

Estudio comparativo de técnicas de detección de fallos basadas en el Análisis de Componentes Principales (PCA)

D. Garcia-Alvarez*, M.J. Fuente

Departamento de Ingeniería de Sistemas y Automática, EII, Universidad de Valladolid, C/ Doctor Mergelina S/N, 47005, Valladolid

Resumen

Este artículo describe y compara diferentes variantes de la detección de fallos mediante el análisis de componentes principales (PCA). PCA es una técnica estadística multivariante. Se describe como se puede diseñar un sistema de detección de fallos mediante PCA y los estadísticos que se pueden calcular para construir los gráficos de control que permiten monitorizar el estado del proceso. Los distintos métodos basados en PCA que se comparan en este artículo son: PCA adaptativo (APCA), PCA multi-escala (MSPCA), PCA pesado exponencialmente (EWPCA), PCA con análisis externo (PCA EA) con su variante no lineal y PCA no lineal NLPCA. Para el estudio comparativo se van a valorar diferentes parámetros, tanto cualitativos como cuantitativos. *Copyright © 2011 CEA.*

Palabras Clave:

Métodos estadísticos/análisis de señales para Detección y Diagnóstico de Fallos, Monitorización de Procesos/control estadístico de procesos.

1. Introducción

Las técnicas modernas de control han resuelto un gran número de problemas, sin embargo la aparición de una causa especial en un proceso puede provocar que éste deje de operar bajo control. Estas causas especiales, en muchos casos, son fallos en los componentes que conforman el sistema. En Blanke et al. (2003) se define un fallo como *una desviación de la estructura o de los parámetros del sistema de su situación nominal*. Algunos de estos fallos pueden deberse a bloqueos en tuberías, bias en sensores, degradación de catalizadores, cambios extremos en concentraciones o variaciones bruscas en la temperatura ambiente, entre otras muchas. La aparición repentina de estos fallos hace necesario un paso más en la automatización de los procesos diseñando e implementado métodos automáticos de detección y diagnóstico de fallos.

Una familia de técnicas utilizadas para la monitorización y detección de fallos en procesos se basa en el control estadístico de procesos (SPC). Los resultados que se obtienen con estos métodos univariados no son muy satisfactorios, ya que, cuando se produce un fallo, varios de estos gráficos lo detectan de manera simultánea, siendo complejo poder detectar la causa del fallo. Esto se debe a que, en general, las variables de un sis-

tema controlado suelen estar correlacionadas y una causa especial puede afectar a más de una variable a la vez. El control estadístico multivariante (MSPC) utiliza, en muchos de sus planteamientos, variables latentes del proceso en lugar de cada una de las variables del proceso. Las técnicas que comprende el MSPC son capaces de calcular modelos empíricos que describen la tendencia del sistema a partir de datos históricos del proceso.

Las técnicas estadísticas multivariantes y particularmente el análisis de componentes principales (PCA) han sido investigadas y estudiadas por diversos autores desde el punto de vista del control estadístico de procesos (Jackson and Mudholkar (1979), Wold (1987), Kourtí and MacGregor (1996), Shlens (2005)). El PCA reduce la dimensionalidad de un espacio original que se establece a partir de los datos históricos de las variables medidas del proceso mediante su proyección en un espacio de menor dimensionalidad. El PCA busca combinaciones lineales de las variables que mejor describen la tendencia del proceso. Matemáticamente, el PCA se basa en una descomposición de la matriz de covarianza de las variables del proceso a lo largo de las direcciones que mejor explican la principales causas de variabilidad de la información analizada.

El análisis de componentes principales ha sido estudiado desde dos perspectivas, una es el citado control estadístico multivariante de procesos (MSPC), y la otra es la detección y diagnóstico de fallos (FDI), esta perspectiva es abordada por Venkatasubramanian et al. (2003a,b,c). El autor divide las técni-

* Autor en correspondencia

Correos electrónicos: dieggar@cta.uva.es (D. Garcia-Alvarez),
maria@autom.uva.es (M.J. Fuente)

cas de detección y diagnosis de fallos en tres: métodos basados en modelos cuantitativos, modelos cualitativos y métodos basados en datos históricos del proceso. PCA entra dentro de la tercera categoría ya que usa datos históricos del proceso para construir un modelo estadístico: el modelo PCA.

