para llevar a cabo esta técnica, se ha empleado la función 'trainAutoencoder' del software *Matlab*. El comportamiento de esta técnica se ha evaluado modificando los siguientes parámetros:

- Número de neuronas en la capa intermedia: dado que valor ha de ser menor que el número de variables, de cara a comprobar la influencia que tiene este parámetro, se ha evaluado un número de neuronas de 1, 3, 5, 7 y 9.
- Normalización: con el objetivo de comprobar qué configuración ofrece mejores resultados en términos de AUC y coste computacional, el conjunto de datos se normalizó en un intervalo de 0 a 1, utilizando el método *Z - score* (Shalabi and Shaaban, 2006) o simplemente no fueron normalizados.
- El criterio empleado para determinar si un dato se encuentra fuera de la clase objetivo y, por tanto, es identificado como una anomalía, se basa en el error de reconstrucción. Si el error de reconstrucción del dato de test sobrepasa un determinado umbral, éste se considera anomalía. Para evaluar el umbral óptimo, se compara el error de reconstrucción del dato de test con el obtenido por los datos de entrenamiento. De manera inmediata, se

puede optar por el siguiente criterio: si el error de test es mayor que el de entrenamiento, se identifica la anomalía. Sin embargo, este criterio tiene un inconveniente, ya que puede que existan datos de entrenamiento puntuales que ofrezcan un error elevado, lo que acarrearía que datos de test obtenidos en un estado de funcionamiento anómalo del proceso no fuesen identificados como tal. Por ello, se evalúa como límite el percentil del error de reconstrucción de los datos de entrenamiento desde un 75 % a un 100 %. Se selecciona entonces como valor umbral del clasificador el percentil que mejor resultados ofrezca sobre los datos de test.

- La función de activación de la capa intermedia se corresponde con una logarítmica-sigmoidal, mientras que la capa de salida tiene una función de activación lineal.

Los resultados en términos de AUC, DT, tiempo de entrenamiento y tiempo de cómputo, en función del tipo de normalización y del número de neuronas se muestran en la Tabla 2.

Tabla 2: Resultados obtenidos con Autoencoder

Nor.	Neur.	AUC (%)	DT (%)	$t_e(\text{min})$	$t_{\text{comp}}(\text{ms})$
-	1	62,89	0,43	110,53	0,01
	3	93,29	0,42	192,01	0,01
	5	95,01	1,23	203,26	0,01
	7	95,42	0,40	206,35	0,01
	9	95,81	0,34	230,33	0,01
0-1	1	51,31	1,52	0,26	0,01
	3	50,66	0,19	0,80	0,01
	5	50,67	0,46	0,74	0,01
	7	53,65	0,80	0,45	0,01
	9	54,07	0,70	0,35	0,01
ZS	1	66,73	0,47	1,00	0,01
	3	89,92	0,58	8,89	0,01
	5	90,84	0,34	6,62	0,01
	7	91,06	0,55	7,14	0,01
	9	91,45	0,43	9,74	0,01

En este caso se puede observar la gran influencia que tiene sobre los resultados el tipo de normalización aplicada. La normalización entre 0 y 1 de los datos de entrenamiento implica unos valores de AUC y tiempos de entrenamiento muy bajos. En cambio, la no normalización de los datos acarrea mejores resultados en términos de AUC (hasta 95,81 % para nueve neuronas) y tiempos de entrenamiento muy elevados con respecto al resto de configuraciones y técnicas.

La normalización mediante el método *Z - Score* ofrece valores de AUC aceptables (91,45 % para nueve neuronas) y tiempos de entrenamiento relativamente elevados en comparación con el método de Contornos Convexos Aproximados. En términos generales, el aumento del número de neuronas en la capa oculta implica un mayor tiempo de entrenamiento y una mejora en el parámetro AUC. Por otra parte, el tiempo de cómputo constante, es decir, es independiente del número de neuronas o del tipo de normalización.

El mejor clasificador para esta técnica se obtiene con una configuración de 9 neuronas sin llevar a cabo normalización.

En la Figura 5, se pueden observar, a modo de ejemplo, los errores de reconstrucción obtenidos para esta configuración. Como se puede apreciar, el error de reconstrucción para los datos de comprobación anómalos, es significativamente mayor que el obtenido para los datos de válidos, tanto de entrenamiento como de comprobación.

