



**Universidad de Valladolid**



**ESCUELA DE INGENIERÍAS  
INDUSTRIALES**

**UNIVERSIDAD DE VALLADOLID**

**ESCUELA DE INGENIERIAS INDUSTRIALES**

**Grado en Ingeniería en Tecnologías Industriales**

**Detección de fallos/anomalías en una  
planta industrial mediante técnicas de  
deep-learning y métodos de clustering**

**Autor:**

**Ormazábal Gómez, Cristina**

**Tutores:**

**De La Fuente Aparicio,**

**Maria Jesús**

**Departamento de Ingeniería**

**de Sistemas y Automática**



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA  
INDUSTRIAL MEDINTE TÉCNICAS DE DEEP-LEARNING Y  
MÉTODOS DE CLUSTERING

**Universidad de Valladolid**



ESCUELA DE INGENIERÍAS  
INDUSTRIALES



## TABLA DE CONTENIDO

RESUMEN .....	7
ABSTRACT .....	8
CAPITULO I: INTRODUCCIÓN .....	9
1.1 INTRODUCCION .....	11
1.2 OBJETIVOS DEL TRABAJO .....	12
1.3 ORGANIZACIÓN DE LA MEMORIA.....	12
CAPÍTULO II: ESTUDIO TEÓRICO .....	15
2.1 CONTROL DE CALIDAD .....	17
2.1.1. HISTORIA DE LA CALIDAD.....	17
2.2. CONTROL ESTADISTICO DE PROCESOS .....	19
2.2.1. VARIABILIDAD.....	20
2.2.2. GRAFICAS DE CONTROL .....	21
2.3 ANALISIS DE COMPONENTES PRINCIPALES (PCA).....	23
2.4 ESTADISTICOS USADOS.....	25
2.5 REDES NEURONALES .....	26
2.6 AUTOENCODER (AE).....	30
2.7. DENOISING AUTOENCODER (DAE).....	32
2.8. METODO DE LOS K VECINOS MÁS CERCANOS (K-NN).....	33
CAPÍTULO III: PLANTA TENNESSEE EASTMAN .....	37
3.1. DATOS DE LA PLANTA.....	41
CAPITULO IV: TRABAJO REALIZADO .....	45
4.1. METODOLOGIA UTILIZADA.....	47
4.2. DETECCION DE FALLOS MEDIANTE ANALISIS DE COMPONENTES PRINCIPALES (PCA).....	47
4.2.1. ANALISIS COMPORTAMIENTO NORMAL .....	48
4.2.2. ANALISIS DETECCION DE FALLOS.....	50
4.3 DETECCION DE FALLOS MEDIANTE TECNICAS DE APRENDIZAJE AUTOMATICO.....	56



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA  
INDUSTRIAL MEDINTE TÉCNICAS DE DEEP-LEARNING Y  
MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS  
INDUSTRIALES

4.3.1. REDES NEURONALES. AUTOENCODER. ....	56
4.3.2 DENOISING AUTOENCODER .....	67
4.4 COMPARACION DE RESULTADOS .....	77
CAPITULO V: CONCLUSIONES .....	79
5.1 CONCLUSIONES .....	81
5.2 TRABAJO FUTURO .....	82
BIBLIOGRAFÍA .....	83



## INDICE DE ILUSTRACIONES

<i>Ilustración 1</i> Ciclo PDCA .....	18
<i>Ilustración 2</i> Gráfico de Ishikawa [3].....	19
<i>Ilustración 3</i> Tipos de salida del proceso [4].....	21
<i>Ilustración 4</i> Grafico de control .....	22
<i>Ilustración 5</i> Interpretación geométrica.....	23
<i>Ilustración 6</i> Estructuras de una red neuronal [8].....	27
<i>Ilustración 7</i> Funcionamiento de un Autoencoder .....	30
<i>Ilustración 8</i> Estructura por capas de AE [10] .....	30
<i>Ilustración 9</i> Funcionamiento de un Denoising Autoencoder .....	32
<i>Ilustración 10</i> Funcionamiento gráfico K-NN [14].....	33
<i>Ilustración 11</i> Planta Tennessee Eastman [17].....	40
<i>Ilustración 12</i> Estadístico T2 en comportamiento normal .....	49
<i>Ilustración 13</i> Estadístico Q en comportamiento normal .....	50
<i>Ilustración 14</i> Gráficos estadísticos del fallo 2 .....	51
<i>Ilustración 15</i> Gráficos estadísticos del fallo 18.....	52
<i>Ilustración 16</i> Gráficos estadísticos del fallo 3 .....	53
<i>Ilustración 17</i> Gráfica T2 y Q de AE para el fallo 2 .....	57
<i>Ilustración 18</i> Grafica T2 y Q de AE: fallo 18.....	58
<i>Ilustración 19</i> Dh en comportamiento normal .....	62
<i>Ilustración 20</i> Dr en comportamiento normal .....	62
<i>Ilustración 21</i> Graficas estadísticas del fallo 2 .....	63
<i>Ilustración 22</i> Graficas estadísticas del fallo 18.....	64
<i>Ilustración 23</i> Graficas estadísticas del fallo 2 .....	68
<i>Ilustración 24</i> Graficas estadísticas del fallo 18.....	69
<i>Ilustración 25</i> Gráficos estadísticos del fallo 2 .....	73
<i>Ilustración 26</i> Gráficos estadísticos del fallo 18.....	73



## INDICE DE TABLAS

<i>Tabla 1 Variables manipuladas del proceso</i> .....	41
<i>Tabla 2 Variables medidas del proceso</i> .....	42
<i>Tabla 3 Tipos de fallos en el proceso</i> .....	43
<i>Tabla 4 Datos calculados del fallo 2</i> .....	51
<i>Tabla 5 Datos calculados del fallo 18</i> .....	52
<i>Tabla 6 Datos calculados del fallo 3</i> .....	53
<i>Tabla 7 Datos del PCA, estadística T2</i> .....	54
<i>Tabla 8 Datos del PCA, estadística Q</i> .....	55
<i>Tabla 9 Datos calculados AE: Fallo 2</i> .....	57
<i>Tabla 10 Datos calculados AE: Fallo 18</i> .....	58
<i>Tabla 11 Datos del AE, estadística T2</i> .....	59
<i>Tabla 12 Datos del AE, estadística Q</i> .....	60
<i>Tabla 13 Datos calculados K-NN Fallo 2</i> .....	63
<i>Tabla 14 Datos calculados K-NN Fallo 18</i> .....	64
<i>Tabla 15 Datos calculados Dh AE</i> .....	65
<i>Tabla 16 Datos calculados Dr AE</i> .....	66
<i>Tabla 17 Datos calculados del fallo 2</i> .....	68
<i>Tabla 18 Datos calculados del fallo 18</i> .....	69
<i>Tabla 19 Datos calculados T2 DAE</i> .....	70
<i>Tabla 20 Datos calculados Q DAE</i> .....	71
<i>Tabla 21 Datos calculados para el fallo 2</i> .....	73
<i>Tabla 22 Datos calculados para el fallo 18</i> .....	74
<i>Tabla 23 Datos calculados Dh DAE</i> .....	75
<i>Tabla 24 Datos calculados Dr DAE</i> .....	76
<i>Tabla 25 Tabla resumen datos medios</i> .....	77
<i>Tabla 26 Tabla resumen datos medios</i> .....	78



## RESUMEN

El control de calidad industrial es un proceso dentro de la producción enfocado en mantener y mejorar la calidad de los productos manufacturados. Este proceso es fundamental para que los productos sean seguros y satisfagan las necesidades y expectativas de los consumidores.

En este trabajo se exponen diferentes técnicas relacionadas con la monitorización de los procesos, una parte fundamental del estudio de calidad de los procesos industriales, y en concreto se busca un método de detección de fallos/anomalías de la planta basado en Deep-learning y clustering. El uso de estas técnicas fundamentadas en las nuevas tecnologías de digitalización, Industria 4.0, big data, control distribuido etc., permiten obtener y después realizar el tratamiento de un gran volumen de datos.

El método de referencia que se usa es el Análisis de Componentes Principales (PCA), una técnica de reducción de dimensionalidad. Identifica patrones de datos al encontrar la dirección en la que los datos varían más, permite detectar el estado de funcionamiento del proceso industrial y saber si su comportamiento es normal o existen anomalías, es decir, permite la detección de los fallos en la planta mediante técnicas estadísticas.

Por otro lado, el creciente auge de la inteligencia artificial, y el “Deep-learning” o aprendizaje profundo, nos permitirá usar un segundo método de detección de fallos basados en redes neuronales, en concreto utilizaremos dos técnicas: los autoencoders y los “denoising” autoencoders. Para la detección de fallos con estos sistemas se usarán las estadísticas usuales como son la estadística de Hotellings y la estadística SPE, pero también se utilizará el método de los K vecinos más cercanos (K-NN), que clasifica los datos en conjuntos según sus características. Estas técnicas se evaluarán en la planta Tennessee Eastman, comparando los diferentes métodos.

**Palabras clave:** Análisis de Componentes Principales (PCA), Redes neuronales, Autoencoder (AE), Denoising Autoencoder (DAE), Planta Tennessee Eastman, clustering, K-NN (K- vecinos más cercanos)



## ABSTRACT

Industrial quality control is a process within production focused on maintaining and improving the quality of manufactured products. This process is essential to ensure that products are safe and meet the needs and expectations of consumers.

This paper presents different techniques related to process monitoring, a fundamental part of the study of quality of industrial processes, and specifically seeks a method of detection of plant faults/anomalies based on Deep-learning and clustering. The use of these techniques based on the new technologies of digitization, Industry 4.0, big data, distributed control, etc., allows to obtain and then perform the processing of a large volume of data.

The reference method used is Principal Component Analysis (PCA), a dimensionality reduction technique. It identifies data patterns by finding the direction in which the data varies the most, allows to detect the state of operation of the industrial process and to know whether its behavior is normal or there are anomalies, i.e. it allows the detection of plant faults by statistical techniques.

On the other hand, the growing rise of artificial intelligence, and deep learning, will allow us to use a second method of fault detection based on neural networks, specifically using two techniques: autoencoders and denoising autoencoders. For the detection of failures with these systems, the usual statistics such as Hotelling's statistics and SPE statistics will be used, but also the K Nearest Neighbors (K-NN) method will be used, which sorts the data into sets according to their characteristics. These techniques will be evaluated at the Tennessee Eastman plant, comparing the different methods.

**Keywords:** Principal Component Analysis (PCA), Neuronal Network, Autoencoder (AE), Denoising Autoencoder (DAE), Tennessee Eastman Plant, clustering, K-NN (K-Nearest Neighbor)



# CAPITULO I: INTRODUCCIÓN



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA  
INDUSTRIAL MEDINTE TÉCNICAS DE DEEP-LEARNING Y  
MÉTODOS DE CLUSTERING

Universidad de Valladolid



ESCUELA DE INGENIERÍAS  
INDUSTRIALES



## 1.1 INTRODUCCION

En esta última década, el mundo ha visto una evolución en la era tecnológica. Los avances en los ordenadores han hecho posible que la información se obtenga de forma rápida y que resuelvan problemas de manera más efectiva. Internet forma parte de nuestro día a día. Proveyendo multitud de usos, organizar viajes, realizar transacciones, obtener información de actividades, realizar pedidos, estas tareas se realizan en tiempo real y se espera que no se produzcan errores. El continuo crecimiento de la tecnología garantiza una continua mejora donde se busca la máxima calidad, para ello los datos se deben analizar de forma rápida y con la máxima fiabilidad.

Un área en el que se espera un gran crecimiento es el “Big Data” y las aplicaciones relacionadas con el análisis de datos. En la actualidad, las técnicas de minerías de datos (data mining) son las encargadas de analizar datos y encontrar patrones, relaciones o anomalías para predecir tendencias. También pueden ser usados para detectar las preferencias del cliente y así proveer un servicio que satisfaga sus expectativas. [1]

Las plantas industriales han experimentado transformaciones significativas, evolucionando hacia empresas altamente automatizadas. Este progreso ha llevado a la necesidad de mantener unos estándares de eficiencia y calidad en el proceso productivo. La importancia de tener una herramienta precisa para la detección temprana de fallos en los sistemas productivos permite la optimización del proceso, reduce costos asociados al mantenimiento, minimiza las paradas por anomalías y mejora la calidad del producto final.

La detección de fallos es un área crucial en la ingeniería, particularmente en el ámbito del control de calidad. Identificar y prevenir posibles fallos es fundamental para garantizar la eficiencia y calidad del producto final.

Una de las herramientas de control estadístico del proceso más usadas en la actualidad es el Análisis de Componentes Principales (PCA), debido a que ayuda en la simplificación de grandes conjuntos de datos conservando la información importante de los datos. Con el uso del estadístico  $T^2$  (Hotelling's) y el estadístico  $Q$  (SPE) nos dice el estado de funcionamiento del proceso, es decir, si su funcionamiento es normal o existen anomalías.

Con el desarrollo de la tecnología de Deep-learning se ha cambiado la forma en la que las industrias abordan el control de calidad. Esta rama destaca por la capacidad de extraer patrones y analizar datos complejos. Al estar basado en algoritmos de redes neuronales con diferentes capas, los datos representados presentan múltiples niveles de abstracción. También se ha extendido al análisis



de los datos de sensores en tiempo real permitiendo analizar de forma rápida y precisa, identificando anomalías y contribuyendo al mantenimiento preventivo.

Entre las técnicas más usadas para el tratamiento de datos también se encuentran el clustering, basada en la agrupación de datos similares en distintos conjuntos llamados clusters. Organiza los datos y busca patrones en los datos sin etiquetar. Esta se usa en análisis de redes sociales, para análisis de patrones genéticos

## 1.2 OBJETIVOS DEL TRABAJO

El principal objetivo de este trabajo es diseñar, desarrollar e implementar técnicas basadas en datos para la detección de fallos en plantas industriales que sean mejores que las actuales. Para alcanzar este objetivo se han usado técnicas basadas en el control estadístico de procesos, como el Análisis de Componentes Principales, técnicas basadas en la inteligencia artificial y deep-learning como los Autoencoders y algoritmos de clustering como el K-NN (K vecinos más próximos).

Posteriormente, se contrastarán los resultados con las diferentes técnicas, identificando cuál de los métodos resulta más eficaz para detectar anomalías en una instalación industrial.

Los datos usados provienen de la planta Tennessee Eastman, utilizada como caso de estudio y banco de datos permitiendo el desarrollar y validar técnicas en un entorno complejo y realista.

## 1.3 ORGANIZACIÓN DE LA MEMORIA

La memoria del trabajo estará estructurada de la siguiente forma:

El primer capítulo abarca la presentación y la introducción del trabajo, donde se detalla el contexto, las metodologías utilizadas, los objetivos y una breve explicación de la organización de la memoria.

El segundo capítulo aborda de manera teórica el control de calidad, así como todas las metodologías desarrolladas para la detección de fallos.



## DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

El tercer capítulo presenta la descripción de la planta Tennessee Eastman, el banco de pruebas seleccionado. Con una breve explicación del proceso, de las variables involucradas y los fallos que se van a producir.

El cuarto capítulo recopila los datos, cálculos y resultados obtenidos para los diferentes desarrollos. Comparando los datos obtenidos mediante gráficos y tablas.

En el quinto capítulo se explican las conclusiones extraídas de los resultados del apartado anterior y sugiere ideas para futuras investigaciones.

Por último, en el sexto capítulo se documenta toda la bibliografía consultada para este trabajo.



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA  
INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y  
MÉTODOS DE CLUSTERING

Universidad de Valladolid



ESCUELA DE INGENIERÍAS  
INDUSTRIALES



# CAPÍTULO II: ESTUDIO TEÓRICO



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA  
INDUSTRIAL MEDINTE TÉCNICAS DE DEEP-LEARNING Y  
MÉTODOS DE CLUSTERING

Universidad de Valladolid



ESCUELA DE INGENIERÍAS  
INDUSTRIALES



## 2.1 CONTROL DE CALIDAD

El control de calidad es un paso imprescindible en un proceso, asegura que los procesos se han llevado a cabo de manera correcta, cumpliendo las normas correspondientes.

### 2.1.1. HISTORIA DE LA CALIDAD

La calidad ha sido un elemento innato en las actividades realizadas por el hombre, por lo que está en continua mejora. Desde la antigüedad, aparece el papel del inspector, que era la persona encargada de asegurar cierta calidad en los objetos. En la civilización egipcia, el inspector medía con una cuerda las piedras usadas en las pirámides para asegurar la homogeneidad de las piedras.

Un gran paso para la calidad fue la normalización de las piezas y su consiguiente estandarización. De forma que una pieza puede servir a cualquier objeto, ya que tienen las mismas medidas y características. Esta normalización traía el inconveniente de que, si una pieza no era apta, el operario debía manipularla hasta conseguir las especificaciones o bien tirar la pieza.

Con la llegada de la era industrial, se desarrolla el sistema de producción en serie. Al final de la línea se veía si una pieza era apta o no, por lo que, para evitar pérdidas materiales y financieras, se introdujo un nuevo departamento llamado control de calidad. Este organismo era encargado de inspeccionar tanto de manera visual como con instrumentos de medición. Si se detectaban errores, las piezas eran mandadas a personas especializadas para modificarlas y así cumplieran las especificaciones. Si eran aprobadas por el inspector, las piezas podían avanzar en la línea al siguiente paso.

Los métodos de control de calidad sufrieron un importante avance con la introducción de métodos estadísticos. En 1920, Walter A. Shewart comienza a perfeccionar el control de la calidad, incorpora los gráficos de control y otros métodos estadísticos al control de proceso. Publica el libro *Economic Control of Quality of Manufactured Product*, donde reconoce que en la producción industrial se da la variación del proceso. Y esta variación debe ser estudiada con métodos de estadística y probabilidad. [2]

Shewart establece que la variación del proceso puede ser ocasionada por causas asignables y causas aleatorias e introdujo los gráficos de control para distinguir estos dos tipos de variaciones. El uso de la estadística en el proceso

conseguía reducir los fallos por causas asignables por lo que la calidad del proceso aumentó.