El objetivo general de los métodos de detección y diagnosis de fallos es asegurar el éxito de las operaciones detectando estos fallos de forma automática. Esto permitirá a los operadores de la planta y al personal de mantenimiento estar mejor informados del estado del proceso, y además servirá de soporte para la toma de decisiones de cara a restaurar el comportamiento normal del proceso. Para mantener informado a los responsables del proceso se utilizan gráficos de control donde se monitoriza el estado del proceso.

La detección y diagnóstico de fallos puede ser dividida en cuatro fases diferenciadas (Puigjaner et al. (2006)):

1. Detección de la presencia de un fallo a partir de la información extraída de los datos medidos del proceso.
2. Identificación del fallo: identificar las variables más relevantes para diagnosticarlo.
3. Diagnóstico del fallo: módulo que someta las características y los fallos producidos en la planta a un proceso de clasificación con el fin de determinar el tipo de fallo, la localización del mismo, el tamaño del fallo y la causa que lo produjo.
4. La última etapa será la recuperación del proceso, es decir, eliminar el efecto del fallo.

Este artículo presenta y compara diferentes métodos basados en PCA. Sólo se evaluarán las características de estos métodos de cara a la detección, es decir, el artículo se centrará en la primera de las fases que persigue la detección y diagnóstico de fallos. Los métodos proponen diversas variantes para tratar de paliar las limitaciones que presenta un sistema de detección de fallos basado en el análisis de componentes principales. Algunas de las principales limitaciones son: la aparición de numerosas falsas alarmas, la imposibilidad de detectar dos fallos consecutivos o que los cambios en los puntos de operación sean detectados como falsas alarmas e incluso como fallos.

Los métodos presentados en este artículo son: APCA (*Adaptive PCA*) o PCA adaptativo, MSPCA (*Multi-scale principal component analysis*) o PCA multi-escala, EWPCA (*Exponentially Weighted Principal Component Analysis*) o PCA pesado exponencialmente que utiliza una ventana de datos igual que el método MPCA (*Moving PCA*) o PCA con ventana deslizante, PCA con análisis externo que este artículo se denominará como PCAEA (PCA using External Analysis) y por último un método que no se basa en ninguna variante de la detección usando el análisis de componentes principales, si no en el análisis de componentes principales no lineales (NLPCA *Nonlinear PCA*) que se calculan mediante redes neuronales autoasociativas. En Garcia-Alvarez and Fuente (2008) se puede encontrar una comparativa entre EWPCA y DPCA (*Dynamic PCA*) o PCA dinámico (por lo que no se describe en este artículo), y en Tien et al. (2004) otra entre MPCA, APCA y EWPCA.

El artículo primero presentará los fundamentos matemáticos del análisis de componentes principales, así como los estadísticos que se usan para la monitorización del estado del proceso. Después presentará y describirá los distintos métodos. Por último se realizará un estudio comparativo de las diferentes técnicas aplicadas sobre una planta simulada que consiste en un sistema de dos tanques comunicantes con un control de nivel en cada uno de ellos.

2. Análisis de Componentes Principales

El uso del análisis de componentes principales para la monitorización del proceso ha sido estudiada tanto en el plano industrial como en el académico. Y su estudio se debe principalmente a una doble utilidad (Peña, 2002):

1. Permite representar óptimamente en un espacio de dimensión pequeña observaciones de un espacio general p -dimensional. En este sentido, el análisis de componentes principales es el primer paso para identificar las posibles variables latentes, o no observadas que generan los datos.
2. Permite transformar las variables originales, en general correlacionadas, en nuevas variables incorrelacionadas, facilitando la interpretación de los datos.