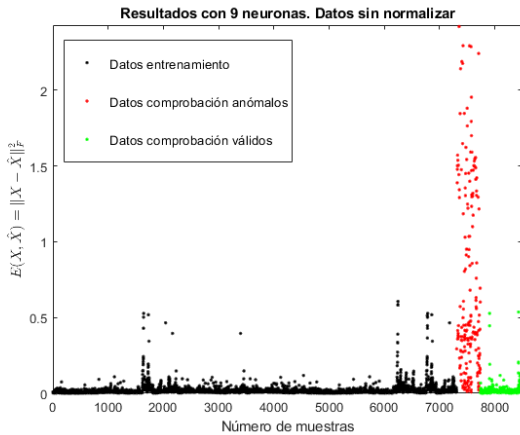


Figura 5: Error de reconstrucción obtenido con 9 neuronas y los datos sin normalizar

4.3. Clasificador SVM

El clasificador SVM se obtuvo a través del empleo de la función *'fitsvm'* del software *Matlab*. Los parámetros tenidos en cuenta para obtener el clasificador fueron los enumerados a continuación:

- Función Kernel: se configura como Gaussiana.
- Fracción de anomalías (Fr_a) de los datos de entrenamiento: se evalúa la influencia que tiene este parámetro asignando valores de entre un 0 % y 5 %, en incrementos de 1 %.
- Normalización: el conjunto de datos se normalizó en un intervalo de 0 a 1, utilizando el método *Z - Score* o simplemente no fueron normalizados.
- El criterio de decisión sobre si un dato es de naturaleza anómala, consiste en la distancia de dicho dato al hiperplano generado por la SVM. Si la distancia es negativa, el dato es identificado como anomalía.

Los valores de AUC, DT, tiempo de entrenamiento y tiempo de cómputo, en función del tipo de normalización y la fracción de anomalías se muestran en la Tabla 3.

En este caso se aprecia cómo los mejores resultados se obtienen mediante una normalización entre 0 y 1, con un 95.55 % de AUC para una fracción de anomalías de 5 %.

Sin embargo, el tipo de normalización aplicada o la fracción de anomalías no muestra una variación significativa en cuanto al tiempo de cómputo, tiempo de entrenamiento y el AUC obtenido.

Tabla 3: Resultados obtenidos con SVM

Nor.	Fr_a (%)	AUC (%)	DT (%)	t_e (min)	t_{comp} (ms)
-	0	94,76	0,80	2,45	0,08
	1	95,05	0,83	2,49	0,09
	2	95,07	1,21	2,35	0,10
	3	95,29	1,32	2,36	0,08
	4	94,92	0,95	2,33	0,08
0-1	5	94,88	1,31	2,29	0,08
	0	94,87	0,55	2,33	0,08
	1	95,08	0,71	2,35	0,08
	2	95,02	1,18	2,35	0,08
	3	94,87	0,87	2,38	0,08
ZS	4	94,74	0,98	2,34	0,08
	5	95,55	0,84	2,60	0,08
	0	95,06	0,74	2,34	0,08
	1	95,07	0,72	2,35	0,09
	2	95,24	0,98	2,32	0,11
	3	94,94	0,83	2,28	0,10
	4	95,09	1,09	2,34	0,08
	5	95,18	0,84	2,32	0,08

4.4. Clasificador PCA

Para obtener el clasificador mediante PCA, se usó la función *pca_dd* de la *toolbox dd_tool* (Tax, 2018). Los parámetros ajustados para dicha función han sido los siguientes:

- Fracción de anomalías de los datos de entrenamiento: se evalúa la influencia de este parámetro en un intervalo entre 0 % y 5 % en incrementos de 1 %.
- Número de componentes: se comprueba el funcionamiento del clasificador para un número de componentes desde 1 hasta 10, que es el número máximo de variables de los datos de entrada.
- Normalización: el conjunto de datos se normalizó en un intervalo de 0 a 1, utilizando el método *Z - Score* o simplemente no fueron normalizados.
- El criterio de decisión para determinar la naturaleza anómala de los datos de test está basado en la distancia entre el dato original y el proyectado, y se autoajusta automáticamente con la función *pca dd*.

Esta técnica ofrece los valores AUC, DT, t_e y t_{comp} , representados en la Tabla 4.

De esta tabla, se han obviado por motivos de espacio los resultados correspondientes a un número de componentes de 1, 2, 9 y 10 debido a los bajos resultados que ofrecían. Tampoco se presentan los resultados en función de la fracción de anomalías de los datos de entrenamiento, ya que no se presentaban variaciones significativas en los mismos.