El uso de métodos estadísticos se expandió a otras industrias. Walter A. Shewart, Edwards Deming y Joseph Juran desarrollaron el ciclo PDCA (Plan, Do, Check, Action) (Figura 1).

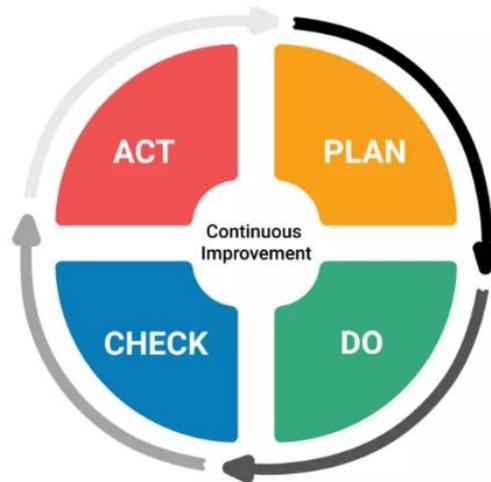


Ilustración 1 Ciclo PDCA

La importancia del control de la calidad se expandió hasta Japón. Cuando Edward Deming visitó y enseñó estas ideas a los ingenieros y empresarios japoneses. Estos tomaron esta estrategia como una ventaja competitiva, por lo que rápidamente comenzaron a profundizar en los principios del control estadístico de procesos. Las empresas realizaron cursos de entrenamiento en busca de una mejora y nació el concepto círculos de calidad, donde un grupo pequeño de empleados que se reúnen para analizar y sugerir soluciones de problemas relacionados con el trabajo, consiguiendo una mejora de la productividad.

El uso de este ciclo produjo una gran mejora, pero insuficiente ante las demandas de la industria. Se introdujo la denominada Calidad Total, la cual implica que la calidad no se debe limitar a la inspección y a los departamentos de producción, sino que debe aplicarse desde el diseño hasta la fabricación. La calidad pasa a ser una estrategia de competitividad, buscando entregar al cliente un producto que cumpla sus requerimientos y tenga una calidad mayor a la de sus competidores.

En los años 60, Kaoru Ishikawa creó el Diagrama causa-efecto, también llamado Diagrama de espina de pescado debido a la forma similar. Este identifica de forma sencilla las posibles razones por las que el proceso puede salirse de control. [3]

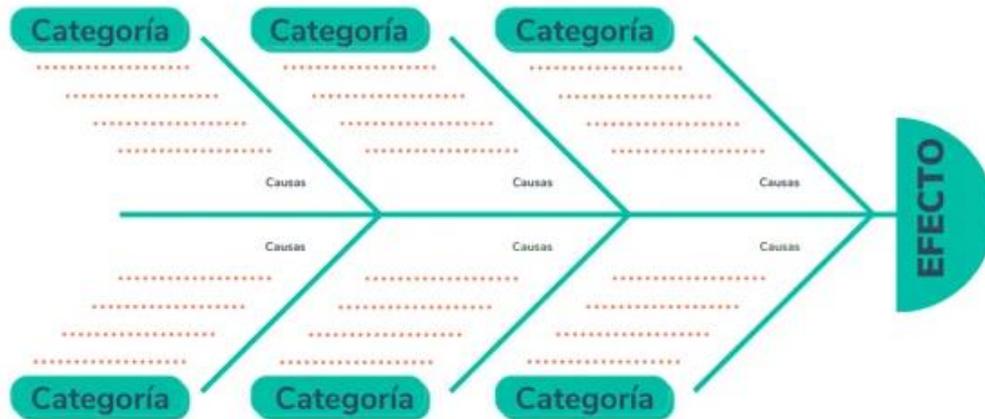


Ilustración 2 Gráfico de Ishikawa [3]

La monitorización del proceso es la primera etapa del control de calidad, en la cual se obtiene información del proceso, se detecta y realiza un diagnóstico de fallos (FDD). La actuación es la última etapa, donde se devuelve el proceso a su estado habitual tras haber aplicado las medidas y herramientas correspondientes. El método más usado es el Control Estadístico de Procesos.

## 2.2. CONTROL ESTADISTICO DE PROCESOS

El Control Estadístico de Procesos (SPC) es la aplicación de técnicas estadísticas con la finalidad de examinar la calidad de un proceso. Esta técnica disminuye los costes que provocarían las averías, reduce las piezas desechadas por fallos, permite conocer los problemas de la planta y detectar anomalías. También se emplea para revisar si un cambio introducido en el proceso produce un buen o mal resultado. [4]

Las gráficas de control son la herramienta más usada para detectar posibles anomalías en el proceso, estas se analizan para comprobar si son perjudiciales o entran dentro de los límites de tolerancia, y así poder corregir la situación antes de que perjudique a los productos. El SPC se aplica en muestras aleatorias del proceso, garantizando una estabilidad de la producción y sin la necesidad de inspeccionar todos los productos.

Se debe tener en cuenta que en un proceso hay variabilidad, por lo que hay que identificar las anomalías por causas asignables y causas aleatorias.



### 2.2.1. VARIABILIDAD

Un proceso industrial no puede fabricar dos productos exactamente iguales, siempre se presenta una variación, pueden ser las variaciones naturales del proceso, que son imposibles de controlar o por variaciones especiales que, a pesar de no poder eliminarse por completo, sí que se puede investigar y controlar con el fin de reducirlas.

La variación por causas naturales son causas predecibles ya que están relacionadas con el proceso y siguen una distribución estable. Si la variación se debe únicamente a estas causas el proceso está bajo control estadístico. Puede disminuirse la variación cambiando características inherentes al proceso.

La variación por causas especiales es de carácter espontáneo o puntual, su presencia provoca que el proceso deje de estar bajo control estadístico. Se debe aplicar las medidas necesarias para identificar y eliminar la causa y que el proceso vuelva a un estado normal.

El Control Estadístico de Procesos es el que permite estudiar el proceso y ver si la variabilidad de este es debido a causas naturales y no hace falta hacer nada o a causas especiales que deben eliminarse. Para ello, en todo el proceso necesitamos medir la variación para conocer su funcionamiento. En la figura 3 se muestran distintos tipos de salida. La salida a está fuera de control estadístico debido a causas especiales y por tanto no se asegura la calidad del mismo, la salida b muestra un proceso bajo control estadístico, pero fuera de los límites especificados, afectando a la calidad de producción. La salida c representa un proceso controlado y dentro de las especificaciones. [4]

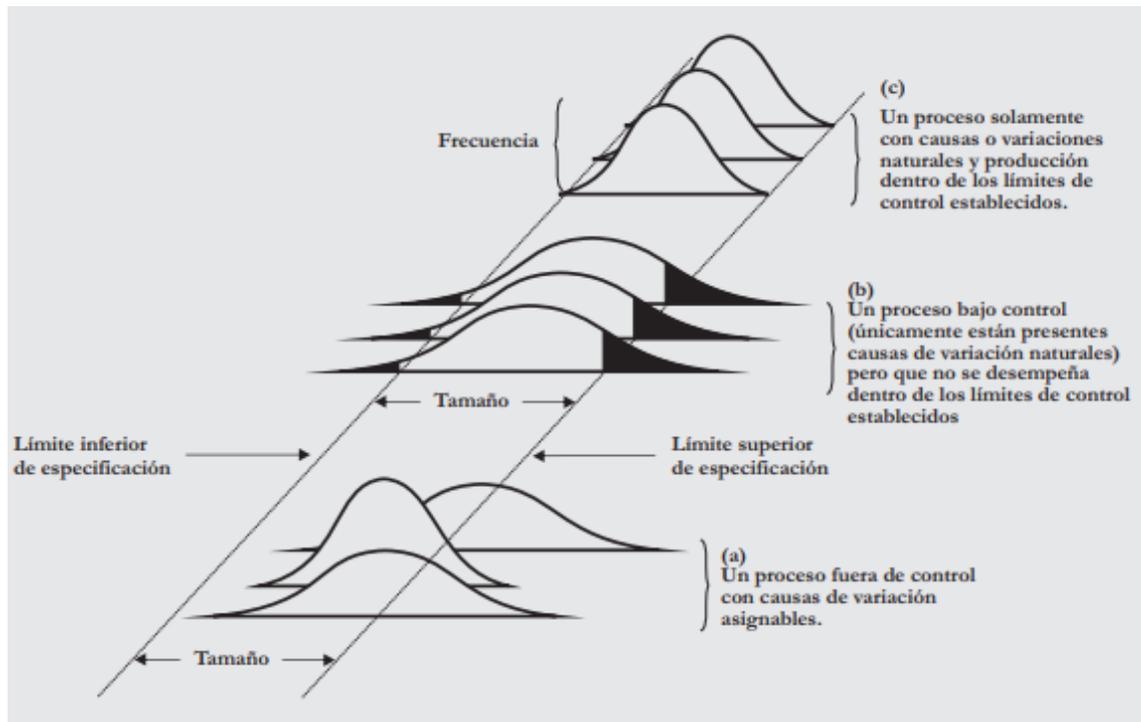


Ilustración 3 Tipos de salida del proceso [4]

## 2.2.2. GRAFICAS DE CONTROL

Es la herramienta más usada en el Control Estadístico de Procesos. Consiste en una línea central (LC) que representaría el valor medio y el objetivo a alcanzar, y dos límites de control, límite superior de control (UCL) situado arriba y el límite inferior de control (LCL) situado debajo de la línea central (Figura 4). Los valores característicos señalados en el gráfico representan el estado del proceso a lo largo del tiempo. Si se sitúan entre los dos límites, el proceso se considera bajo control estadístico, si por el contrario los puntos están marcados fuera de los límites o presentan un comportamiento extraño, el proceso está fuera de control estadístico, se necesita investigar la causa y solucionarla. Por esta razón, es una herramienta rápida e intuitiva. [5]

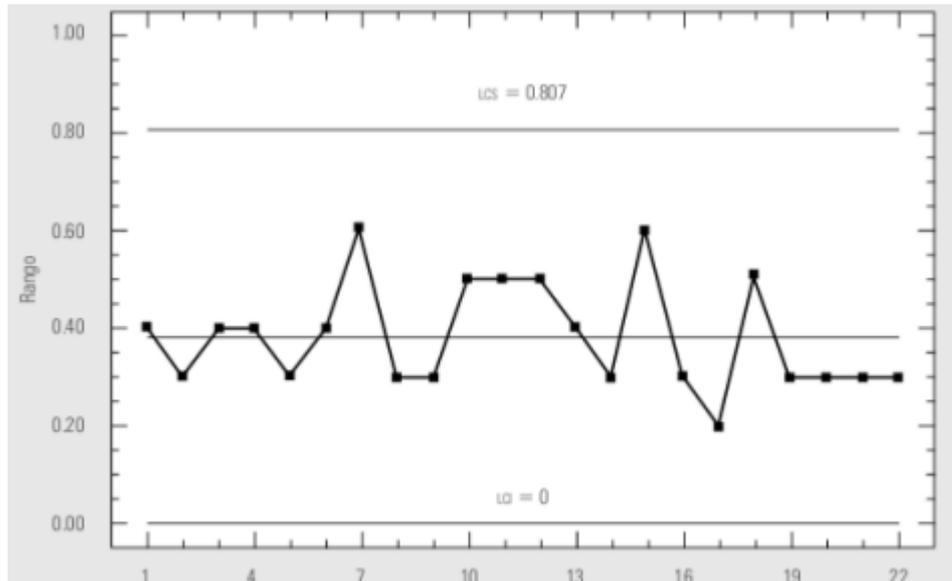


Ilustración 4 Grafico de control

Los gráficos de control se realizan de la siguiente forma:

- Seleccionar y medir una muestra aleatoria del proceso y calcular una medida variable.
- Si el punto se sitúa fuera de los límites de control, buscar una causa asignable.
- Eliminar la causa y reconstruir la gráfica con datos nuevos.
- Repetir todo el procedimiento de forma periódica.

La línea central se establece como la media  $\mu$  y los límites de control se calculan como tres veces la desviación típica  $\sigma$  del sistema, este valor corresponde a un valor de 0.0027 del parámetro  $\alpha$  para distribuciones normales, este parámetro es la probabilidad de obtener alarmas falsas, puede ser modificado, pero debemos tener en cuenta que, si el valor aumenta, las falsas alarmas aumentarían también.

Las anomalías representadas en este tipo de gráficos pueden ser divididos en dos tipos de errores distintos.

El *error tipo I*, se rechaza un lote de buena calidad, sucede cuando un punto se sitúa fuera de los límites de control y se establece que el proceso está fuera de control, cuando se trataba de un efecto aleatorio.

El *error tipo II*, se acepta un lote de mala calidad, se produce cuando los puntos fuera de los límites de control, se considera un evento aleatorio y que el proceso está bajo control, cuando realmente el proceso sí está fuera de control. [5]

## 2.3 ANALISIS DE COMPONENTES PRINCIPALES (PCA)

El análisis de componentes principales o PCA es un método estadístico que simplifica la alta dimensionalidad de un conjunto de datos, por lo que reduce su dificultad conservando toda la información posible de los datos originales. Se basa en la idea de que las variables están relacionadas entre sí, por lo que pueden estar midiendo el mismo elemento. El PCA identifica estas variables correlacionadas y las combina en nuevas variables no relacionadas llamadas componentes principales. Son ortogonales entre sí y se ordenan de forma decreciente de variabilidad, donde el primer componente principal es aquel que cuenta con la mayor variabilidad, el segundo componente principal es el siguiente con la mayor variabilidad y así continuamente. Esto nos resultará útil para escoger las variables con más información del proceso.

En una muestra con  $n$  observaciones y  $m$  variables, se busca la reducción a un subconjunto  $p < m$  variables, donde las variables  $p$  son combinaciones lineales de las  $m$  variables originales, sin correlación entre ellas y con poca pérdida de información. Esta técnica permite distribuir el espacio en dos subespacios, representando el conjunto de datos, tomando como ejemplo la Figura 5, la figura muestra un elipsoide con dos ejes, los cuales representan los dos componentes principales y por tanto los dos subespacios. El eje mayor representa la tendencia del proceso y el menor representa el residuo de este. [6]

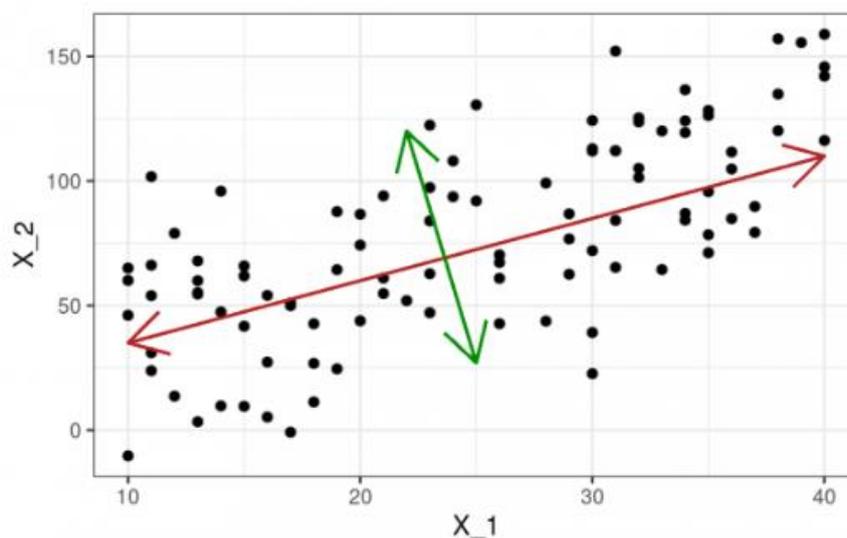


Ilustración 5 Interpretación geométrica



Para comenzar con el desarrollo matemático de este proceso, se deben aplicar a los datos un pretratamiento, eliminando las variables que tienen valores erróneos, ya sea por errores de los instrumentos de medida o de los sensores, debido a que no aportan información real al proceso. Después, se normaliza las  $m$  variables con media 0 y varianza 1, para que todas contribuyan por igual en el análisis.

Finalizado el pretratamiento, se aplica el método al conjunto de datos. Obteniendo una matriz  $X$  de dimensión  $n \times m$ . El siguiente paso consiste en calcular la matriz de covarianza, la cual nos ayuda a ver si hay alguna relación entre las variables, porque algunas pueden estar correlacionadas y contienen información importante. La matriz de covarianza tiene dimensión  $m \times m$ , y es simétrica respecto a su diagonal principal.

$$R = \frac{1}{n-1} \cdot X^T \cdot X \quad (1)$$

Se calcula la descomposición de  $R$  en valores singulares. Donde la matriz  $\Lambda$ , de dimensión  $m \times m$ , está formada por valores propios reales no negativos ordenados en orden decreciente ( $\lambda_1 \geq \lambda_2 \geq \dots \geq 0$ ),  $\lambda_i$  es la varianza  $\lambda_i = \sigma_i^2$ . Y la matriz  $V$ , de dimensión  $m \times m$ , cuyas columnas están formadas por los vectores propios o vectores de carga.

$$R = V \cdot \Lambda \cdot V^T \quad (2)$$

Para reducir la dimensionalidad conservando la mayor cantidad de información posible, elegimos  $a$  vectores propios correspondientes a los  $a$  valores propios mayores, hasta que la varianza acumulada sea mayor o igual que el valor de un porcentaje a elegir, el cual en este trabajo será 90%.

Almacenamos los  $a$  vectores propios anteriormente seleccionados en la matriz  $P$ , la cual tendrá una dimensión reducida  $m \times a$ , y con la matriz de datos  $X$ , se crea la matriz de transformación  $T$  de dimensión  $n \times a$ .

$$T = X \cdot P \quad (3)$$

Para volver al espacio de partida, mediante las matrices  $P$  y  $T$ , se obtiene la matriz  $X$  recalculada:

$$\hat{X} = T \cdot P^T \quad (4)$$



Y esta nos proporciona la matriz de residuos  $E$ , definida como la diferencia entre la matriz de datos originales y la matriz recalculada.

$$E = X - \hat{X} \quad (5)$$

De forma que se obtiene el conjunto de datos inicial:

$$X = \hat{X} + E \quad (6)$$

Con estos datos calculados, se pasa a la detección de fallos.