Si se considera una matriz $X \in \mathfrak{R}^{n \times m}$ que representa las n muestras tomadas de m variables del proceso (MacGregor and Kourti, 1995; Kourti, 2005):

$$X = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{pmatrix} \quad (1)$$

Es conveniente normalizar los datos de cada variable (columnas) con media nula y varianza unitaria para que de cara al cómputo de componentes principales todas las variables tengan el mismo peso, ya que las variables de mayor varianza ejercen más influencia en el modelo.

A partir de esta matriz se puede calcular la matriz de covarianzas R de la siguiente forma:

$$R = \frac{1}{n-1} X^T X \quad (2)$$

Realizando la descomposición de valores singulares (SVD) de R se obtiene:

$$R = \Lambda V^T \quad (3)$$

donde $\Lambda \in \mathfrak{R}^{m \times m}$ es una matriz diagonal que contiene los valores propios reales no negativos en orden decreciente de R ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m \geq 0$) y cuyo valor es: $\lambda_i = \sigma_i^2$. V contiene los vectores propios de R . Si se escogen los vectores propios de los a valores propios más grandes y se almacenan en P , se puede calcular la proyección de los datos de partida en un nuevo espacio de dimensión reducida.

$$T = XP \quad (4)$$

P marca la dirección del nuevo espacio y sus columnas son vectores conocidos como *loadings*. A cada uno de los componentes del nuevo espacio T se les denomina *scores*.

A partir de P y T operando matricialmente se puede volver al espacio de partida de la siguiente forma:

$$\widehat{X} = TP^T \quad (5)$$

Y la diferencia entre X y \widehat{X} es la matriz de residuos E.

$$E = X - \widehat{X} \quad (6)$$

Finalmente se obtiene la expresión

$$X = TP^T + E \quad (7)$$

Donde el conjunto de datos de partida queda expresado por los componentes principales seleccionados y el espacio del ruido.

El primer componente principal, que es una combinación lineal de las variables originales, define la dirección de la mayor variabilidad en el conjunto de datos, y de ahí que tenga la mayor suma de varianzas en la matriz Λ . El segundo componente principal explica la segunda mayor fuente de variación; y así sucesivamente el resto de componentes. En la mayoría de las aplicaciones industriales las mayores fuentes de variabilidad quedan capturadas en unos pocos componentes de mayor variabilidad. Cuanto más correlacionadas estén las variables del proceso menos componentes describirán la variabilidad del proceso. Generalmente los últimos componentes de menor valor representan el ruido del proceso y de los instrumentos por lo que es conveniente rechazarlos.

2.1. Selección del número de componentes principales

Se han sugerido distintas reglas para seleccionar el número de componentes principales (*a*). Se debe seleccionar el número de *loadings* que conformarán la matriz P de transformación y cuales pasarán a formar parte de la matriz de residuos o ruido.

Existen distintos métodos para esta elección, (Jackson, 1991; Chiang et al., 2000; Weighell et al., 2001; Peña, 2002). Un de estos métodos consiste en realizar un gráfico de barras que represente los valores de λ_i $i = 1, 2, \dots, m$ ordenados de mayor a menor y en él buscar un *codo*, es decir, un punto a partir del cual los valores propios son aproximadamente iguales. Otro método consiste en seleccionar el número de componentes hasta cubrir una cota de varianzas (CPV). Se suelen seleccionar valores de CPV de entre el 80 % y el 90 % Peña (2002). Otra opción consiste en despreciar los componentes con valores propios menores que la unidad, si se trabaja con la matriz de correlación el valor medio de los componentes es 1.

Todos estos métodos tienen un planteamiento un tanto heurístico. Una opción bastante extendida (Zarzo, 2004) y aceptada es la validación cruzada, que se basa en la extracción de componentes principales que maximiza la bondad de ajuste y predicción.

Una medida del ajuste del modelo PCA a los datos es la *bondad de ajuste* R_x^2 (por su analogía con el coeficiente R^2 usado en regresión) y que representa la proporción de varianzas de

cada uno de los componentes. El cálculo de R_x^2 da una idea de la importancia de cada uno de los componentes principales de cara a entender el proceso. Pero para determinar el número de componentes principales retenidos éste puede complementarse mediante el cálculo de la *bondad de predicción* Q^2 .