El mejor clasificador en términos de AUC se obtiene con una normalización entre 0 y 1 y 4 componentes, alcanzando un 97,50 % de AUC. A partir de la Tabla 4, se puede apreciar cómo el tipo de normalización no tiene especial influencia en el AUC obtenido. Tampoco influye significativamente en el tiempo de cómputo y tiempo de entrenamiento.

Tabla 4: Resultados obtenidos con PCA

Nor.	Comp.	AUC (%)	DT (%)	t_e (min)	t_{comp} (μ s)	
-	3	91,40	0,12	0,03	3,26	
	4	92,41	0,34	0,03	3,40	
	5	95,16	0,42	0,05	6,01	
	6	96,10	0,39	0,03	3,01	
	7	96,76	0,37	0,03	4,05	
	8	77,34	0,94	0,05	5,60	
	0-1	3	94,57	0,35	0,04	4,56
		4	97,50	0,37	0,06	6,84
5		97,29	0,50	0,03	3,72	
6		93,26	0,98	0,05	6,06	
7		88,74	1,12	0,03	3,83	
8		87,53	0,35	0,06	6,46	
ZS	3	94,24	0,24	0,03	2,98	
	4	97,49	0,48	0,05	6,58	
	5	97,25	0,33	0,03	3,06	
	6	93,42	0,56	0,05	6,50	
	7	92,18	1,62	0,03	3,08	
	8	87,67	0,37	0,06	6,71	

5. Conclusiones y trabajos futuros

En este artículo, se han propuesto y evaluado cuatro técnicas distintas para llevar a cabo la detección de anomalías en una planta de mezclado de bicomponentes empleados en la fabricación de palas de aerogeneradores. A partir de los datos correspondientes al correcto funcionamiento, se han implementado distintos clasificadores *one-class* con el objetivo de detectar las anomalías generadas artificialmente variando los parámetros de la planta.

Los resultados alcanzados en términos de AUC y DT han sido muy satisfactorios en términos generales para las cuatro técnicas, ofreciendo el mejor AUC la técnica de Contornos Convexos Aproximados, con un 98,15 % y una DT de 0,36 %. Sin embargo, resulta conveniente evaluar los resultados también desde un punto de vista computacional, prestando atención a los tiempos de cómputo y de entrenamiento de cada una de las técnicas empleadas.

En la primera de las técnicas, Contornos Convexos Aproximados, el aumento en el número de proyecciones aumenta las prestaciones del AUC en detrimento del tiempo de cómputo y entrenamiento. Es por este motivo que, a pesar de obtenerse mediante esta técnica el mejor de los resultados en términos de AUC, no se elige este clasificador para la aplicación que nos ocupa.

El clasificador mediante Análisis de Componentes Principales con 4 componentes y los datos normalizados obtiene unos resultados ligeramente inferiores al mejor clasificador obtenido con Contornos Convexos Aproximados (97,50 %). Sin embargo, los tiempos de cómputo y entrenamiento son extremadamente más pequeños (6,84 μ s y 0,06 minutos respectivamente). Por tanto, se elige éste como el mejor clasificador de todos los considerados.

Con respecto al clasificador obtenido mediante Autoencoder, se puede apreciar que el tiempo de entrenamiento se reduce significativamente cuando se aplica la normalización entre 0 y

1, sin embargo los resultados obtenidos en esta configuración no son satisfactorios.

Mediante el resto de configuraciones no se obtienen resultados tan buenos como los obtenidos mediante la técnica de Contornos Convexos Aproximados, especialmente desde un punto de vista de tiempo de entrenamiento. Además, se ha demostrado para este caso, que el número de neuronas en la capa oculta tiene una influencia significativa en el coste computacional y el valor de AUC obtenido.

El clasificador obtenido a través de las SVM ofrece buenos resultados en todas sus configuraciones, sin presentarse una diferencia notable entre ellas. Sin embargo, presenta un tiempo de entrenamiento más elevado comparativamente con la técnica PCA, la cual se revela como la más rápida de las cuatro.

Para el clasificador seleccionado, se calcula un tiempo de latencia de 500,006 ms, que es el resultado de sumar el periodo de muestreo necesario para adquirir un nuevo dato (500 ms) y el tiempo de cómputo del clasificador escogido (6 μ s).

Con el método propuesto, es posible detectar de manera satisfactoria las anomalías producidas, en la totalidad de los componentes presentes en el sistema de mezclado de bicomponentes empleados en la fabricación de palas de aerogenerador.