## 2.4 ESTADÍSTICOS USADOS

Una vez definido el espacio reducido de componentes principales, se realiza la detección de fallos con PCA. Se utiliza dos estadísticos, uno analiza el espacio de los componentes principales y el otro el espacio de los residuos. Estos permiten establecer un umbral para detectar los fallos.

### Estadístico Hotellings $T^2$ :

El estadístico  $T^2$  se puede definir de esta forma:

$$T^2 = x \cdot P \cdot \Lambda_a^{-1} \cdot P^T \cdot x^T \quad (7)$$

A partir de la matriz normalizada  $X$ , cada una de las filas de esta, forman una observación  $x \in \mathfrak{R}^{m \times 1}$ , con la matriz  $P$  previamente calculada. La matriz  $\Lambda_a$ , con  $a$  número de componentes elegido anteriormente, esta compuesta por las primeras  $a$  columnas y filas de  $\Lambda$ .

Es necesario establecer un umbral, para ser capaz de detectar el fallo. Si una muestra supera el umbral  $T^2$ , se ha producido un fallo, por lo que el proceso está fuera de control estadístico.

$$T_\alpha^2 = \frac{(n^2-1)a}{n(n-a)} \cdot F_\alpha \cdot (\alpha, n - a) \quad (8)$$

En la fórmula,  $n$  son el número de observaciones,  $a$  el número de componentes principales y  $(a, n - a)$  es el valor crítico de la distribución de Fisher-Snedecor con  $\alpha$  como valor de significancia y  $n-a$  grados de libertad. [6]

El estadístico  $T^2$  está basado en los  $a$  primeros componentes, que muestra la variabilidad del proceso mediante la medida de las desviaciones de las



variables latentes, es decir, el fallo solo se detecta si la variación de las variables latentes es mayor que la variación por causas comunes. El estadístico Q soluciona este problema analizando las variables anteriormente consideradas ruido.

### Estadístico Q o SPE:

Se define de la siguiente forma:

$$Q = r^T \cdot r \quad (9)$$

El vector de residuos  $r$ , se calcula, a partir de la observación  $x \in \mathfrak{R}^{m \times 1}$

$$r = (I - PP^T)x \quad (10)$$

Al igual que con el anterior estadístico, se necesita establecer un umbral.

$$Q_\alpha = \theta_1 \cdot \left[ \frac{h_0 C_\alpha \sqrt{2\theta_2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{\frac{1}{h_0}} \quad (11)$$

Donde  $C_\alpha$  es el valor de la distribución normal con media 0 y desviación estándar 1.

La detección de fallos es más fiable si se utilizan ambos estadísticos. El primer estadístico detecta fallos solo si la variación es mayor que la variación por causas comunes y el estadístico Q detecta fallos en el ruido descartado.

En este trabajo, se detectará fallo si las observaciones sobrepasan los umbrales 10 veces consecutivas. La elección de este número es para evitar posibles falsas alarmas.

## 2.5 REDES NEURONALES

Las redes neuronales artificiales son un modelo computacional que se inspira en la estructura, organización y procesamiento del cerebro de los seres humanos. Estos modelos forman parte de la rama científica 'machine learning', el cual consiste en el uso de algoritmos y datos para que las máquinas encuentren patrones y desarrollen sistemas que aprendan y hagan predicciones.

Las redes neuronales son dinámicas, constantemente están adaptándose a las nuevas condiciones, y son adaptativas, tienen capacidad de autoajustarse [7]

de forma que la salida de la red neuronal obtenga un resultado lo más similar posible a la salida real. Estas son unas de las características más atractivas de las redes neuronales, ya que no se necesita crear modelos previos, distinguen patrones con ejemplos y con el entrenamiento.

Una red neuronal (Figura 6) está compuesta por neuronas interconectadas y ordenadas en capas que procesan la información. Los datos se introducen por la capa de entrada, cruzan a través de las capas ocultas y salen por la capa de salida.

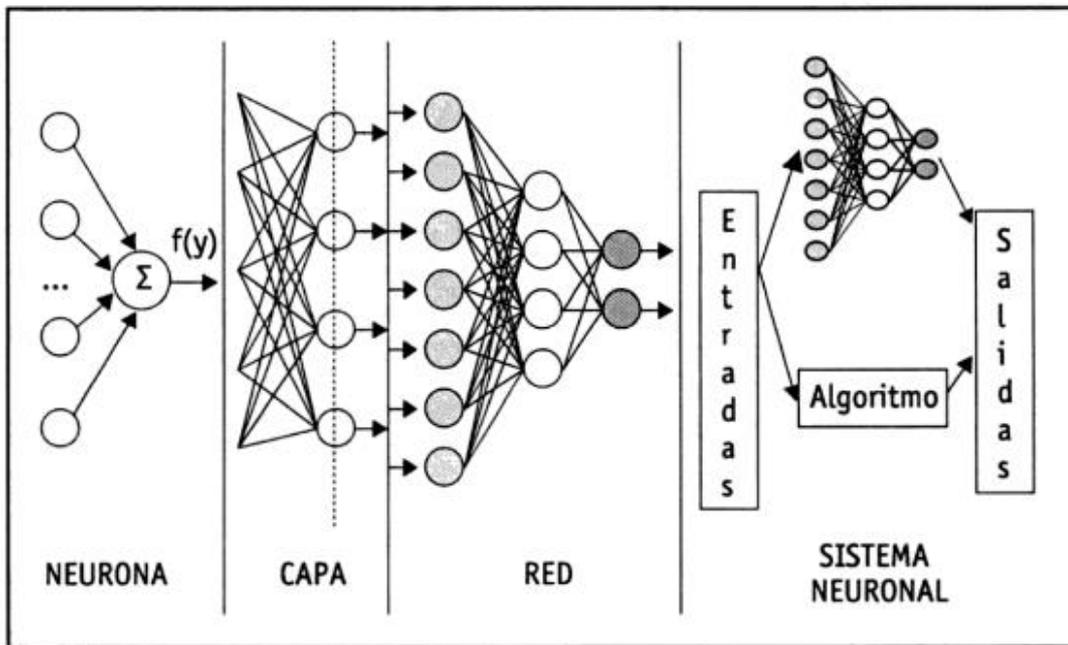


Ilustración 6 Estructuras de una red neuronal [8]

La red neuronal con propagación hacia adelante (Feedforward Neuronal Network) es la más sencilla y usada de todas las redes neuronales creadas. En esta red, la información se mueve solo en una dirección, desde la capa de entrada a la capa de salida. No se producen ciclos, ni realimentaciones. La red puede estar formada por múltiples capas. [9]

La red neuronal recurrente sí que tiene realimentaciones. Son modelos bidireccionales.



Las neuronas son procesadores básicos. Reciben un vector de entrada y proporcionan una salida única, que se convierte en la entrada para otra capa de neuronas. Cada neurona  $x_i$ , envía una señal de entrada ponderada con un peso sináptico  $w_{ji}$  que determina la importancia de la información de cada conexión. Este peso multiplica a su entrada y sumando todas las entradas ponderadas, obtenemos la entrada total a la neurona  $y_j^{input}$ . Las neuronas de entrada no realizan este proceso, solo pasan la información.

$$y_j^{input} = \sum_{i=1}^n w_{ji} \cdot x_i \quad (12)$$

A esta se le aplica una función de activación, y elabora una señal de salida  $y_j$ .

$$y_j = f(y_j^{input}) \quad (13)$$

El aprendizaje de la red neuronal es un proceso por el cual las neuronas adaptan sus parámetros debido a la interacción continua con el medio ambiente. Las neuronas varían sus pesos sinápticos y el umbral de forma que permitan a la red desarrollar la tarea correcta.

Las funciones de activación pueden ser lineales o no lineales, las lineales son poco usadas en Deep-learning debido a que la necesidad de que las redes neuronales aprendan a tomar decisiones solo lo permiten las funciones no lineales. Las funciones de activación más usadas son:

- *Función Sigmoide*: Esta función produce valores de salidas entre [0,1]. Se interpreta como una probabilidad, por esta razón se usa en la última capa para clasificar datos en categorías.

$$f(x) = \frac{1}{1+e^{-x}} \quad (14)$$

- *Función Tangente hiperbólica*: Similar a la Sigmoide pero esta función da valores entre [-1,+1]

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (15)$$

- *Función RELU (Rectified Lineal Unit)*: Es la función más usada en este momento debido a su simplicidad y el uso de poca memoria de procesamiento, es usada en las capas ocultas, no en la capa de salida. La entrada es un valor  $x$  y la salida un valor máximo entre 0 y  $x$ .

$$f(x) = \max(0, x) \quad (16)$$



El entrenamiento de las redes neuronales puede dividirse en dos clases:

- *Entrenamiento supervisado:* Está basado en el control del entrenamiento por un elemento externo (supervisor o maestro). Se entrega un vector de entrada a la red, calcula la salida y el supervisor la contrasta con la salida deseada, la diferencia entre ambas salidas se realimenta a la red y los pesos se reajustan para minimizar el error. Es un proceso cíclico hasta conseguir una diferencia mínima.
- *Entrenamiento no supervisado:* La red no recibe información por elementos externos, no usa un vector de salida deseado, solo tiene vectores de entrada. El algoritmo varía el valor de los pesos a la entrada, para que las entradas similares, proporcionen una salida parecida. El proceso agrupa en clases los vectores de entrada con características similares, es decir, busca patrones para agrupar los datos en categorías.  
[10]

El algoritmo de retropropagación hacia atrás (backpropagation) es el más usado para las redes neuronales (FNN). Este método ajusta los pesos de una red neuronal mediante la minimización del error. Calcula un gradiente de la función de pérdida respecto a los pesos de la red y actualiza los pesos en la dirección opuesta al gradiente, minimizando la pérdida.

Este algoritmo tiene dos fases:

-*La propagación hacia adelante.* En esta fase los datos se introducen en la capa de entrada y se propagan capa por capa, calculando las salidas de la red, mediante funciones de activación.

-*La retropropagación.* Se calcula el gradiente de la función de pérdida con los pesos de la red. Y luego se ajustan utilizando el gradiente, esto actualiza los pesos minimizando la pérdida.

La retropropagación se repite múltiples veces, consiguiendo que la red neuronal ajuste y aprenda sus pesos para realizar más precisas sus predicciones.

## 2.6 AUTOENCODER (AE)

El autoencoder (Figura 7) es un tipo específico de red neuronal con propagación hacia delante con un algoritmo de aprendizaje no supervisado [11]. El cometido del AE es obtener una salida que sea igual que los datos de entrada. La arquitectura puede dividirse en dos partes, el encoder, encargado de reducir la dimensionalidad y el decoder, encargado de la operación contraria. Por lo que es necesario que tanto la capa de entrada como la de salida tengan el mismo número de neuronas.

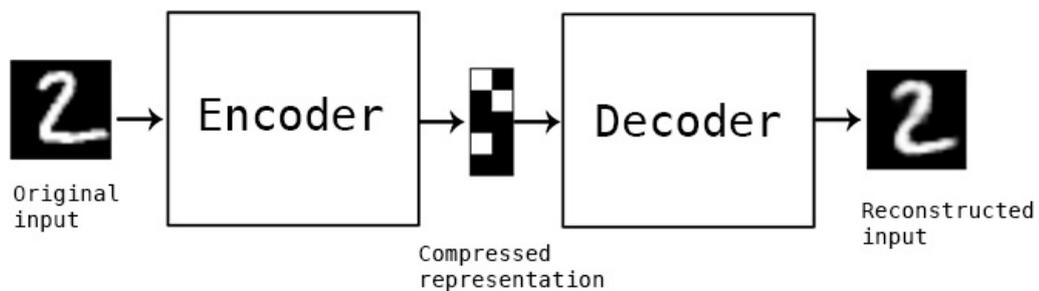


Ilustración 7 Funcionamiento de un Autoencoder

El AE (Figura 8) recibe una entrada de datos de alta dimensionalidad, el encoder la comprime, conservando la información relevante y desechando la irrelevante, y la transporta a la capa oculta. El decoder recibe de la capa oculta la versión comprimida y vuelve a reconstruir los datos. La función “Loss” o también llamada pérdida de reconstrucción, es el error medio entre la entrada y salida. En este trabajo, se ha usado la función ‘Mean Square Error’

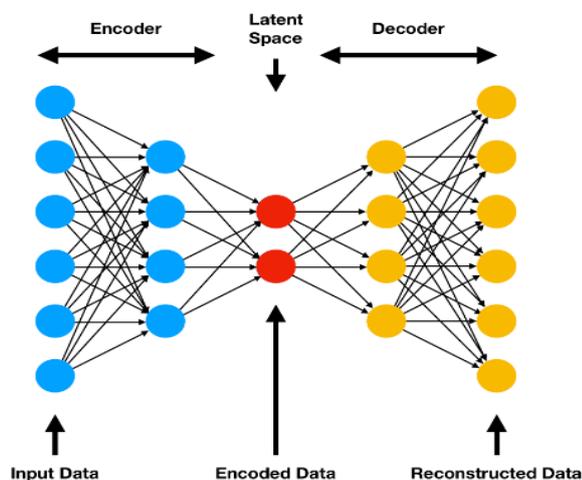


Ilustración 8 Estructura por capas de AE [10]



Tiene una limitación de uso, dado que solo comprimen datos similares a los usados para su entrenamiento.

Un problema a tener en cuenta en estos tipos de redes es el sobreajuste. Este ocurre por diferentes razones, el modelo se entrena durante mucho tiempo, los datos contienen mucho ruido, el tamaño de los datos de entrenamiento son muy pequeños o el modelo tiene una alta complejidad. Esto provoca que el algoritmo aprenda patrones que no son relevantes o que comience a memorizar el ruido. [12]

Para detectar este problema, los datos de entrenamiento se separan en dos agrupaciones, el grupo 'entrenamiento' y el grupo 'test'. El conjunto de datos 'test' se utilizan como datos de prueba. Una tasa de error alta indica sobreajuste.

Para evitar este problema, el reducir el número de neuronas de la capa oculta para que sea menor que en las capas de entrada y de salida o el aumentar los datos del conjunto 'entrenamiento' para que el algoritmo generalice mejor, son las soluciones más sencillas. En este trabajo se ha utilizado un método de regularización para evitar el sobreajuste, en concreto una penalización L1 sobre los pesos de las capas ocultas.

Una vez entrenado el autoencoder para usarlo para la detección de fallos, se usarán los estadísticos  $T^2$  y  $Q$ . Estos estadísticos se definen de la siguiente forma:

El estadístico  $T^2$  va a calcularse con los valores calculados en la capa del encoder, es decir, la capa con menos neuronas cuya salida es la matriz  $h$ .

$$T^2 = (h - \bar{h}) \cdot \sigma^{-1} \cdot (h - \bar{h})^T \quad (17)$$

Donde  $\bar{h}$  es la media de  $h$  y  $\sigma$  la matriz de covarianza de  $h$ .

El estadístico  $Q$  se calcula con la diferencia entre los datos reales y los datos predichos, es decir, el residuo  $r$ . En este caso, la media  $\bar{r}$  y la matriz de covarianza será del residuo.

$$Q = (r - \bar{r}) \cdot \sigma_r^{-1} \cdot (r - \bar{r})^T \quad (18)$$

Los umbrales en este trabajo se definen en el percentil 99, por lo que el 99% de los datos están bajo el umbral.

## 2.7. DENOISING AUTOENCODER (DAE)

Una función importante de los autoencoders es la reducción o eliminación de ruido. El Autoencoder Denoising (Figura 9) recibe como entrada una versión de los datos con ruido añadido.

Este autoencoder detecta las características principales e importantes de la entrada y elimina el ruido restante, de esta forma reconstruye los datos originales. Cuando se calcula la función Loss, es importante que la salida deseada (entrada sin ruido) se compare con la salida de la red cuya entrada tiene ruido, para que el algoritmo no aprenda la función de identidad sino las características.

El ruido en los datos hace que sea más parecido a un conjunto de datos real, mejorando la ejecución del modelo y haciendo que este algoritmo sea muy bueno eliminando ruido. Una característica deseada en el campo médico, por ejemplo, para la detección de enfermedades tempranas.

Para detectar fallos con este DAE se usarán las estadísticas  $T^2$  y  $Q$ , definidas en las ecuaciones (17) y (18), y el umbral de las mismas también se calcula usando el percentil del 99%.

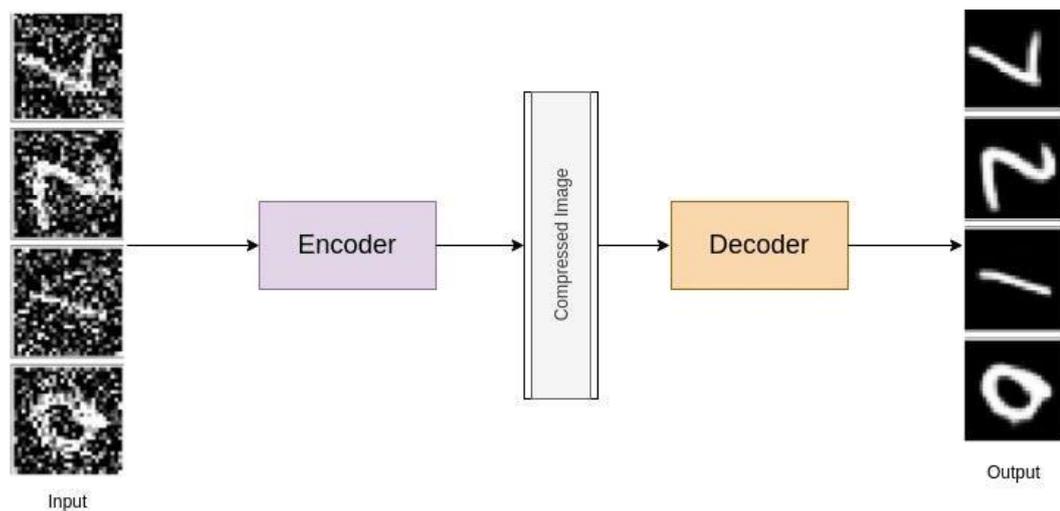


Ilustración 9 Funcionamiento de un Denoising Autoencoder

## 2.8. METODO DE LOS K VECINOS MÁS CERCANOS (K-NN)

El algoritmo de aprendizaje de los K-vecinos más cercanos, K-Nearest Neighbor, es un modelo de aprendizaje inductivo supervisado. Consiste en la suposición de que los datos similares se encuentran unos cerca de otros, donde K es el valor que determina el número de vecinos en los que hay que fijarse para seleccionar a que clase pertenece (Figura 10). Este algoritmo se clasifica como un modelo de aprendizaje perezoso, el cual en vez de pasar por una etapa de entrenamiento, almacena un conjunto de datos de entrenamiento y el cálculo solo se realiza cuando se ejecuta una clasificación. Esto produce una necesidad de gran cantidad de memoria y almacenamiento de datos comparado con otros algoritmos.