El cálculo de la bondad de predicción se calcula a partir de la suma de cuadrados del error de predicción (*PRESS*). Esta medida se calcula de forma similar a la suma de cuadrados residual con la salvedad de que para cada individuo *i*-ésimo el valor predicho se calcula con el modelo en el cual dicho individuo se ha excluido.

Esta bondad de ajuste por validación cruzada permite determinar cuántas componentes conviene extraer. Se suele considerar que una componente es estadísticamente significativa si $Q_a^2 > 0$.

3. Estadísticos para la monitorización con PCA

Para la monitorización del estado del proceso a partir del análisis de componentes principales se utilizan distintos estadísticos que permiten construir gráficos de control para supervisar el estado del proceso. De esta forma se consigue monitorizar el estado del proceso de forma univariable y ver el umbral de normalidad en una misma gráfica.

Los estadísticos que usan para este fin son:

- **Estadístico de Hotellings (T^2):** Dado un vector de observación del proceso $x \in \mathcal{R}^{m \times 1}$ podemos definir este estadístico de la forma

$$T^2 = x^T P \Lambda_a^{-1} P^T x \quad (8)$$

donde Λ_a contiene las primeras *a* filas y columnas de Λ , siendo *a* el número de componentes principales elegidos.

Este estadístico representa una medida de la variación del proceso, ya que se construye a partir del subespacio de la variación dominante, formado por los *a* primeros autovectores.

Si este estadístico supera un umbral se puede inferir que el proceso está fuera de control, es decir, que se ha producido un fallo. Este umbral se puede calcular fuera de línea a partir de los datos de muestreo de la siguiente forma:

$$T_\alpha^2 = \frac{(n^2 - 1)a}{n(n - a)} F_\alpha(a, n - a) \quad (9)$$

Donde *n* es el número de muestras que se tomaron para el cálculo del PCA y $F_\alpha(a, n - a)$ es el valor crítico de la distribución F (distribución F de Fisher-Snedecor) con *n* y *n - a* grados de libertad y α nivel de significancia, que especificará el grado de compromiso de falsas alarmas. Sus valores más típicos son 0.01 y 0.05.

El estadístico T^2 se basa en los *a* primeros componentes principales, por eso, proporciona una medida de las desviaciones de las variables latentes, que son aquellas que mejor

explican la variabilidad del proceso. De este modo, este estadístico sólo detecta un evento si la variación en las variables latentes es mayor que la variación explicada por las causas comunes, pero pueden existir otro tipo de eventos que producen grandes variaciones en el espacio de ruido desechado para el cálculo de este estadístico. Estos eventos se detectan con el estadístico Q que se explica a continuación.

- **Estadístico Q o SPE:** Este estadístico es conocida con el nombre de error de predicción al cuadrado (SPE).

El estadístico Q puede calcularse a partir de un vector de observación $x \in \mathcal{R}^{m \times 1}$ de la siguiente forma:

$$Q = r^T r \tag{10}$$

con:

$$r = (I - PP^T)x$$

Donde r es el vector de residuos.

Este estadístico indica la diferencia, o residuo, entre el vector de observación actual x y su proyección en el espacio reducido de los a componentes seleccionados.

Al igual que en el caso anterior puede establecerse un umbral para determinar cuando el proceso esta fuera de control. Este umbral se calcula con los datos tomados fuera de línea para el PCA (Chiang et al., 2000):

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

con:

$$\theta_i = \sum_{j=\alpha+1}^m \lambda_j^i \quad h_0 = 1 - \frac{2\theta_1\theta_3}{3\theta_2^2}$$

Donde c_α es el valor de la distribución de probabilidad normal con media 0 y desviación estándar 1. Como en el caso anterior, α es el nivel de significancia.

Cuando el proceso está bajo control, el estadístico Q representa fluctuaciones del ruido. Si ocurriese un evento inusual que afectase a la covarianza de X , se detectaría porque la estadística Q superaría el umbral.