Este clasificador se presenta como una herramienta valiosa a la hora de realizar la detección de un funcionamiento anómalo en la planta industrial, lo que permite tomar decisiones y favorecer su correcto funcionamiento, con las ventajas que ello implica, en materia de ahorro de energía, de material y mantenimiento, entre otros.

Como trabajos futuros, se podría considerar la realización de un clasificador independiente para cada una de las señales monitorizadas.

Como paso previo a la implementación de cada clasificador, posiblemente sería viable emplear Técnicas de Reducción Dimensional para disminuir el número de variables de entrada y así, reducir el coste computacional del mismo. Además, se plantea la posibilidad de emplear otras técnicas, tales como Estimación de Densidad Parzen (PDE, por sus siglas en inglés), *k-centros* o *k-medias*.

Además, debido a que el sistema está evolucionando durante su uso, es probable que el comportamiento de los datos vaya cambiando durante su correcto funcionamiento. Este cambio puede no implicar una anomalía, aunque así lo determinase el clasificador implementado en este trabajo. Una alternativa para evitar esta circunstancia consistiría en reentrenar el clasificador cada cierto tiempo de funcionamiento.

Referencias

- Bradley, A. P., 1997. The use of the area under the roc curve in the evaluation of machine learning algorithms. *Pattern Recognition* 30 (7), 1145 – 1159. DOI: [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2)
- Casale, P., Pujol, O., Radeva, P., 2011. Approximate convex hulls family for one-class classification. In: Sansone, C., Kittler, J., Roli, F. (Eds.), *Multiple Classifier Systems*. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 106–115.
- Casale, P., Pujol, O., Radeva, P., 2014. Approximate polytope ensemble for one-class classification. *Pattern Recognition* 47 (2), 854 – 864. DOI: <https://doi.org/10.1016/j.patcog.2013.08.007>
- Chandola, V., Banerjee, A., Kumar, V., 2009. Anomaly detection: A survey. *ACM computing surveys (CSUR)* 41 (3), 15.