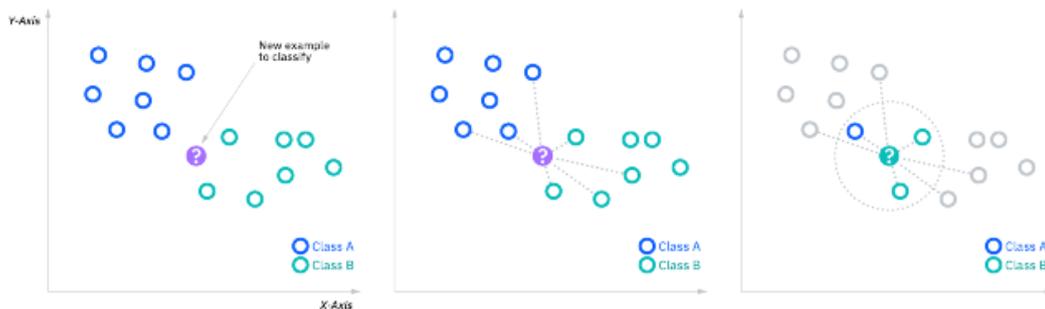


Ilustración 10 Funcionamiento gráfico K-NN [14]

Para el cálculo del algoritmo, primero se debe calcular una matriz distancia con los vectores de distancia de los datos de entrenamiento, luego se calcula la distancia entre el vector de un punto a clasificar con respecto a otros ya clasificados, se seleccionan las k distancias más pequeñas. El nuevo punto se asigna a la clase más repetida. [13]

Para determinar la distancia entre el punto a clasificar y los datos, se usan las siguientes medidas de distancia:

- La *distancia Euclidiana*, es la más usada y mide la distancia más corta, es decir, la línea recta de dos puntos.



$$d_{ij} = \sqrt{\sum_{k=1}^n (x_{ki} - x_{kj})^2} \quad (19)$$

- La *distancia Manhattan*, mide el valor absoluto entre dos puntos. También llamada distancia taxi, ya que se visualiza como una cuadrícula, similar a moverse por las calles de una ciudad

$$d_{ij} = \sum_{k=1}^n |x_{ik} - x_{jk}| \quad (20)$$

- La *distancia Minkowsky*, es la fórmula generalizada de la distancia euclidiana y la distancia Manhattan. El parámetro p permite crear nuevas fórmulas. La distancia euclidiana surge cuando el parámetro p=2 y la distancia Manhattan cuando el p=1.

$$d_{ij} = (\sum_{k=1}^n |x_{ik} - x_{jk}|)^{1/p} \quad (21)$$

La elección del valor k depende de cada situación, un determinado valor de k puede llevar a un ajuste insuficiente o a uno excesivo, por eso hay que tener en cuenta los datos de entrada, por ejemplo si estos tienen mucho ruido se recomienda usar un valor alto de k. [14]

Un alto valor de k reduce la varianza, pero puede desechar patrones pequeños que contiene información importante o haría que el algoritmo siempre eligiera la clase más común. Un valor k muy pequeño, por el contrario, no desecha el ruido, influyendo erróneamente en la clasificación.

Las ventajas de este algoritmo es su sencilla implementación, dada su sencillez y precisión, no hay coste de aprendizaje, se pueden agregar nuevos datos de forma sencilla y funciona correctamente ante la presencia de ruido.

Su principal desventaja es el cálculo con datos con alta dimensionalidad, una cantidad muy grande de datos de entrada puede crear el fenómeno de pico, el cual ocurre después de alcanzar la cantidad óptima de funciones, los errores de clasificación comienzan a aparecer. También puede producirse un sobreajuste, si la elección de k no es la adecuada. Al necesitar mucha memoria también es un método costoso.

Usar el método K-NN para detectar fallos surge de la idea de que la distancia entre una muestra con fallo y sus k vecinos más próximos con datos normales de operación es mucho más grande que la distancia entre una muestra de comportamiento normal y las k muestras más próximas también de comportamiento normal.



Por tanto, para comenzar a desarrollar el método de K-NN como técnica para detectar fallos, se normaliza la matriz de entrada  $X$  (de datos de comportamiento normal del proceso) con media cero y varianza uno, para dotar a todos los datos con la misma importancia.

Se introducen los datos al Autoencoder para conseguir dos conjuntos de datos, el conjunto  $h$  son las características extraídas de la capa oculta y el conjunto  $r$  son las características resultado de la diferencia entre los datos de la capa de salida y los datos de entrada. Estas dos variables serán usadas para la detección de fallos.

Para cada variable realizamos los siguientes pasos.

1.- Encontrar los  $k$ -vecinos más próximos en cada espacio de trabajo de comportamiento normal,  $h$  y  $r$ . Para ello, se calcula la distancia euclídea de cada muestra respecto a todas las demás, obteniendo matrices  $(d_{ij})$  de dimensiones  $n \times n$ , donde  $n$  es el número de muestras. Seleccionar los  $k$  valores más pequeños por cada fila, y las matrices se reducen a  $d_{ij}$  de dimensiones  $(n \times k)$

2.- Se calcula la suma al cuadrado de las distancias de cada muestra con sus  $k$ -vecinos más próximos, obteniendo como resultado una matriz  $Dh^2 \in \mathcal{R}^{n \times 1}$  y  $Dr^2 \in \mathcal{R}^{n \times 1}$ , respectivamente (ecuación 22).

$$D_i^2 = \frac{1}{k} \sum_{j=1}^k d_{ij}^2 \quad (22)$$

3.- Se calcula los umbrales de cada estadístico, definidos en este trabajo como el percentil 99,  $(Dh_{\alpha^2}$  y  $Dr_{\alpha^2}$ ) [15]

Para detectar fallos, cuando llega una nueva muestra  $x_{new}$  que debemos clasificar:

a) Se pasa por el autoencoder y se obtiene el vector de características  $h(x_{new})$  y el residuo  $r_{new}$ .

b) Se calculan los  $k$  vecinos más próximos de esta nueva muestra en cada uno de los dos espacios, con los datos de entrenamiento, como se hizo en el paso 1 del algoritmo.

c) Se calculan las dos estadísticas para esta nueva muestra  $Dh^2(x_{new})$  y  $Dr^2(x_{new})$  y se comparan con su umbral, Si ambas estadísticas están por debajo del umbral, es decir,  $Dh^2 \leq Dh_{\alpha^2}$  y  $Dr^2 \leq Dr_{\alpha^2}$  la muestra es de comportamiento normal, en cualquier otro caso hay fallo.



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA  
INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y  
MÉTODOS DE CLUSTERING

Universidad de Valladolid



ESCUELA DE INGENIERÍAS  
INDUSTRIALES



# CAPÍTULO III: PLANTA TENNESSEE EASTMAN



**Universidad de Valladolid**

DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA  
INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y  
MÉTODOS DE CLUSTERING



**ESCUELA DE INGENIERÍAS  
INDUSTRIALES**

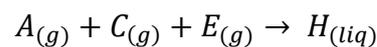
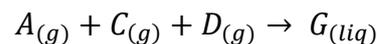


En este trabajo se van a usar los datos extraídos de la planta Tennessee Eastman. Creada para ser un problema de referencia para desarrollar diferentes tecnologías y como banco de pruebas para ingenieros o científicos en el control estadístico de procesos.

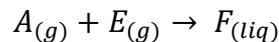
En 1993, Downs y Vogel publicaron un modelo inspirado en el proceso de la empresa Eastman Chemical Company, para un propósito experimental. Esta planta es un proceso no lineal multivariable y con alta complejidad permitiendo poder estudiar distintos métodos de detección de fallos. [16]

En esta planta dan lugar cuatro reacciones las cuales están formadas por cuatro reactivos (A, C, D, E), dos productos (G, H), un subproducto (F) y un inerte (B), dando lugar a ocho componentes. Las reacciones llevadas a cabo son las siguientes:

- Reacciones de los productos:



- Reacciones de los subproductos:



Todas las reacciones son exotérmicas, reversibles, tienen una relación lineal entre la concentración y el tiempo, y el equilibrio depende de la temperatura. La reacción que da lugar al producto G tiene una sensibilidad mayor frente a la temperatura alta debido a su alta energía de activación.

En el proceso (Figura 11) hay cinco operaciones unitarias, una reacción, una condensación, una separación líquido-vapor, una compresión y una operación de desorción o stripping. Por otra parte, también hay elementos secundarios como bombas, válvulas de control, indicadores, analizadores, etc...

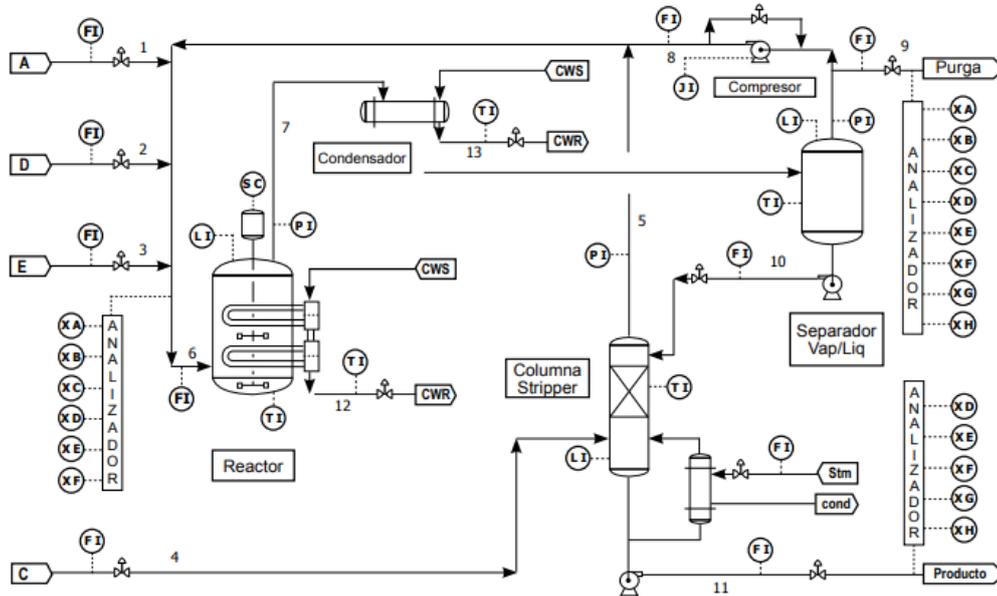


Ilustración 11 Planta Tennessee Eastman [17]

El proceso comienza con la introducción de los reactivos gaseosos (A, D, E) al reactor, estos reaccionan obteniendo los productos como vapor. A esta reacción se añade un catalizador en fase líquida para aumentar la velocidad. Los productos se llevan al condensador y luego al separador líquido-vapor.

Los componentes no condensados se realimentan al reactor de nuevo, para juntarlos con los reactivos A, D y E.

Los componentes condensables se dirigen a una columna de destilación que se alimenta con el reactivo C y permite la eliminación por desorción de la pequeña cantidad de producto que pudiera quedar. El producto de colas será el subproducto F y el inerte B que serán purgados en la corriente de vapor del separador líquido-vapor. Y los productos G y H saldrán de la columna y se separan en una sección de refinación, no incluida en el problema por su poca importancia.



### 3.1. DATOS DE LA PLANTA

El modelo de planta de Tennessee Eastman cuenta con 12 variables manipuladas (XMV) y 41 variables medidas (XMEAS). Del conjunto de variables, las 22 primeras medidas se miden de forma continua y las otras 19 se obtienen de los analizadores distribuidos a lo largo de la planta que realizan mediciones periódicamente. Están representadas en las tablas

Las 12 variables manipuladas ofrecen 12 grados de libertad, estos corresponden a las 9 válvulas de flujo, 2 válvulas de control de temperatura y una velocidad de agitación. Estas variables están recogidas en la tabla 1 y la tabla 2.

En esta planta se han provocado distintas anomalías, distribuidas a lo largo del proceso, que se presentan en la tabla 3.

Numero de Variable	Descripción Variable	Unidades
XMV(1)	Flujo de alimentación D	Kgh <sup>-1</sup>
XMV(2)	Flujo de alimentación E	Kgh <sup>-1</sup>
XMV(3)	Flujo de alimentación A	kscmh
XMV(4)	Flujo de alimentación A y C	Kscmh
XMV(5)	Válvula de recirculación del compresor	%
XMV(6)	Válvula de carga	%
XMV(7)	Flujo de líquido del separador LV	m <sup>3</sup> h <sup>-1</sup>
XMV(8)	Flujo de líquido de la columna stripping	m <sup>3</sup> h <sup>-1</sup>
XMV(9)	Válvula de vapor de la columna de stripping	%
XMV(10)	Flujo de agua de refrigeración del reactor	m <sup>3</sup> h <sup>-1</sup>
XMV(11)	Flujo de agua en el condensador	m <sup>3</sup> h <sup>-1</sup>
XMV(12)	Velocidad del agitador del reactor	rpm

*Tabla 1 Variables manipuladas del proceso*



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

Numero de Variable	Descripción Variable	Unidades
XMEAS(1)	Flujo de alimentación A	kscmh
XMEAS(2)	Flujo de alimentación D	Kscmh
XMEAS(3)	Flujo de alimentación E	kscmh
XMEAS(4)	Flujo de alimentación A y C	kscmh
XMEAS(5)	Flujo de recirculación	kscmh
XMEAS(6)	Flujo de alimentación al reactor	kscmh
XMEAS(7)	Presión del reactor	kPa
XMEAS(8)	Nivel del reactor	%
XMEAS(9)	Temperatura del reactor	°C
XMEAS(10)	Flujo de purga	kscmh
XMEAS(11)	Temperatura del separador	°C
XMEAS(12)	Nivel del separador	%
XMEAS(13)	Presión del separador	kPa
XMEAS(14)	Corriente del separador	m <sup>3</sup> h <sup>-1</sup>
XMEAS(15)	Nivel de destilador (stripper)	%
XMEAS(16)	Presión del destilador (stripper)	kPa
XMEAS(17)	Corriente del destilador (stripper)	m <sup>3</sup> h <sup>-1</sup>
XMEAS(18)	Temperatura del destilador (stripper)	°C
XMEAS(19)	Flujo de vapor del destilador (stripper)	Kgh <sup>-1</sup>
XMEAS(20)	Potencia de compresor	kW
XMEAS(21)	Temperatura de la salida del agua se refrigeración del reactor	°C
XMEAS(22)	Temperatura de la salida del agua de refrigeración del separador	°C
XMEAS(23-28)	Concentración de la alimentación del reactor	% mol
XMEAS(29-36)	Concentración de la purga	% mol
XMEAS(37-41)	Concentración aguas abajo del destilador	% mol

Tabla 2 Variables medidas del proceso



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

Fallo	Descripción Variable	Unidades
IDV(1)	Relación de flujo de alimentaciones A/C, composición de B constante	Escalón
IDV(2)	Composición de B con relación A/C constante	Escalón
IDV(3)	Temperatura de alimentación D	Escalón
IDV(4)	Temperatura de entrada del agua del refrigerante del reactor	Escalón
IDV(5)	Temperatura de entrada del agua del refrigerante del condensador	Escalón
IDV(6)	Pérdida de alimentación de A	Escalón
IDV(7)	Pérdida de presión en la corriente C	Escalón
IDV(8)	Composición de las alimentaciones A, B y C	Variación aleatoria
IDV(9)	Temperatura de alimentación D	Variación aleatoria
IDV(10)	Temperatura de alimentación C	Variación aleatoria
IDV(11)	Temperatura de entrada del agua del refrigerante del reactor	Variación aleatoria
IDV(12)	Temperatura de entrada del agua del refrigerante del condensador	Variación aleatoria
IDV(13)	Cinética de las reacciones	Variación lenta
IDV(14)	Válvula del agua refrigerante del reactor	Bloqueo
IDV(15)	Válvula del agua refrigerante del condensador	Bloqueo
IDV(16)	Desconocido	No especificado
IDV(17)	Desconocido	No especificado
IDV(18)	Desconocido	No especificado
IDV(19)	Desconocido	No especificado
IDV(20)	Desconocido	No especificado
IDV(21)	Desconocido	Constante

Tabla 3 Tipos de fallos en el proceso



## DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

En otros estudios se ha probado que los fallos 3, 9 y 15 son más difíciles de detectar, ya que no sufren cambios respecto al comportamiento normal.

En este trabajo se ha trabajado con dos conjuntos de datos, el primer conjunto de datos es una simulación de la planta con 960 observaciones de cada variable, donde el fallo ocurre a partir de la observación número 160.