4. Estudio comparativo

Para comparar los distintos métodos se va usar una planta de laboratorio simulada con SIMULINK®, cuyo esquema puede verse en la figura ???. La planta consiste en dos tanques comunicantes con un control de nivel en cada uno de ellos. En Fuente et al. (2008) se puede encontrar una descripción más completa de la planta. El período de muestreo de recogida de datos es de un segundo. Al modelo se le añadió un ruido blanco de media 0 y varianza 0,1.

Los fallos que se van a considerar son:

1. **Fallo en el sensor h_1 :** Este fallo corresponde a un bias en el sensor de nivel del tanque T_1 .

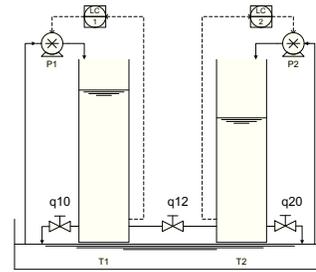


Figura 1: Esquema de la planta piloto.

2. **Fallo en el sensor h_2 :** Este fallo corresponde a un bias en el sensor de nivel del tanque T_2 .
3. **Fallo en la bomba P_1 :** Este fallo corresponde al mal funcionamiento de la bomba P_1 .
4. **Fallo de la bomba P_2 :** Este fallo corresponde al mal funcionamiento de la bomba P_2 .

Todos ellos son fallos aditivos. Para simular estos fallos se añade un porcentaje, que el usuario puede elegir, del valor de la señal del sensor o del actuador.

A cada uno de los métodos considerados se le aplicará tres casos para poder comparar sus capacidades de detección. El primer caso consistirá en detectar un fallo del 20% en el sensor de nivel de tanque 1 en un protocolo sin cambios en la referencias de los tanques para conseguir un estado estacionario lo más estable posible. En el segundo caso se monitorizará una situación con dos fallos consecutivos, el primero un fallo del 20% de en el sensor de nivel del tanque 1 y el segundo un fallo de idénticas características en el sensor de nivel del tanque 2 para el mismo protocolo simple. Y por último, en el tercer caso se monitorizará un protocolo de funcionamiento con diferentes puntos de operación en el que se provocará un fallo de similares características al de la primera prueba. Este protocolo posee diferentes saltos en la referencia de ambos tanques para así conseguir un funcionamiento no-lienal. Para cada una de estos casos se mostrarán los resultados de la monitorización mediante los gráficos de control de los estadísticos T^2 y Q .

En todos los métodos evaluados en este artículo el número de componentes principales obtenido basándose en los diferentes métodos fue de dos.

4.1. Monitorización con PCA

Para implementar un sistema de monitorización con PCA hay que llevar a cabo dos fases: por un lado el análisis previo donde se realiza el análisis de componentes principales, y por otro la monitorización propiamente dicha.

- **Cálculo del PCA (fuera de línea):** Esta fase es previa a la detección de fallos y se realiza fuera de línea.

Una vez que se tienen los datos del proceso en condiciones normales de operación se genera la matriz X y se lleva a cabo el análisis de componentes principales. Previo al análisis es conveniente normalizar los valores de las variables medidas a valores de media 0 y varianza 1.

En esta fase también se calculan los umbrales o límites de operación de los estadísticos.

- **Monitorización del Proceso (en línea):** Una vez que se tienen los datos relativos al PCA se puede realizar la monitorización y detección de fallos del proceso.

Esta fase se realiza en línea con el proceso. Para cada una de las nuevas lecturas que se obtenga del proceso monitorizado se tienen que calcular los estadísticos T^2 y Q . Pevio al cálculo de los estadísticos hay que normalizar el vector de medidas del proceso con la media y la varianza de los datos con los que se realizó el PCA fuera de línea. Si alguna de las estadísticas supera el umbral se notifica una alarma, si el número de alarmas consecutivas supera un número preestablecido se notificará que ha sucedido un fallo.