- Chen, Y., Zhou, X. S., Huang, T. S., 2001. One-class svm for learning in image retrieval. In: *Image Processing, 2001. Proceedings. 2001 International Conference on*. Vol. 1. IEEE, pp. 34–37.
- Chiang, L. H., Russell, E. L., Braatz, R. D., 2000. *Fault detection and diagnosis in industrial systems*. Springer Science & Business Media.
- de la Portilla, M. P., Piñeiro, A. L., Sánchez, J. A. S., Herrera, R. M., 2017. Modelado dinámico y control de un dispositivo sumergido provisto de actuadores hidrostáticos. *Revista Iberoamericana de Automática e Informática industrial* 15 (1), 12–23.
DOI: 10.4995/riai.2017.8824
- Fan, H., Wong, C., Yuen, M.-F., April 2006. Prediction of material properties of epoxy materials using molecular dynamic simulation. In: *Thermal, Mechanical and Multiphysics Simulation and Experiments in Micro-Electronics and Micro-Systems, 2006. EuroSime 2006. 7th International Conference on*. pp. 1–4.
DOI: 10.1109/ESIME.2006.1644033
- Fernández-Francos, D., Fontenla-Romero, O., Alonso-Betanzos, A., 2018. One-class convex hull-based algorithm for classification in distributed environments. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 1–11.
DOI: 10.1109/TSMC.2017.2771341
- González, G., Angelo, C. D., Forchetti, D., Aligia, D., 2018. Diagnóstico de fallas en el convertidor del rotor en generadores de inducción con rotor bobinado. *Revista Iberoamericana de Automática e Informática industrial* 15 (3), 297–308.
DOI: 10.4995/riai.2017.9042
- Goodfellow, I., Bengio, Y., Courville, A., Bengio, Y., 2016. *Deep learning*. Vol. 1. MIT press Cambridge.
- Heller, K. A., Svore, K. M., Keromytis, A. D., Stolfo, S. J., 2003. One class support vector machines for detecting anomalous windows registry accesses. In: *Proc. of the workshop on Data Mining for Computer Security*. Vol. 9.
- Hobday, M., 1998. Product complexity, innovation and industrial organisation. *Research policy* 26 (6), 689–710.
- Hodge, V., Austin, J., 2004. A survey of outlier detection methodologies. *Artificial intelligence review* 22 (2), 85–126.
- Hwang, B., Cho, S., 1999. Characteristics of auto-associative mlp as a novelty detector. In: *Neural Networks, 1999. IJCNN'99. International Joint Conference on*. Vol. 5. IEEE, pp. 3086–3091.
- Jove, E., Casteleiro-Roca, J.-L., Quintián, H., Méndez-Pérez, J. A., Calvo-Rolle, J. L., 2018. A new approach for system malfunctioning over an industrial system control loop based on unsupervised techniques. In: Graña, M., López-Guede, J. M., Etxaniz, O., Herrero, Á., Sáez, J. A., Quintián, H., Corchado, E. (Eds.), *International Joint Conference SOCO'18-CISIS'18-ICEUTE'18*. Springer International Publishing, Cham, pp. 415–425.
- Krstajic, D., Buturovic, L. J., Leahy, D. E., Thomas, S., Mar 2014. Cross-validation pitfalls when selecting and assessing regression and classification models. *Journal of Cheminformatics* 6 (1), 10.
URL: <https://doi.org/10.1186/1758-2946-6-10>
DOI: 10.1186/1758-2946-6-10
- Li, K.-L., Huang, H.-K., Tian, S.-F., Xu, W., 2003. Improving one-class svm for anomaly detection. In: *Machine Learning and Cybernetics, 2003 International Conference on*. Vol. 5. IEEE, pp. 3077–3081.
- Miljković, D., 2011. Fault detection methods: A literature survey. In: *MIPRO, 2011 proceedings of the 34th international convention*. IEEE, pp. 750–755.
- Sakurada, M., Yairi, T., 2014. Anomaly detection using autoencoders with non-linear dimensionality reduction. In: *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis*. ACM, p. 4.
- Schölkopf, B., Platt, J. C., Shawe-Taylor, J., Smola, A. J., Williamson, R. C., 2001. Estimating the support of a high-dimensional distribution. *Neural computation* 13 (7), 1443–1471.
- Schwartz, J., 1994. Air pollution and daily mortality: A review and meta analysis. *Environmental Research* 64 (1), 36 – 52.
DOI: <http://dx.doi.org/10.1006/enrs.1994.1005>
- Segovia, F., Górriz, J. M., Ramírez, J., Martínez-Murcia, F. J., García-Pérez, M., 2018. Using deep neural networks along with dimensionality reduction techniques to assist the diagnosis of neurodegenerative disorders. *Logic Journal of the IGPL* 26 (6), 618–628.
URL: <http://dx.doi.org/10.1093/jigpal/jzy026>
DOI: 10.1093/jigpal/jzy026
- Shalabi, L. A., Shaaban, Z., May 2006. Normalization as a preprocessing engine for data mining and the approach of preference matrix. In: *2006 International Conference on Dependability of Computer Systems*. pp. 207–214.
DOI: 10.1109/DEPCOS-RELCOMEX.2006.38
- Tax, D., Jan 2018. Ddtools, the data description toolbox for matlab. Version 2.1.3.
- Tax, D. M. J., 2001. *One-class classification: concept-learning in the absence of counter-examples* [ph. d. thesis]. Delft University of Technology.
- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., Manzagol, P.-A., 2010. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research* 11 (Dec), 3371–3408.
- Wei, X., Huang, G., Li, Y., Aug 2007. Mahalanobis ellipsoidal learning machine for one class classification. In: *2007 International Conference on Machine Learning and Cybernetics*. Vol. 6, pp. 3528–3533.
DOI: 10.1109/ICMLC.2007.4370758
- Westerhuis, J. A., Gurden, S. P., Smilde, A. K., 2000. Generalized contribution plots in multivariate statistical process monitoring. *Chemometrics and intelligent laboratory systems* 51 (1), 95–114.
- Wu, J., Zhang, X., 2001. A pca classifier and its application in vehicle detection. In: *IJCNN'01. International Joint Conference on Neural Networks. Proceedings (Cat. No. 01CH37222)*. Vol. 1. IEEE, pp. 600–604.
- Young, W.-B., Wu, W.-H., Aug 2011. Optimization of the skin thickness distribution in the composite wind turbine blade. In: *Fluid Power and Mechatronics (FPM), 2011 International Conference on*. pp. 62–66.
DOI: 10.1109/FPM.2011.6045730
- Zeng, Z., Wang, J., 2010. *Advances in neural network research and applications*, 1st Edition. Springer Publishing Company, Incorporated.
- Zuo, Y., Liu, H., June 2012. Evaluation on comprehensive benefit of wind power generation and utilization of wind energy. In: *Software Engineering and Service Science (ICSESS), 2012 IEEE 3rd International Conference on*. pp. 635–638.
DOI: 10.1109/ICSESS.2012.6269547