Los datos del modelo teórico de Tennessee Eastman son públicos y visibles para todo el mundo. Estos pueden ser obtenidos a través del siguiente enlace: <http://web.mit.edu/braatzgroup/links.html>

Para el entrenamiento de las redes neuronales que tienen muchos parámetros a calcular (los AE entran dentro de la denominada deep-learning) es necesario usar muchos más datos de los mostrados en ese link. Dichos datos están formados por 250 simulaciones de la planta TE en condiciones normales de funcionamiento durante 48 horas, de las cuales se han cogido datos de dimensiones (240000, 52) y estos datos se pueden obtener del siguiente enlace:

<https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/6C3JR1>



# CAPITULO IV: TRABAJO REALIZADO



**Universidad de Valladolid**

DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA  
INDUSTRIAL MEDINTE TÉCNICAS DE DEEP-LEARNING Y  
MÉTODOS DE CLUSTERING



**ESCUELA DE INGENIERÍAS  
INDUSTRIALES**



## 4.1. METODOLOGIA UTILIZADA

Para la realización de este trabajo, se usarán los datos de simulación descargados de la planta Tennessee Eastman para detectar y analizar fallos mediante las técnicas explicadas en el Capítulo II.

Para el desarrollo, se trabaja con 22 simulaciones. La primera simulación corresponden a los datos de entrenamiento, estos datos representan la planta con comportamiento normal con 240.000 observaciones de cada una de las 52 variables, este conjunto de datos también servirán para testear el algoritmo desarrollado y 21 simulaciones restantes correspondientes a cada una de las diferentes anomalías que se pueden producir, descritas en la tabla 3.3., en estas simulaciones el fallo ocurre a partir de la observación 160.

Con relación a los datos simulados, los fallos IDV(3), IDV(9), ambos correspondientes a la temperatura de alimentación D e IDV(15), relacionado con la válvula del agua refrigerante del condensador han sido excluidos del análisis. Estas anomalías son difíciles de clasificar y analizar por su alta similitud al comportamiento normal de la planta.

Se trabajará con el lenguaje de programación de Python y el uso de la librería Keras de TensorFlow para el desarrollo de los Autoencoders. Primero, se realizará el Análisis de Componentes Principales (PCA) y la detección y análisis de los fallos. Se compararán estos resultados con los obtenidos mediante los distintos métodos desarrollados, Autoencoder (AE), Denoising Autoencoders (DAE) y K-nearest neighbors (K-NN).

## 4.2. DETECCION DE FALLOS MEDIANTE ANALISIS DE COMPONENTES PRINCIPALES (PCA)

La primera técnica que vamos a aplicar para detectar los fallos en el sistema es PCA. Se realizan los cálculos de reducción de dimensionalidad y se calculan los estadísticos  $T^2$  y  $Q$  y sus correspondientes umbrales descritos anteriormente en el Capítulo II.

A continuación, por medio de las simulaciones de anomalías de la planta se realiza la detección de fallos en la planta.



#### 4.2.1. ANALISIS COMPORTAMIENTO NORMAL

Se inicia con la carga de los datos correspondientes al comportamiento normal y su almacenaje en una matriz  $X$  de dimensión  $960 \times 52$ . Este espacio muestral se debe reducir a un espacio  $\mathcal{R}^{960 \times a}$ , a correspondiente al número de componentes principales. Para ello, la matriz  $X$  se normaliza a media cero y varianza uno con el objetivo de dar la misma importancia a todos los datos. Se calcula la matriz de correlación  $R$  y luego se extraen los valores singulares, obteniendo la matriz  $\Lambda$ , cuya diagonal está compuesta de los valores propios en orden decreciente y la matriz  $V$ , compuesta de los vectores propios correspondientes a los valores anteriores. En este trabajo, se ha establecido una variabilidad límite del 90%, con el uso de un test de porcentaje de varianza calculamos las componentes principales. Una variabilidad no superior del 90% equivale a 31 componentes principales.

Conociendo el número de componentes principales que se usarán, se construye la matriz  $P \in \mathcal{R}^{52 \times 31}$ , compuesta por los vectores de carga correspondientes a los valores singulares mayores. La matriz  $P$  nos permite proyectar el espacio a una proyección reducida llamada  $T$ , cuya dimensión es  $\mathcal{R}^{960 \times 31}$ . Con el espacio reducido calculado, recalculamos la matriz de partida (ecuación 4). Y esta permitirá el cálculo de la matriz de residuos  $E$  (ecuación 5)

Por último, se calculan los estadísticos  $T^2$  y  $Q$ , que nos permitirán visualizar las anomalías del proceso si hubiera. Se comienza con el cálculo de  $T^2$  para cada vector de observación de dimensiones  $1 \times 52$  se aplica la ecuación 7, obtenemos una matriz de dimensiones  $1 \times 960$ , lo cual equivaldría a un valor estadístico de  $T^2$  para cada observación. Esto nos permite calcular el umbral, el cual en este trabajo se ha establecido en el percentil 99. Representada gráficamente con una línea de color rojo.

Representando cada uno de los valores del estadístico  $T^2$  como puntos de color azul y su umbral (Figura 12), confirmamos que el umbral no se supera a excepción de alguna ocasión puntual. Corroborando que los cálculos son correctos.

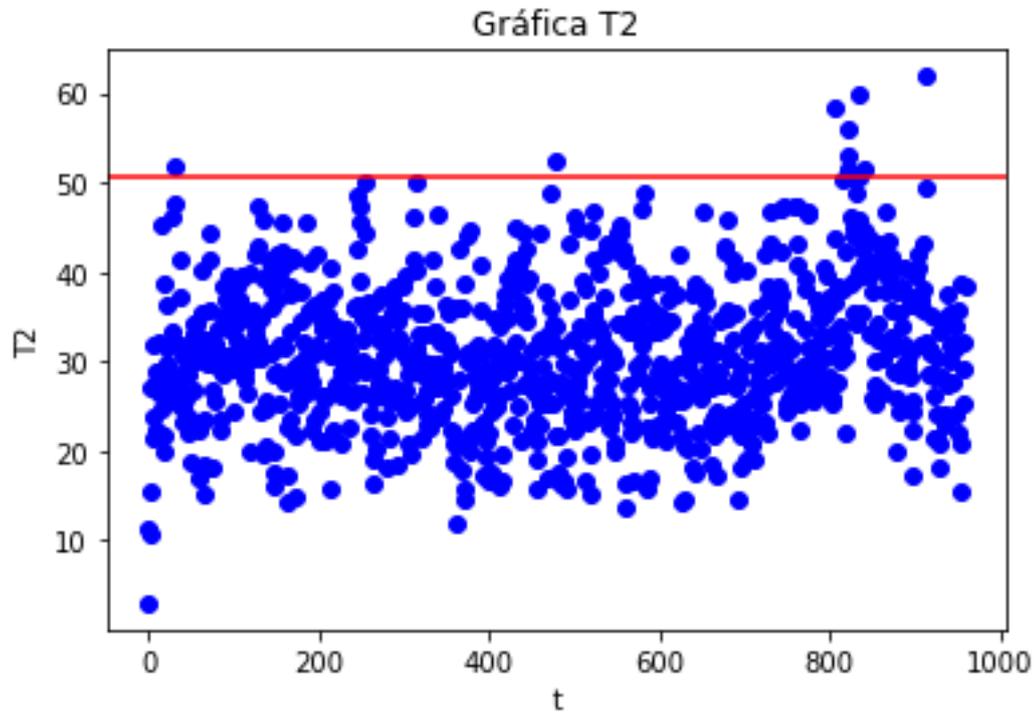


Ilustración 12 Estadístico  $T^2$  en comportamiento normal

Ahora calculamos el estadístico  $Q$ , con la matriz de residuos  $E$ , calculada anteriormente, de similar forma al apartado anterior. Por cada vector de observaciones  $1 \times 52$ , aplicamos la ecuación (10), obteniendo la matriz  $Q$  de dimensiones  $1 \times 960$  (Figura 13). Su umbral también se establece en el percentil 99.

Representamos sus valores y comprobamos que al igual que en el estadístico  $T^2$  el funcionamiento es el correcto.

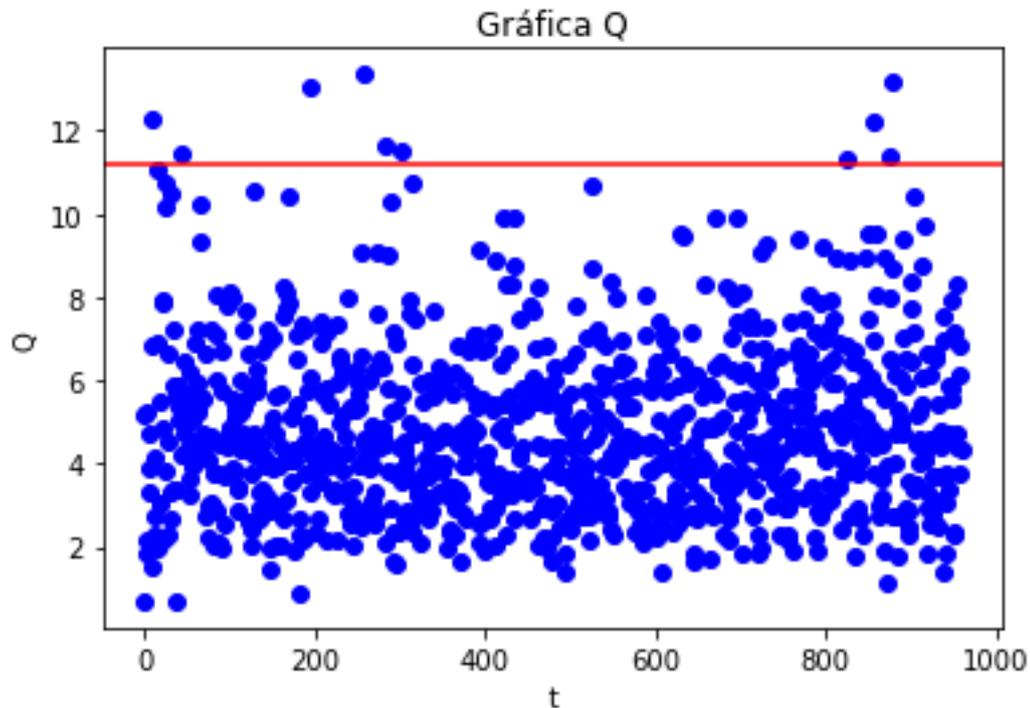


Ilustración 13 Estadístico Q en comportamiento normal

#### 4.2.2. ANALISIS DETECCION DE FALLOS

Con los datos de PCA calculados, se procede a la monitorización del proceso y detección de posibles fallos que pueden ocurrir en el sistema. Haciendo uso de las 21 simulaciones que contienen datos de las anomalías. Al igual que en los cálculos con comportamiento normal, comenzamos normalizando la matriz  $X$  de dimensiones  $960 \times 52$  con media cero y varianza uno.

Calculamos los estadísticos  $T^2$  y  $Q$  de la misma forma que en el caso de comportamiento normal y se compraran con sus umbrales correspondientes. Se considera que ocurre un fallo cuando el umbral es rebasado, pero con el fin de evitar falsas alarmas, consideramos que realmente ocurre un fallo cuando el límite sea sobrepasado 10 veces sucesivamente. También, vamos a tener en cuenta distintos parámetros. El tiempo de detección, que nos señala el número de observación desde que ocurre el fallo (160) hasta que es detectado por el método, el porcentaje de alarmas detectadas, que indica el porcentaje de datos que una vez producido el fallo supera el umbral y el porcentaje de falsas alarmas, que señala el porcentaje de datos que supera el umbral antes de que se produzca el fallo.

A continuación, se han simulado todas las situaciones de fallos. Solo se van a mostrar los gráficos de los estadísticos  $T^2$  y  $Q$  para los fallos 2,3 y 18, debido que son muchas simulaciones. Al final, se expone una tabla que agrupa todos los datos de los diferentes parámetros calculados, anteriormente mencionados.

En la figura 14, observamos los estadísticos  $T^2$  y  $Q$  del fallo 2 “Composición de B con relación A/C constante”. Se observa que para ambos estadísticos las 160 primeras observaciones corresponden al funcionamiento en comportamiento normal, sin sobrepasar el umbral. Las siguientes observaciones se advierten muy por encima del umbral, lo que significa que el fallo ha sido detectado.

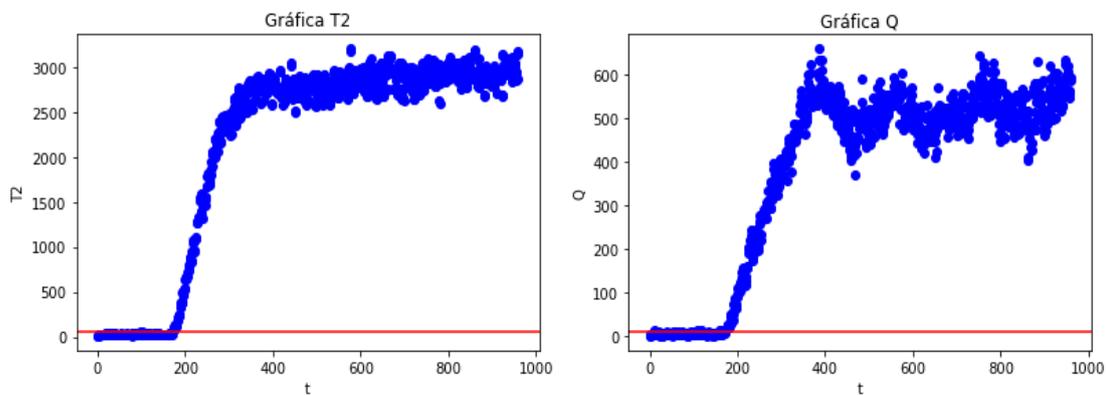


Ilustración 14 Gráficos estadísticos del fallo 2

En la tabla 4, se indica que el tiempo de detección en los estadísticos es de 170 y 173 respectivamente, por lo que se puede concluir que es un fallo detectado rápidamente. El porcentaje de falsas alarmas es bajo, lo que significa que las alarmas se han producido antes de la detección del fallo son pocas. Y por último, el porcentaje de alarmas detectadas es superior al 98% en ambos estadísticos, considerándose que se han detectado de forma correcta.

$T^2$			$Q$		
TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)	TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
170	1.875	98.625	173	2.5	98.5

Tabla 4 Datos calculados del fallo 2

La siguiente simulación es del fallo 18 “Desconocido”, representamos ambos estadísticos (Figura 15) donde comprobamos que detecta el fallo de forma correcta.

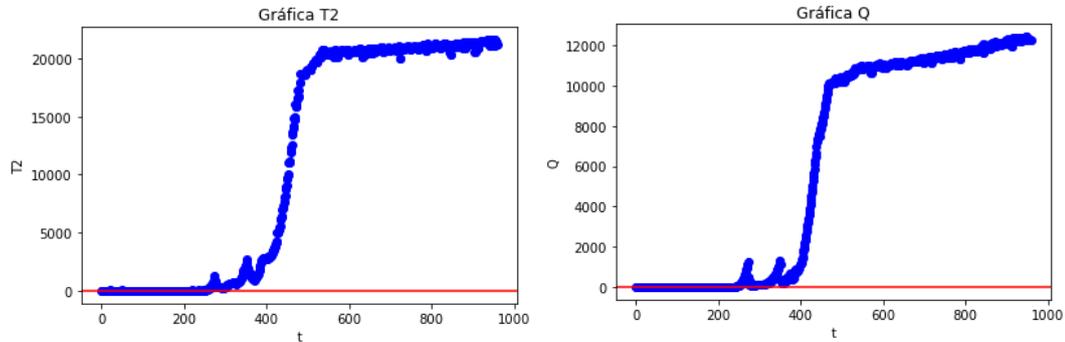


Ilustración 15 Gráficos estadísticos del fallo 18

En esta simulación, como se muestra en la tabla 5, el fallo no es detectado hasta la observación 251 en el estadístico  $T^2$  y hasta la observación 242 en el estadístico  $Q$ .

$T^2$			$Q$		
TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)	TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
251	1.25	89.375	242	2.5	90.125

Tabla 5 Datos calculados del fallo 18

Por último, vamos a representar los gráficos correspondientes al fallo 3” Temperatura de alimentación D”. Este fallo, como ya se ha comentado antes, es difícil de detectar debido a su similitud al comportamiento normal, esto se puede comprobar ya que los gráficos para este fallo (Figura 16) son similares a las ilustraciones 12 y 13 correspondientes al comportamiento normal de la planta.

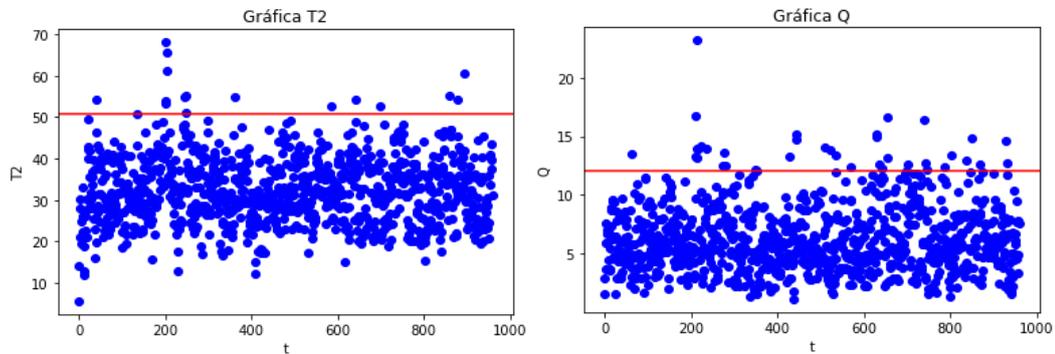


Ilustración 16 Gráficos estadísticos del fallo 3

No se han podido detectar 10 alarmas seguidas por encima del umbral como muestra la Tabla 6 por lo que este fallo no es detectado por ninguna de las estadísticas.

T <sup>2</sup>			Q		
TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)	TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
-	1.25	1.875	-	0.625	4.75

Tabla 6 Datos calculados del fallo 3

A continuación, se muestra la tabla 7 que contiene un resumen de los datos calculados de las 21 simulaciones de fallos mediante el estadístico T<sup>2</sup> y la tabla 8 de los datos calculados mediante el estadístico Q.