La figura 2 representa la monitorización de los estadísticos T^2 y Q y como éstos son capaces de detectar el fallo de bias en el sensor de nivel de tanque 1, el fallo es detectado claramente en el instante de su ocurrencia (3000). Se ha utilizado una escala logarítmica para una mejor visualización del progreso de ambas estadísticas. La detección de fallos utilizando un esquema de monitorización basado en PCA se muestra eficiente para sistemas de control donde no hay grandes cambios en el modo de operación. Aparecen diferentes alarmas que debido a su corta duración no pueden ser confundidas con falsos fallos positivos.

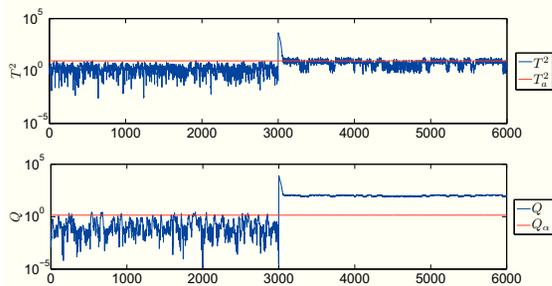


Figura 2: Monitorización de un fallo con PCA.

Si en el proceso monitorizado apareciesen dos fallos diferentes en distintos instantes de tiempo la monitorización con PCA no sería capaz de distinguir el segundo fallo detectado ya que la detección del primero provoca el disparo de los estadísticos T^2 y Q por encima de su umbral. La figura 3 muestra como el primer fallo provocado como un bias del 20 % en el sensor de nivel del tanque 1 es claramente detectado y como el segundo fallo no se distingue debido al disparo de los estadísticos.

Si se quiere monitorizar la misma planta pero con un funcionamiento que recorra diferentes puntos operación hay que recoger datos de los diferentes modos de operación para que el modelo PCA tenga en cuenta las distintas correlaciones de variables que pueden aparecer. Si se monitoriza este tipo de funcionamiento se puede comprobar que los diferentes transitorios entre los modos de operación disparan los estadísticos el

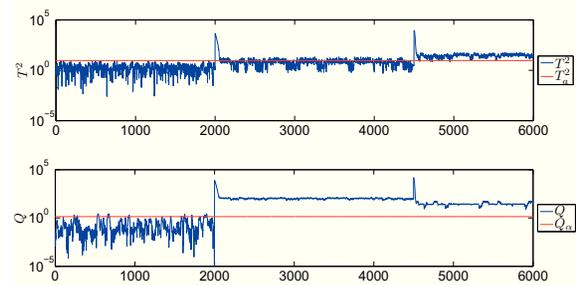


Figura 3: Monitorización de dos fallos con PCA.

suficiente número de muestras para que sean detectados como fallos. Además, si se provoca un fallo de similares características al de la figura 2 es ligeramente diferenciable de los cambios en los modos de operación, como muestra la figura 4, debido a que tanto los cambios en el modo de operación como el fallo disparan el estadístico Q . Aunque a partir de la ocurrencia del fallo el estadístico se mantiene por encima del umbral. Se puede concluir que la monitorización con PCA sobre datos de funcionamiento con múltiples modos de operación hace que el método pierda parte de su potencia de detectabilidad.

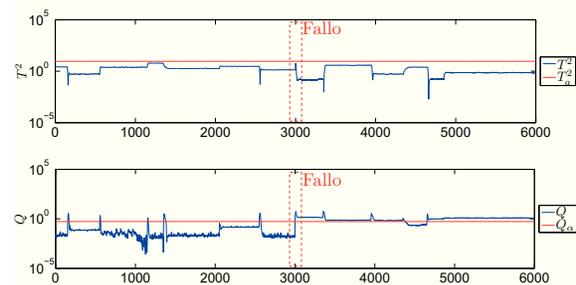


Figura 4: Monitorización de un fallo con PCA sobre un protocolo de funcionamiento con varios modos de operación.

La varianza capturada por dos componentes, tanto para el modo de funcionamiento simple como para el caso con múltiples modos de operación, fue de entre el 82 % y el 90 % dependiendo del conjunto de datos seleccionado.

4.2. Monitorización con APCA

En Zumoffen and Basualdo (2007) se describe un método de detección, aislamiento y estimación de fallos (FDIE). Este método utiliza para la detección de fallos una variante del PCA clásico denominada PCA adaptativo (APCA). El fundamento de este método consiste en que cuando se detecta un fallo la media y la varianza con las que se escala la siguiente lectura del proceso dejan de ser las del cálculo del PCA fuera de línea y se pasa a escalar las nuevas lecturas con una media y la varianza de una ventana de datos del nuevo estado del proceso, por eso se puede decir que el método se *adapta* al fallo. La ventaja que presenta este método con respecto al anterior es que cuando se produzca un nuevo fallo podrá volver a detectarlo.

El algoritmo que sigue este método consta de las siguientes fases:

1. Tomar datos del proceso en funcionamiento normal y ordenarlos en la matriz X . Normalizar los datos con media 0 y varianza 1. Llevar a cabo el análisis de componentes principales sobre estos datos. Calcular los límites de los estadísticos T_α^2 y Q_α . Establecer el tamaño de la ventana deslizante N_w y la matriz normalizada X_N , que será una ventana de datos normalizada que servirá para recalculer el PCA y los umbrales si fuese necesario.
2. Obtener la siguiente lectura x y normalizarla.
3. Calcular los estadísticos T^2 y Q con el modelo PCA actual.
4. Chequear si alguna de los estadísticos supera su umbral, si no lo supera se considera que la medida es normal. Si es normal añadir x normalizado a la matriz normalizada X_n . Volver al paso 2.
5. Si la medida no es normal generar una alarma. Si se producen un determinado número de alarmas consecutivas notificar un fallo. Si no volver al paso 2.
6. Si se ha notificado un fallo, almacenar la medida del proceso en una matriz auxiliar X_{aux} y almacenar la medida de fallo durante N_{aux} muestras. Volver al paso 2.
7. Cuando el tamaño de X_{aux} supera N_{aux} , actualizar los valores de la media y la varianza de normalización por la media y la varianza de X_{aux} .
8. Actualizar los límites de los estadísticos T_α^2 y Q_α .
9. Actualizar el modelo del PCA con la matriz normalizada X_N .
10. Volver al paso 2.

En este método aparecen nuevos parámetros que se deben de fijar teniendo en cuenta las características del proceso, como por ejemplo, el tiempo de asentamiento. Estos parámetros son el número de alarmas consecutivas que se tienen que dar para que se notifique un fallo, el tamaño de la ventana de datos normalizados y el tamaño de la matriz X_{aux} de valores no normales.

La figura 5 muestra como la monitorización con APCA permite detectar el fallo de bias en el sensor de nivel del tanque 1.

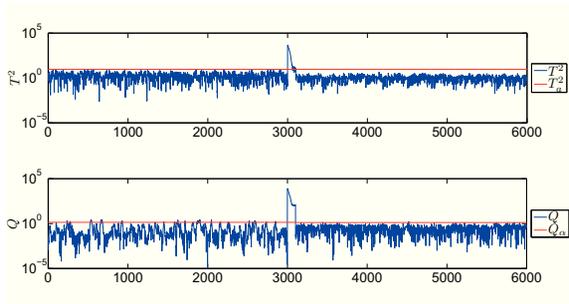


Figura 5: Monitorización de un fallo con APCA.

Si se provoca un segundo fallo después del provocado en el sensor de nivel del tanque 1, en este caso, en el sensor de nivel del tanque 2, el método es capaz de detectarlo gracias a su calidad adaptativa. Después de haber detectado el primer fallo, los

estadísticos T^2 y Q se adaptan a la nueva situación de fallo mediante el cálculo de un nuevo modelo PCA. La figura 6 muestra un ejemplo de monitorización de dos fallos consecutivos.

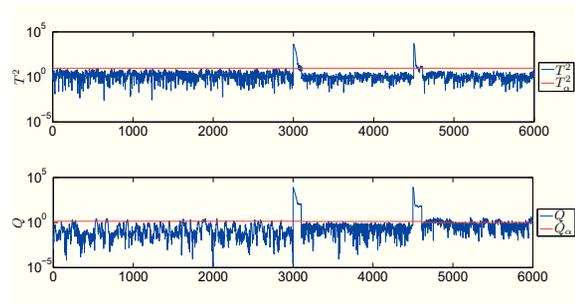


Figura 6: Monitorización de dos fallos con APCA.