En las tablas se ve que la estadística Q detecta mejor los fallos y más rápidamente que la estadística T<sup>2</sup>. Además, se ve como hay fallos que son fáciles de detectar por ambas estadísticas, como los fallos 1,2,6,7,8,12,14 que se detectan muy rápidamente y con un porcentaje de detección elevado de más del 98%, llegando incluso alguno de ellos al 100% de detección. Sin embargo, otros fallos son difíciles de detectar como los fallos 3,9 y 15 ya comentados, pero también los fallos 4, 10 o 16 con un porcentaje muy bajo de alarmas detectadas en ambas estadísticas o incluso el fallo 19 que tampoco es detectado por ninguna de las estadísticas.



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDINTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

		T <sup>2</sup>	
	TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	165	1,25	99,25
IDV(2)	170	1,875	98,625
IDV(3)	-	1,25	1,875
IDV(4)	663	0,625	41,875
IDV(5)	169	0,625	25,75
IDV(6)	168	0,625	98,875
IDV(7)	160	0	100
IDV(8)	181	0	97,25
IDV(9)	-	3,125	3,375
IDV(10)	262	1,875	30,75
IDV(11)	209	0	51,25
IDV(12)	180	1,25	98,75
IDV(13)	204	1,875	94,625
IDV(14)	160	0,625	99,5
IDV(15)	-	1,25	2,5
IDV(16)	469	3,75	15,125
IDV(17)	187	0,625	78,625
IDV(18)	251	1,25	89,375
IDV(19)	-	0,625	12,25
IDV(20)	245	2,5	31,25
IDV(21)	663	1,25	41,375
<b>MEDIA</b>	<b>265</b>	<b>1,25</b>	<b>57,73</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>265</b>	<b>1,15</b>	<b>66,92</b>

Tabla 7 Datos del PCA, estadística T<sup>2</sup>



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDINTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

	TIEMPO DETECCION	Q	
		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	161	1,25	99,75
IDV(2)	173	2,5	98,5
IDV(3)	-	0,625	4,75
IDV(4)	160	1,875	100
IDV(5)	160	1,875	30,75
IDV(6)	160	1,25	100
IDV(7)	160	0,625	100
IDV(8)	176	3,75	96,75
IDV(9)	-	2,5	2,875
IDV(10)	206	0	40,25
IDV(11)	165	4,375	66,625
IDV(12)	181	4,375	94,5
IDV(13)	199	1,25	95,125
IDV(14)	160	1,875	99,875
IDV(15)	-	1,25	3,625
IDV(16)	353	1,875	39,625
IDV(17)	180	1,875	95,375
IDV(18)	242	2,5	90,125
IDV(19)	-	3,125	15,75
IDV(20)	243	2,5	53
IDV(21)	659	2,5	47,875
<b>MEDIA</b>	<b>220</b>	<b>2,08</b>	<b>65,78</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>220</b>	<b>2,19</b>	<b>77</b>

Tabla 8 Datos del PCA, estadística Q



## 4.3 DETECCION DE FALLOS MEDIANTE TECNICAS DE APRENDIZAJE AUTOMATICO

Para la detección de fallos vamos a utilizar métodos de aprendizaje automático explicadas en el capítulo II, estas técnicas buscan mejorar los resultados obtenidos con PCA. Utilizaremos un autoencoder de 5 capas ocultas, 7 contando la entrada y la salida, siendo simétrica su estructura, utilizando para detectar los fallos ambas técnicas las estadísticas  $T^2$  y  $Q$ , y las obtenidas con los k-vecinos más próximos,  $D_h^2$  y  $D_r^2$ . Después realizaremos de nuevo la detección con un Denoising Autoencoder.

### 4.3.1. REDES NEURONALES. AUTOENCODER.

Cogemos en este caso una simulación de comportamiento normal del proceso formado por 250 simulaciones diferentes de dicho comportamiento y con dimensión (240000x52) como comentamos anteriormente, para tener suficientes datos y entrenar este AE, una técnica de deep-learning. Comenzamos normalizando por columnas la matriz de entrada a media cero y varianza uno.

El Autoencoder que vamos a crear tiene los siguientes datos:

- Numero de iteraciones o épocas: 600
- Tamaño de batch: 64
- Optimizador: Adam
- Función de perdida: Mean Square Error

Después de probar con varias estructuras para la red neuronal, número de capas ocultas, número de neuronas en cada capa, etc., la red que mejor resultado obtuvo es la siguiente. La estructura del Autoencoder está formada por una primera y quinta capa de 34 neuronas, la segunda y cuarta de 30 neuronas y la capa central será de 22 neuronas. Por lo que formar una estructura final 52-34-30-22-30-34-52.

La función de activación que se va a usar es la sigmoide. Y el 20% de los datos serán usados para validar los resultados. Con el Autoencoder desarrollado, se comienza el entrenamiento, para su posterior detección de fallos.

La detección de fallos se realizará con dos métodos distintos para así poder comprobar si mejora uno respecto el otro, la primera, será con el uso de los estadísticos  $T^2$  y  $Q$  y la segunda, con el uso del método K-NN

### DETECCION FALLOS MEDIANTE $T^2$ y $Q$

Con el Autoencoder desarrollado, calculamos los umbrales de  $T^2$  y  $Q$  con los nuevos datos obtenidos por el entrenamiento. Definimos de nuevo la variable  $h$  de la ecuación 17, pero en este caso como el conjunto de datos calculados en el encoder, la capa con menos neuronas de la red. Para el cálculo de la variable  $r$ , usada en la ecuación 18, se usarán los datos proporcionados por el autoencoder menos los datos de entrada sin alterar. Con estas variables se calculan los estadísticos  $T^2$  y  $Q$ , y proporcionan un gráfico de control, para cada uno.

Al igual que en el apartado de PCA, vamos a analizar en detalle los fallos 2 y 18. En la figura 17 y en la Tabla 9, correspondiente a la simulación de la anomalía 2, se observa la detección del fallo en la observación 173 en el estadístico  $T^2$  y en la observación 169 para el estadístico  $Q$ . Las falsas alarmas son bajas y el porcentaje de alarmas detectadas es bastante alta.

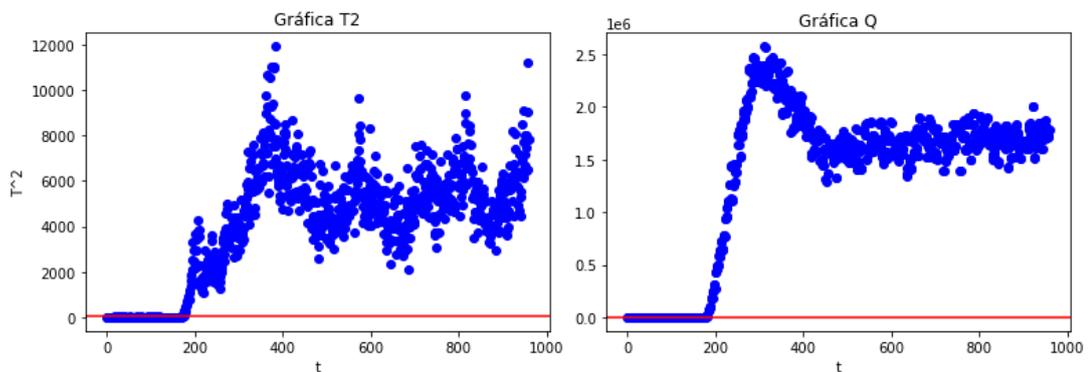


Ilustración 17 Gráfica  $T^2$  y  $Q$  de AE para el fallo 2

TIEMPO DETECCION	$T^2$		TIEMPO DETECCION	$Q$	
	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
173	0	98,5	169	1,25	98,75

Tabla 9 Datos calculados AE: Fallo 2

En la figura 18 y en la Tabla 10, correspondiente al fallo 18, se observa una detección tardía del fallo en ambos estadísticos, exactamente en la observación 257 y 243. Las falsas alarmas son nulas.

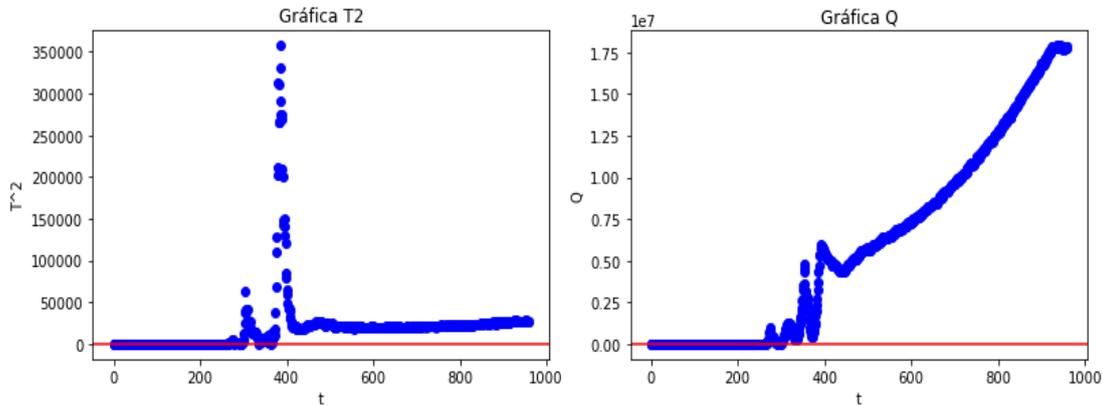


Ilustración 18 Gráfica T2 y Q de AE: fallo 18

TIEMPO DETECCION	T <sup>2</sup>		TIEMPO DETECCION	Q	
	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
257	0	88,125	243	0	89,625

Tabla 10 Datos calculados AE: Fallo 18

A continuación, se presentan dos tablas resumen para cada estadístico con los datos obtenidos (Tablas 11 y 12). Se puede observar una reducción de las falsas alarmas con respecto a PCA. Y un aumento en el porcentaje de detección de alarmas. Cabe resaltar que el estadístico T<sup>2</sup> ha detectado menos fallos, el fallo 4 “Temperatura de entrada del agua del refrigerante del reactor”, el fallo 11 “Temperatura de entrada del agua del refrigerante del reactor” y el fallo 19 “Desconocido” no se han conseguido detectar.

En cambio, el estadístico Q, los únicos fallos que no ha conseguido detectar son el 3, 9 y 15, que ya comentamos que eran muy complicados debido a su comportamiento similar al normal. La diferencia entre la detección de fallo entre un estadístico y otro puede atribuirse a el uso de la capa oculta por parte de T<sup>2</sup>.



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

	TIEMPO DETECCION	T <sup>2</sup>	
		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	167	0,625	99
IDV(2)	173	0	98,5
IDV(3)	-	1,25	0,75
IDV(4)	-	0	1,75
IDV(5)	173	0	20,875
IDV(6)	170	0	98,625
IDV(7)	160	0	100
IDV(8)	185	0	96,375
IDV(9)	-	1,25	1,625
IDV(10)	255	0	28,25
IDV(11)	-	0	14,125
IDV(12)	182	0	97,375
IDV(13)	219	0,625	93,125
IDV(14)	190	0,625	76,5
IDV(15)	-	0,625	1,125
IDV(16)	469	3,75	13
IDV(17)	189	0	66,5
IDV(18)	257	0	88,125
IDV(19)	-	0	2,125
IDV(20)	248	0	21,625
IDV(21)	715	0,625	29,875
<b>MEDIA</b>	<b>250</b>	<b>0,45</b>	<b>49,96</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>250</b>	<b>0,35</b>	<b>58,1</b>

Tabla 11 Datos del AE, estadística T<sup>2</sup>



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

	TIEMPO DETECCION	Q	
		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	163	0,625	99,5
IDV(2)	169	1,25	98,75
IDV(3)	-	0	1,25
IDV(4)	618	0	43,375
IDV(5)	160	0	100
IDV(6)	160	0,625	100
IDV(7)	160	0	100
IDV(8)	180	0	97,375
IDV(9)	-	0	0,375
IDV(10)	185	0	74
IDV(11)	254	0	44,875
IDV(12)	161	0,625	99,75
IDV(13)	203	0,625	94,5
IDV(14)	160	0	99,875
IDV(15)	-	0	3
IDV(16)	169	1,875	72,75
IDV(17)	183	0,625	85,,5
IDV(18)	243	0	89,625
IDV(19)	331	0	62,375
IDV(20)	230	1,25	72,25
IDV(21)	711	0,625	33,625
<b>MEDIA</b>	<b>247</b>	<b>0,39</b>	<b>66,06</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>247</b>	<b>0,45</b>	<b>76,81</b>

Tabla 12 Datos del AE, estadística Q



Comparando con el PCA, el estadístico  $T^2$  no consigue mejores resultados en cuanto a detección, solo detecta 15 fallos, un 71.4%, 2 fallos menos de los que detectaba el PCA. En cambio el estadístico Q sí que presenta una mejoría, consigue detectar el fallo 19, aunque tarda más en el tiempo de detección con el resto de fallos, con una media de 247 observaciones, el fallo 4 presenta un tiempo de detección de 618 observaciones mucho mayor que el obtenido con PCA de 160 observaciones. Y el porcentaje de falsas alarmas ha bajado en ambas estadísticos, consiguiendo un valor menor de 0.5%.

### DETECCION DE FALLOS POR K-NN

Una vez entrenado el AE con la matriz de datos iniciales de dimensiones 24000x52, debido al gran número de observaciones, reducimos la matriz a dimensiones 500x52, para reducir el uso de la memoria para calcular las distancias entre las muestras y los k vecinos más próximos. Normalizamos la matriz X con media cero y varianza uno para que todos los datos aporten el mismo valor. Introducimos la matriz en el Autoencoder, para obtener la variable h, correspondiente a los datos de la capa oculta y r, correspondiente a la diferencia de los datos de entrada al Autoencoder y los datos iniciales de la matriz X. En este trabajo se ha elegido k=5, es decir, las 5 medidas más cercanas.

A continuación, se calcula la matriz distancia para la variable h por cada fila, con la distancia euclidiana, con respecto a todas las muestras, obteniendo una matriz de dimensiones 500x500. Para la correcta aplicación del método K-NN, seleccionamos las 5 distancias más pequeñas, consiguiendo una matriz  $D_h \in \mathcal{R}^{500 \times 5}$ , con estos valores calculamos la media cuadrática por cada fila. Obteniendo un espacio reducido  $D_h \in \mathcal{R}^{500 \times 1}$ . De esta forma, podemos obtener el umbral  $D_h$ , correspondiente al percentil 99 en nuestro caso. Al visualizar el gráfico de control de  $D_h$  (Figura 19), observando que para observación se representa un valor y el umbral está representado en color rojo.

Para la variable r, se hace de igual forma. Obteniendo una matriz  $D_r \in \mathcal{R}^{500 \times 1}$ , de donde obtendremos, el umbral  $D_r$ . En el gráfico de control (Figura 20), comprobamos que el umbral de color rojo, no es superado más que en unas pocas ocasiones, por lo que los cálculos realizados en ambos estadísticos son correctos

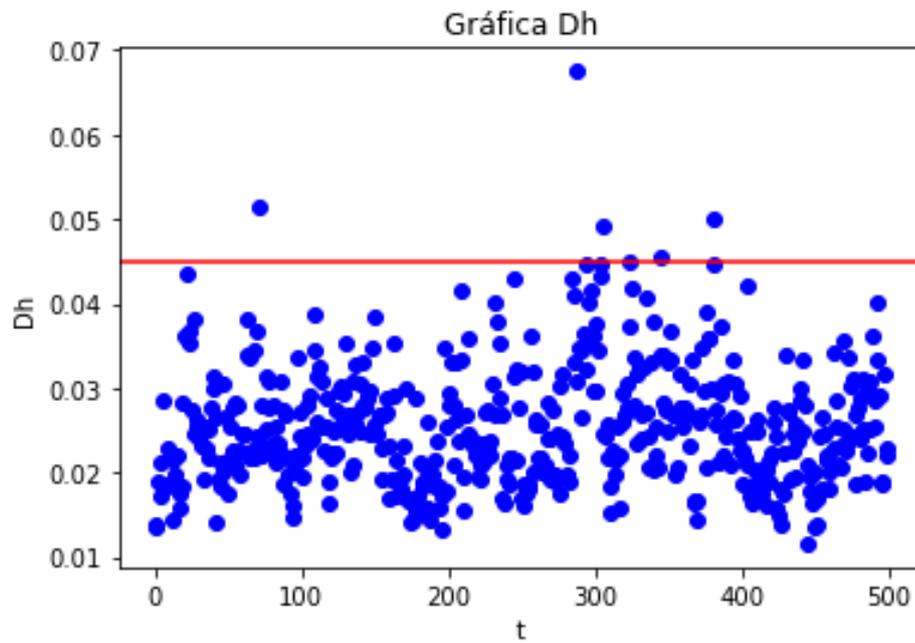


Ilustración 19 Dh en comportamiento normal

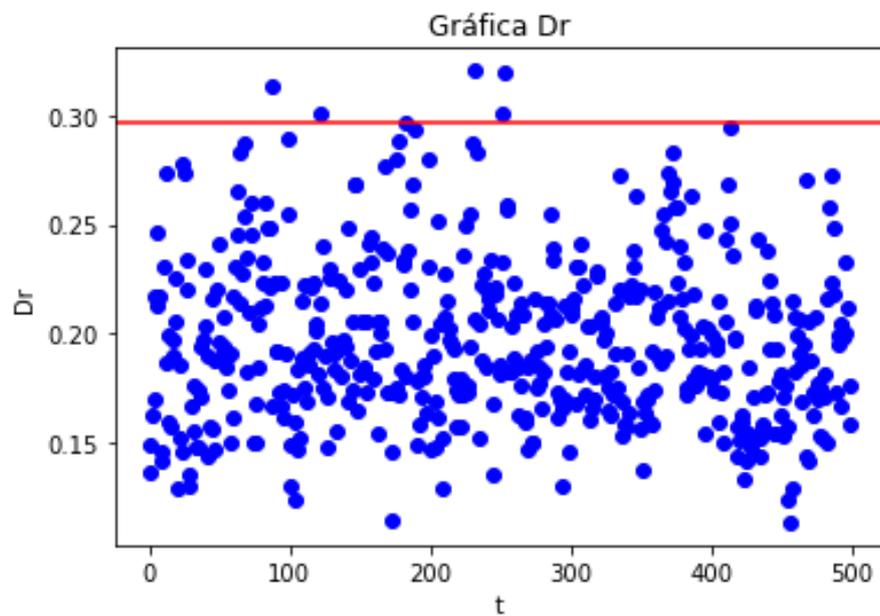


Ilustración 20 Dr en comportamiento normal

Con los parámetros definidos y el modelo entrenado, procedemos al análisis de los gráficos de las simulaciones de los fallos 2 y 18.

En la figura 21 y en la Tabla 13, se ve la detección del fallo 2 “Composición de B con relación A/C constante” mediante el método K-NN. Se puede ver, como la detección se produce en la observación 169 para Dh, 9 observaciones después de que se produzca el fallo y en la observación 173 para Dr, 13 observaciones después de que se produzca el fallo, por lo que la detección es rápida. El porcentaje de alarmas detectadas es alto, lo que quiere decir que las alarmas han sido detectadas de forma correcta.

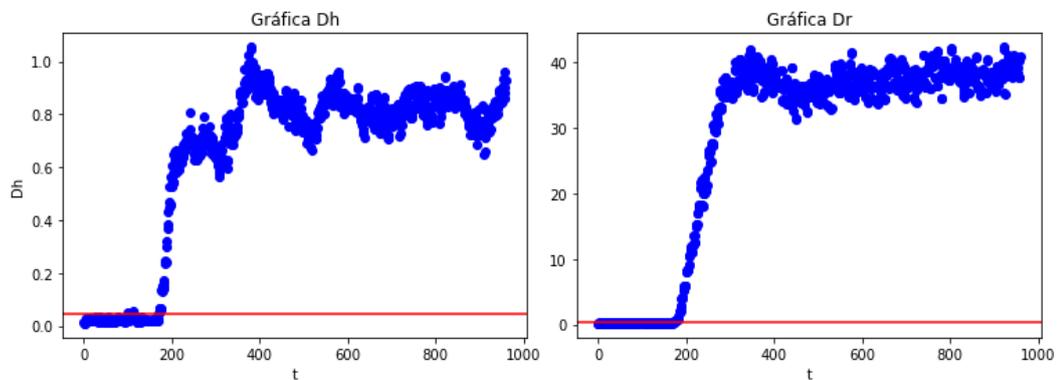


Ilustración 21 Gráficas estadísticas del fallo 2

TIEMPO DETECCION	Dh		TIEMPO DETECCION	Dr	
	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
169	1.25	98.75	173	1.25	98.25

Tabla 13 Datos calculados K-NN Fallo 2

Podemos ver en la figura 22 y en la tabla 14, la detección del fallo 18, al igual que en los otros métodos el tiempo de detección es más tardío, en la observación 257 y 242, respectivamente.

Los datos obtenidos son similares al apartado anterior.

Dh			Dr		
TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)	TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
257	0.625	88.125	242	1.875	90

Tabla 14 Datos calculados K-NN Fallo 18

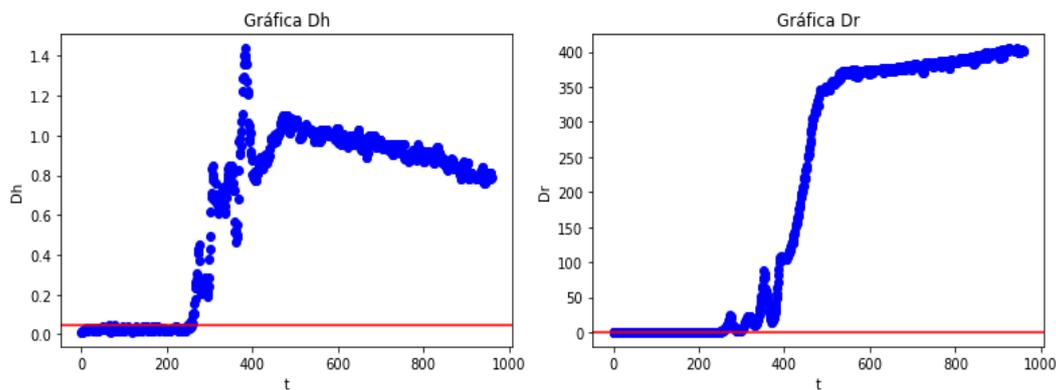


Ilustración 22 Graficas estadísticas del fallo 18

A continuación, se presentan las tablas 15 y 16, con los datos calculados para Dh y Dr. En esta podemos observar que en Dh no se detectan los fallos 3, 4, 9, 15 y 19. Y en Dr, los fallos no detectados son 3,9, 15 y 19, este estadístico consigue un tiempo de detección muy bajo, ya que en los fallos 4, 5, 6, 7 y 17 detecta el fallo nada más producirse. Las falsas alarmas son bajas, por lo que solo una minoría ha superado el umbral establecido, con excepción del fallo 16 que presenta un porcentaje del 8.125% en el estadístico Dh.

En comparación con el PCA, el estadístico Dh no detecta el fallo 4, que mediante PCA si era posible detectarlo y ha aumentado el tiempo de detección. El estadístico Dr presenta resultados similares a los obtenidos por el estadístico Q y a pesar de que detecte un fallo menos, los tiempos de detección en ambos estadísticos son iguales a los conseguidos por PCA.



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDINTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

	TIEMPO DETECCION	Dh	
		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	166	0,625	99,125
IDV(2)	169	1,25	98,75
IDV(3)	-	0	2
IDV(4)	-	0,625	6
IDV(5)	173	0,625	22,875
IDV(6)	170	0	98,625
IDV(7)	160	0,625	100
IDV(8)	185	0,625	96,5
IDV(9)	-	1,25	1,375
IDV(10)	250	0	31,75
IDV(11)	537	0,625	22,875
IDV(12)	181	0,625	97,75
IDV(13)	214	0,625	93,625
IDV(14)	190	0	81,25
IDV(15)	-	0,625	2,875
IDV(16)	469	8,125	14,875
IDV(17)	188	1,25	72,375
IDV(18)	257	0,625	88,125
IDV(19)	-	1,25	4
IDV(20)	255	0,625	20
IDV(21)	714	3,125	32,875
<b>MEDIA</b>	<b>267</b>	<b>1,1</b>	<b>51,79</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>267</b>	<b>1,18</b>	<b>60,08</b>

Tabla 15 Datos calculados Dh AE



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

	TIEMPO DETECCION	Dr	
		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	161	0,625	99,75
IDV(2)	173	1,25	98,25
IDV(3)	-	0,625	3
IDV(4)	160	3,125	100
IDV(5)	160	3,125	32,125
IDV(6)	160	1,875	100
IDV(7)	160	1,875	100
IDV(8)	178	0	97,75
IDV(9)	-	3,125	3,25
IDV(10)	255	1,875	36,5
IDV(11)	164	2,5	75,125
IDV(12)	165	2,5	98,375
IDV(13)	195	1,875	95,5
IDV(14)	160	1,25	100
IDV(15)	-	1,25	2,5
IDV(16)	354	1,875	31,75
IDV(17)	182	0,625	72,375
IDV(18)	242	1,875	90
IDV(19)	-	1,875	15,125
IDV(20)	243	1,25	50,125
IDV(21)	643	2,5	44,5
<b>MEDIA</b>	<b>221</b>	<b>1,76</b>	<b>64,10</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>221</b>	<b>1,77</b>	<b>74,29</b>

Tabla 16 Datos calculados Dr AE



### 4.3.2 DENOISING AUTOENCODER

La estructura será igual que para el Autoencoder.

Comenzamos normalizando por columnas la matriz de entrada a media cero y varianza uno. Para este tipo de Autoencoder debemos tener una matriz de entrada con ruido, por lo que añadimos un 30% de ruido. Esta matriz se usará para entrenar los datos. De esta forma, conseguimos un Autoencoder más robusto y eficaz para eliminar ruido.

El Autoencoder que vamos a crear tiene los siguientes datos:

- Numero de iteraciones o épocas: 600
- Tamaño de batch: 64
- Optimizador: Adam
- Función de pérdida: Mean Square Error

La estructura del Autoencoder está formada por una primera y quinta capa de 34 neuronas, la segunda y cuarta de 30 neuronas y la capa central será de 22 neuronas. Por lo que formará una estructura final 52-34-30-22-30-34-52.

La función de activación que se va a usar es la sigmoide. Y el 20% de los datos serán usados para validar los resultados.

Con el Denoising Autoencoder desarrollado y entrenado. Procedemos a la detección de fallos. Para ello igual que en el apartado anterior usaremos los estadísticos  $T^2$  y  $Q$  y el método K-NN.

#### **ESTADÍSTICO $T^2$ y $Q$**

Calculamos los umbrales de  $T^2$  y  $Q$  con los nuevos datos obtenidos por el entrenamiento. Definimos de nuevo la variable  $h$  de la ecuación 17, pero en este caso como el conjunto de datos calculados en el encoder, la capa con menos neuronas de la red. Para el cálculo de la variable  $r$ , usada en la ecuación 18, se usarán los datos proporcionados por el autoencoder menos los datos de entrada sin alterar. Con estas variables se calculan los estadísticos  $T^2$  y  $Q$ , y proporcionan un gráfico de control, para cada uno.

Analizamos los fallos 2 y 18 y compararemos los resultados a los obtenidos por PCA y por Autoencoder.

Los gráficos del fallo 2 (Figura 23), muestran la detección del fallo en la observación 170 en ambos estadísticos.

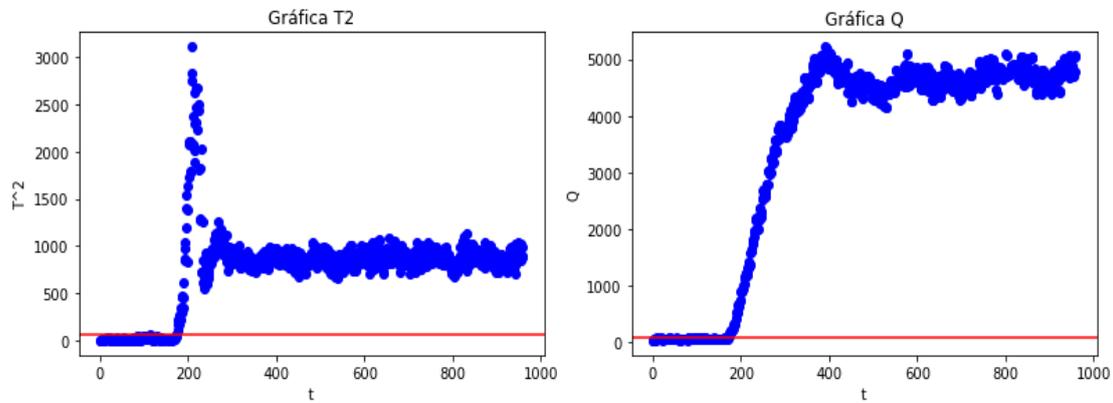


Ilustración 23 Gráficas estadísticas del fallo 2

Como se observa en la tabla 17, se detectan una alta tasa de alarmas producidas, el 98% de las alarmas. Y el porcentaje de falsas alarmas es nulo, por lo que no se ha producido ninguna.

TIEMPO DETECCION	T <sup>2</sup>		TIEMPO DETECCION	Q	
	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
173	0	98,25	170	0	98,5

Tabla 17 Datos calculados del fallo 2

En la ilustración, perteneciente al fallo 18 (Figura 24), la detección del fallo no se produce hasta la observación 253 en el estadístico T<sup>2</sup> y hasta la observación 241 en el estadístico Q.

Los datos obtenidos como se ve en la Tabla 18 son similares que los obtenidos por Autoencoder, no tienen una variación notable.

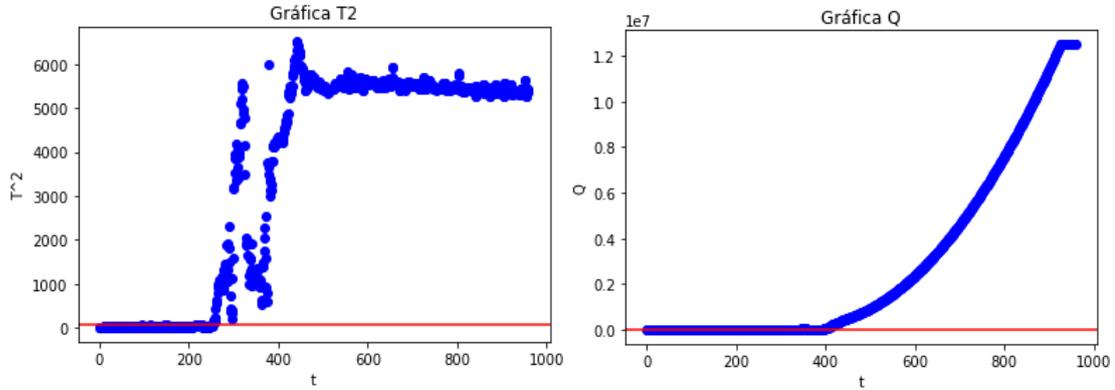


Ilustración 24 Graficas estadísticas del fallo 18

T <sup>2</sup>			Q		
TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)	TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
253	0.625	88,25	241	0.625	90,25

Tabla 18 Datos calculados del fallo 18

A continuación, se presentan las tablas 19 y 20, con los datos calculados para los estadísticos T<sup>2</sup> y Q. Podemos observar que el estadístico T<sup>2</sup> no detecta los fallos 3 “Temperatura de alimentación D”, 4 “Temperatura de entrada del agua del refrigerante del reactor”, 9 “Temperatura de alimentación D”, 11 “Temperatura de entrada del agua del refrigerante del reactor”, 15 “Válvula del agua refrigerante del condensador” y 19 “Desconocido”. En cambio, el estadístico Q únicamente no ha detectado los fallos 3, 9 y 15. Esta diferencia se debe a que los datos que usa el estadístico T<sup>2</sup> son las características de la capa oculta.



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

	TIEMPO DETECCION	T <sup>2</sup>	
		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	166	0	99,125
IDV(2)	175	0	98
IDV(3)	-	0	0,125
IDV(4)	-	0,625	1,875
IDV(5)	173	0,625	21,5
IDV(6)	167	0	99
IDV(7)	160	0	97,625
IDV(8)	186	0	94,875
IDV(9)	-	0	0,125
IDV(10)	229	0	31,125
IDV(11)	-	1,25	14,25
IDV(12)	181	0	95,625
IDV(13)	215	0	92,125
IDV(14)	483	0	74,375
IDV(15)	-	0	2,125
IDV(16)	471	3,125	13,875
IDV(17)	189	0	67,375
IDV(18)	253	0	88,25
IDV(19)	-	0	0,5
IDV(20)	245	0	23
IDV(21)	880	0	14,625
<b>MEDIA</b>	<b>278</b>	<b>0,27</b>	<b>49,02</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>278</b>	<b>0,31</b>	<b>57,06</b>

Tabla 19 Datos calculados T2 DAE



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

	TIEMPO DETECCION	Q	
		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	161	1,25	99,75
IDV(2)	171	0	98,5
IDV(3)	-	2,5	1,25
IDV(4)	160	0,625	100
IDV(5)	160	0,625	100
IDV(6)	160	0	100
IDV(7)	160	0	100
IDV(8)	176	0	98
IDV(9)	-	1,25	1,5
IDV(10)	180	0	85,375
IDV(11)	164	0	74,25
IDV(12)	160	0,625	99,875
IDV(13)	195	0	95,5
IDV(14)	160	0	100
IDV(15)	-	0,625	2,75
IDV(16)	167	1,875	88,375
IDV(17)	180	0	95,875
IDV(18)	241	0,625	90,25
IDV(19)	168	0	88,75
IDV(20)	225	1,25	90,625
IDV(21)	641	2,5	45,125
<b>MEDIA</b>	<b>201</b>	<b>0,65</b>	<b>78,85</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>201</b>	<b>0,52</b>	<b>91,68</b>

Tabla 20 Datos calculados Q DAE



El estadístico  $T^2$  empeora con respecto a PCA, no solo detecta menos fallos, sino que el tiempo de detección es mayor, pero consigue disminuir el porcentaje de falsas alarmas.

Por otro lado, el estadístico Q presenta una gran mejora, el fallo 19 "Desconocido" es ahora detectado, el tiempo de detección ha disminuido al igual que el porcentaje de falsas alarmas. Y presenta un alto porcentaje de alarmas detectadas.

La comparativa entre el AE y el DAE de los estadísticos  $T^2$  y Q, muestran que el estadístico  $T^2$  presenta malos resultados en ambos casos, esto pueden deberse al uso de datos obtenidos de la capa oculta. El estadístico Q presenta mejores resultados en el DAE, tanto un menor tiempo de detección como un alto porcentaje de alarmas detectadas.

### **DETECCION DE FALLOS POR K-NN**

La matriz de entrada de dimensión  $500 \times 52$ , esta ha sido reducida de la matriz inicial formada por 240000 observaciones, para usar menos memoria. Normalizamos la matriz X con media cero y varianza uno para que todos los datos aporten el mismo valor. Introducimos la matriz en el Autoencoder, para obtener la variable h, correspondiente a los datos de la capa oculta y r, correspondiente a la diferencia de los datos de entrada al Autoencoder y los datos iniciales de la matriz X. En este trabajo, como ya se había comentado antes, se ha elegido  $k=5$ , es decir, las 5 medidas más cercanas.

A continuación, se calcula la matriz distancia para la variable h por cada fila, con la distancia euclidiana, con respecto a todas sus muestras, obteniendo una matriz de dimensiones  $500 \times 500$ . Para la correcta aplicación del método K-NN, seleccionamos las 5 distancias más pequeñas, consiguiendo una matriz  $D_h \in \mathcal{R}^{500 \times 5}$ , con estos valores calculamos la media cuadrática por cada fila. Obteniendo un espacio reducido  $D_h \in \mathcal{R}^{500 \times 1}$ . De esta forma, podemos obtener el umbral  $D_h$ , correspondiente al percentil 99 en nuestro caso.

En la ilustración 25 y en la Tabla 21, correspondientes al fallo 2 "Composición de B con relación A/C constante". Se observa que para ambos estadísticos las 160 primeras observaciones corresponden al funcionamiento en comportamiento normal, sin sobrepasar el umbral. Las siguientes observaciones se advierten muy por encima del umbral, lo que significa que el fallo ha sido detectado. Este error es detectado rápidamente.

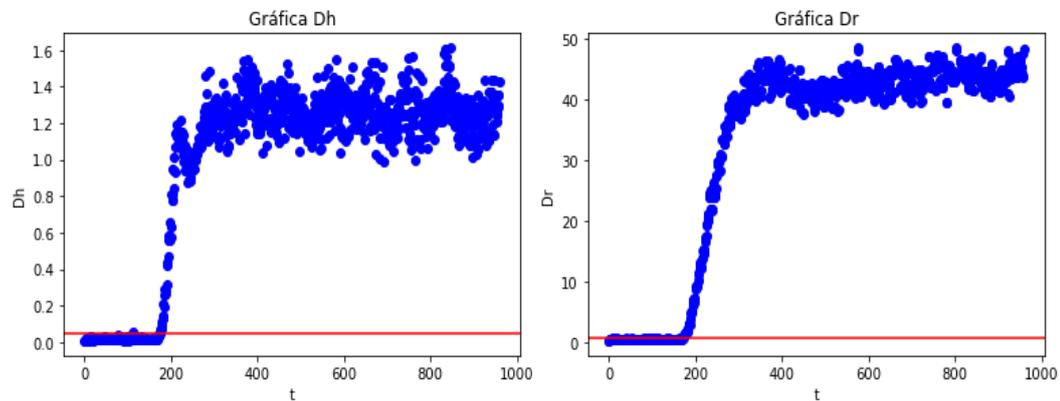


Ilustración 25 Gráficos estadísticos del fallo 2

El fallo es detectado en la observación 174 para el estadístico Dh y en la observación 170 para el estadístico Dr. El porcentaje de alarmas detectadas es alto y el porcentaje de alarmas es bajo.

Dh			Dr		
TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)	TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
174	0.625	98.125	170	1.875	98.625

Tabla 21 Datos calculados para el fallo 2

En la figura 26 y en la tabla 22, correspondientes al fallo 18 “Desconocido”, la detección de fallo es tardía en ambos estadísticos, exactamente en la observación 253 y 242. El porcentaje de falsas alarmas es bajo.

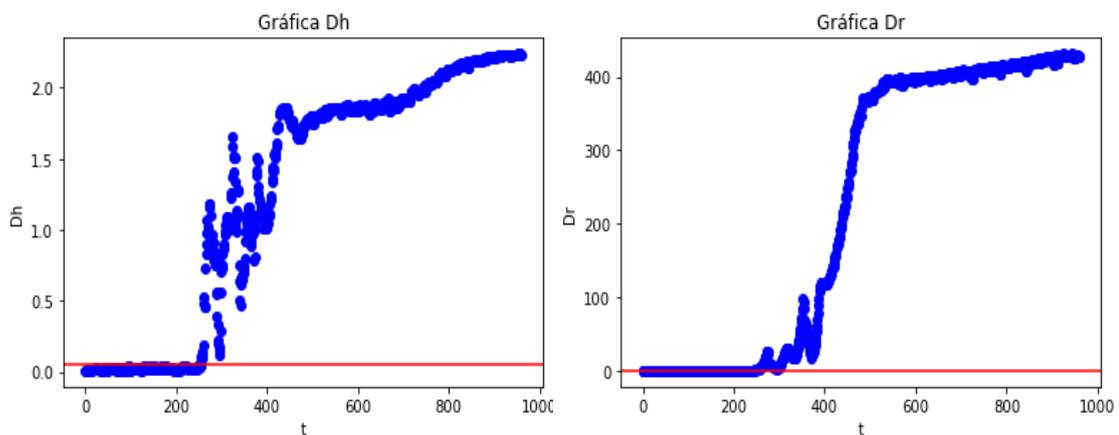


Ilustración 26 Gráficos estadísticos del fallo 18



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



TIEMPO DETECCION	Dh		TIEMPO DETECCION	Dr	
	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
253	0	88.375	242	2.5	89.875

Tabla 22 Datos calculados para el fallo 18

A continuación, se muestran las tablas 23 y 24 resumen de los datos calculados para ambos estadísticos.

En comparación con el PCA, el método K-NN con Denoising Autoencoder ha mejorado los resultados, el estadístico Dh consigue detectar el fallo 15 “Válvula del agua de refrigerante del condensador”, detectando 18 fallos, uno más que el estadístico T<sup>2</sup>, el tiempo de detección mejora en todos los fallos al igual que el porcentaje de alarmas detectadas. Aunque el fallo 16 “Desconocido” presenta un porcentaje de falsas alarmas del 20.625%, este porcentaje tan alto ocurrió también en este fallo en el Autoencoder con método K-NN.

El estadístico Dr obtiene una ligera mejoría respecto al estadístico Q, el tiempo de detección disminuye, el porcentaje de falsas alarmas también, y presenta una mejoría del porcentaje de alarmas detectadas.

Estos resultados son mejores que los obtenidos por el método K-NN con Autoencoder. La entrada con ruido del DAE provoca que sea mejor para eliminar el ruido y represente las características más importantes, obteniendo unos datos más precisos.



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

		Dh	
	TIEMPO DETECCION	FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	165	1,25	99,25
IDV(2)	174	0,625	98,125
IDV(3)	175	0	5,75
IDV(4)	-	0,625	6,75
IDV(5)	173	0,625	25,875
IDV(6)	167	0,625	99
IDV(7)	160	0	71,625
IDV(8)	167	1,25	97,375
IDV(9)	-	5	2,75
IDV(10)	216	0	40,75
IDV(11)	293	0	28,99
IDV(12)	180	1,875	97,25
IDV(13)	215	0	93,75
IDV(14)	190	0,625	80,625
IDV(15)	834	0	8
IDV(16)	126	20,625	24,75
IDV(17)	188	0,625	74
IDV(18)	253	0	88,375
IDV(19)	-	0	1,375
IDV(20)	245	0	34,375
IDV(21)	723	0,625	27,75
<b>MEDIA</b>	<b>258</b>	<b>1,64</b>	<b>52,69</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>258</b>	<b>1,63</b>	<b>60,56</b>

Tabla 23 Datos calculados Dh DAE



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDINTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

	TIEMPO DETECCION	Dr	
		FALSAS ALARMAS (%)	ALARMAS DETECTADAS (%)
IDV(1)	162	1,875	99,625
IDV(2)	170	1,875	98,625
IDV(3)	-	1,25	2,75
IDV(4)	160	1,875	97,875
IDV(5)	160	1,875	27,75
IDV(6)	160	0	100
IDV(7)	160	0,625	100
IDV(8)	178	0,625	97,875
IDV(9)	-	2,5	2,75
IDV(10)	208	1,25	43,5
IDV(11)	169	0	71,875
IDV(12)	165	0	99
IDV(13)	195	1,25	95,5
IDV(14)	160	0,625	100
IDV(15)	-	1,25	4,625
IDV(16)	355	4,375	31,875
IDV(17)	182	0	91,875
IDV(18)	242	2,5	89,875
IDV(19)	-	0,625	17,625
IDV(20)	245	0	49,375
IDV(21)	659	1,875	44,5
<b>MEDIA</b>	<b>219</b>	<b>1,25</b>	<b>65,09</b>
<b>MEDIA SIN FALLOS 3,9 Y 15</b>	<b>219</b>	<b>1,18</b>	<b>75,38</b>

Tabla 24 Datos calculados Dr DAE



## 4.4 COMPARACION DE RESULTADOS

En este último apartado, se contrastarán los datos obtenidos por los métodos, con el objetivo de conocer cuál es el método que mejor detecta fallos. En las tablas 25 y 26, se presentan los valores medios de los métodos y los valores medios sin los fallos 3, 9 y 15.

TABLA RESUMEN					
	PCA T <sup>2</sup>	AE T <sup>2</sup>	AE Dh	DAE T <sup>2</sup>	DAE Dh
<b>TIEMPO DE DETECCION</b>	265	250	267	278	258
<b>FALSAS ALARMAS (%)</b>	1,25	0,45	1,1	0,27	1,64
<b>FALSAS ALARMAS (%) SIN FALLO 3,9 Y 15</b>	1,15	0,35	1,18	0,31	1,63
<b>ALARMAS DETECTADAS (%)</b>	57,73	49,96	51,79	49,02	52,69
<b>ALARMAS DETECTADAS (%) SIN FALLO 3,9 Y 15</b>	66,92	58,1	60,08	57,06	60,56

*Tabla 25 Tabla resumen datos medios*

Como se observa en la tabla 25, el porcentaje de alarmas detectadas no ha mejorado respecto a PCA. Por otro lado, el porcentaje de falsas alarmas da mejores resultados con el AE con el método K-NN y con el estadístico T<sup>2</sup> y con DAE con el estadístico T<sup>2</sup>, estos últimos consiguiendo un porcentaje menos del 0,5%.

El método más rápido en detectar fallos el AE con el estadístico T<sup>2</sup> con un tiempo de detección de 250 observaciones, el segundo más rápido sería el DAE con método K-NN con 258 observaciones.



DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y MÉTODOS DE CLUSTERING



Universidad de Valladolid

ESCUELA DE INGENIERÍAS INDUSTRIALES

TABLA RESUMEN					
	PCA Q	AE Q	AE Dr	DAE Q	DAE Dr
TIEMPO DE DETECCION	220	247	221	201	219
FALSAS ALARMAS (%)	2,08	0,39	1,76	0,65	1,25
FALSAS ALARMAS (%) SIN FALLO 3,9 Y 15	2,19	0,45	1,77	0,52	1,18
ALARMAS DETECTADAS (%)	65,78	66,06	64,1	78,85	65,09
ALARMAS DETECTADAS (%) SIN FALLO 3,9 Y 15	75,77	76,81	74,29	91,88	75,38

Tabla 26 Tabla resumen datos medios

En la tabla 26 se observa que los mejores resultados de alarmas detectadas sería el DAE con el estadístico Q con un 78,85% y si eliminamos los fallos 3,9y 15 este porcentaje aumenta hasta una 91,88%. El segundo mejor método en detectar sería AE con el estadístico Q con un 66,06%, seguido de cerca con el método PCA.

El porcentaje de falsas alarmas se ha reducido en todos los métodos, consiguiendo mejores resultados respecto a PCA.

Por último, el menor tiempo de detección lo ha conseguido el método DAE con el estadístico Q.



# CAPITULO V: CONCLUSIONES



**Universidad de Valladolid**

DETECCION DE FALLOS/ANOMALÍAS EN UNA PLANTA  
INDUSTRIAL MEDIANTE TÉCNICAS DE DEEP-LEARNING Y  
MÉTODOS DE CLUSTERING



**ESCUELA DE INGENIERÍAS  
INDUSTRIALES**



## 5.1 CONCLUSIONES

El objetivo de este trabajo es el desarrollo de diferentes técnicas de detección de fallos en una planta industrial basados en datos y comparar sus resultados para buscar una mejora. Se valorará especialmente el porcentaje de alarmas detectadas y el tiempo de detección.

Se comienza con el desarrollo del Análisis de Componentes Principales (PCA). Con esta técnica los fallos 3, 9, 15 y 19 se quedan sin detectar en ambos estadísticos, es decir, 17 de los 21 fallos son detectados, esto equivale a un 81% de los fallos. El porcentaje medio de falsas alarmas en el estadístico  $T^2$  y en el estadístico Q es 1,25 y 2,08 respectivamente. Y un porcentaje de alarmas detectadas de 57,73% y 66,92%.

Luego, se desarrollan el Autoencoder y el Denoising Autoencoder, en cada uno vamos a usar dos estadísticos distintos, los estadísticos  $T^2$  y Q y los estadísticos calculados por el método K-NN.

El mejor método para la detección de fallos ha resultado ser el DAE con el estadístico Q presenta un buen tiempo de detección con 201 observaciones de media y un porcentaje de detección de alarmas de 78,85%, llegando a alcanzar 91,88% si eliminamos los datos de los fallos 3,9 y 15. El porcentaje de falsas alarmas es de 0,65% uno de los más bajos.

El segundo mejor método para detectar fallos es el AE con el estadístico Q, con un 66,06% de alarmas detectadas. Presenta un 0,39% de falsas alarmas, el segundo porcentaje más bajo entre todos los métodos.

El método que peor resultados ha dado es el Denoising Autoencoder con el estadístico  $T^2$ , el estadístico solo detecta 15 fallos de 21, con un tiempo de detección de 278 observaciones, el más alto de los métodos. Y un porcentaje de alarmas detectadas de 49,02%. A pesar de los malos resultados en estas áreas, el porcentaje de falsas alarmas es de 0,27%, el más bajo.

Como conclusión final del TFG realizado, el mejor método para detección de fallos es el DAE con estadístico Q, este alcanza un porcentaje de detección de alarmas muy alto y las falsas alarmas que se producen son muy bajas. El estadístico Q ha conseguido obtener buenos datos con otros métodos y el uso de redes neuronales ha conseguido reducir las falsas alarmas de manera significativa. El método PCA sigue siendo un método que consigue buenos resultados.



## 5.2 TRABAJO FUTURO

En un futuro para mejorar los resultados de este trabajo, sería realizar la detección de fallos con autoencoders variando el número de neuronas presente en cada capa, variar la función de procesamiento de las neuronas, usando ReLU, etc. O variar las funciones usadas para entrenar la red neuronal.

Otra posibilidad es usar otro tipo de autoencoders, como los autoencoders que tienen en cuenta la dinámica del sistema: autoencoders recurrentes (RAE), o autoencoders que mejoran la capa latente del sistema (la salida  $h$  del encoder), donde se le obliga a obtener una distribución de probabilidad determinada, este tipo de autoencoders se llaman autoencoders variacionales (VAE), o mezclar ambos obteniendo autoencoders recurrentes variacionales (RVAE)

Otra posible trabajo futuro, sería utilizar otro tipo de estructuras de deep-learning, como las redes convolucionales.



# BIBLIOGRAFÍA

- [1] Mitra, A. (2021). Fundamentals of quality control and improvement (5th ed.). Wiley.
- [2] Jimenez Villares, P. (2007), “Metodologías y herramientas para la gestión por procesos. Aplicación a un caso del servicio andaluz de salud”. Proyecto Fin de Carrera defendido en la Escuela Técnica Superior de Ingeniería, Universidad de Sevilla <https://biblus.us.es/bibing/proyectos/abreproy/4252/> [Último acceso: 25 de Noviembre]
- [3] <https://blog.hubspot.es/sales/diagrama-ishikawa> [Ultimo acceso: 14 de Diciembre]
- [4] Carro, R. y González Gómez, D. A. (2012). Control estadístico de procesos. *Universidad Nacional de Mar del Plata, Argentina*, pp:5-7
- [5] Hernández Pedrera, C., & Da Silva Portofilipe, F.. (2016). Aplicación del control estadístico de procesos (CEP) en el control de su calidad. *Tecnología Química*, 36(1), 104-116  
[http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S2224-61852016000100010&lng=es&tlng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S2224-61852016000100010&lng=es&tlng=es) [Ultimo acceso: 29 de Noviembre]
- [6] Fuente, M.J., & García-Alvarez, D., (2011), “Estudio comparativo de técnicas de detección de fallos basadas en el Análisis de Componentes Principales (PCA)”. *Revista Iberoamericana de Automática e Informática industrial*, Vol.8, pp:182–195.  
<https://www.elsevier.es/index.php?p=revista&pRevista=pdfsimple&pii=S1697791211000070&r=331> [Ultimo acceso: 18 de Noviembre]
- [7] Matich, D. J. (2001). Redes Neuronales: Conceptos básicos y aplicaciones. *Universidad Tecnológica Nacional, México*, 41, 12-16.
- [8] Fernández Fernández, J.M. & Flórez López, R. (2008) Las redes neuronales artificiales, La Coreña, España: NetBiblio.
- [9] Singh, Y., & Chauhan, A. S. (2009). Neural Networks in Data Mining. *Journal of Theoretical & Applied Information Technology*, Vol. 5(1).
- [10] Elena Gómez, A. (2022). Detección y diagnóstico de fallos mediante técnicas basadas en datos aplicadas a un colector de aguas. TFG, EII, Universidad de Valladolid



- [11] Wang, Z. & Li, K. & Xia, S. & Liu, H. (2021). Economic Recession Prediction Using Deep Neural Network. Michtom School of Computer Science, United States  
[https://www.researchgate.net/publication/353450665\\_Economic\\_Recession\\_Prediction\\_Using\\_Deep\\_Neural\\_Network](https://www.researchgate.net/publication/353450665_Economic_Recession_Prediction_Using_Deep_Neural_Network) [Ultimo acceso: 13 de Diciembre]
- [12] <https://www.ibm.com/es-es/topics/overfitting> [Ultimo acceso: 14 de Noviembre]
- [13] Cambroner, C. G., & Moreno, I. G. (2006). Algoritmos de aprendizaje: knn & kmeans. *Inteligencia en Redes de Comunicación, Universidad Carlos III de Madrid*, 23.
- [14] <https://www.ibm.com/mx-es/topics/knn> [Ultimo acceso: 6 de Diciembre]
- [15] Zhang, Z. & Jiang, T. & Li, S. & Yang, Y. (2018), “Automated feature learning for nonlinear process monitoring – An approach using stacked denoising autoencoder and k-nearest neighbor rule”. *Journal of Process Control* , Vol 64, pp:49-61.
- [16] Downs, J.J. & Vogel, E.F (1993), “A plant-wide industrial process control Problem”, *Computer Chemical Engineering*, Vol 17, pp: 245-255.
- [17] Álvarez Toro, L.A. & Sotomayor, O. (2018) “Integración Optimización-Control predictivo y aplicación a la planta Tennessee Eastman”, *Rev. Per. Quím. ing. Quím.* vol. 11 n.º 1.