La figura 7 muestra la monitorización de un protocolo de funcionamiento de la planta donde aparecen diferentes modos de operación. En este caso los distintos cambios entre modos se detectan como fallos pero no son lo suficientemente duraderos en el tiempo para provocar un cambio en el modelo PCA, el fallo inducido en la muestra 3000 se detecta y provoca que el modelo PCA cambie y los umbrales de los estadísticos se recalculen, a partir de este instante otros cambios en el modo de operación provocan que el modelo PCA se vuelva a recalcular, haciendo imposible la distinción entre los cambios en el modo de operación y el fallo.

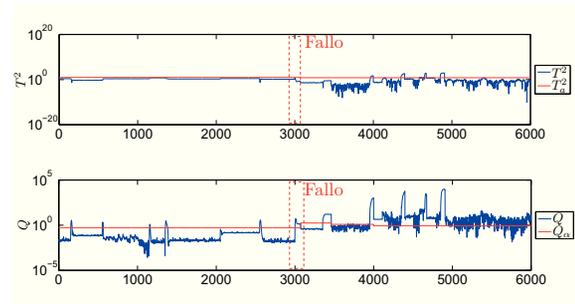


Figura 7: Monitorización de un fallo con APCA sobre un protocolo de funcionamiento con varios modos de operación.

La varianza capturada en este método por los dos componentes seleccionados fue idéntica a la del apartado anterior pudiendo variar dependiendo del fallo detectado.

4.3. Monitorización con MSPCA

Misra et al. (2002) proponen utilizar el PCA sobre la descomposición en frecuencias de las señales de las variables medidas. Para esta descomposición se utilizan las *wavelets*. El método es denominado como MSPCA (*Multi-scale principal component analysis*).

En la mayoría de las señales son las componentes de baja frecuencia las que le otorgan a la señal la mayor parte de su información. Mientras que las componentes de alta frecuencia se encargan de incorporar características más particulares.

Estas componentes se separan a través de filtros, como se muestra en la figura 8, donde S es la señal que se desea analizar, A la salida del filtro pasa baja y D la salida del filtro pasa alta. Los filtros se diseñan de manera que sean complementarios, es decir, la suma de A y D debe de ser S .

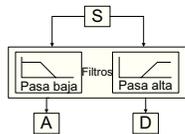


Figura 8: Diagrama de descomposición de señales.

Para muchas señales de mayor complejidad, se puede iterar el proceso de filtrado, es decir, aplicar el mismo procedimiento a las señales de salida de la primera etapa, y así sucesivamente hasta el nivel de precisión que se desee. Esto da origen a una descomposición multinivel conocida como ramificación o árbol de descomposición *wavelet*.

La implementación de este método utiliza una ventana flotante de datos recogidos del proceso para poder calcular la descomposición de las señales en línea. El algoritmo sigue los siguientes pasos:

1. Fuera de línea hay que recoger datos de las variables medidas de la planta en funcionamiento normal, a continuación hay que realizar su descomposición en frecuencias usando *wavelets* para cada una de las variables, y juntar las variables por rango de frecuencia en distintas matrices de datos para calcular un modelo PCA para cada una de ellas. Se pueden calcular los umbrales de los estadísticos también para cada una de las frecuencias. Un esquema de este paso se puede ver en la figura 9. En este método sólo se calcula el estadístico Q .

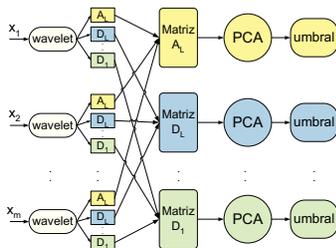


Figura 9: Esquema del cálculo de PCA en el método MSPCA.

2. Añadir la siguiente lectura del proceso a la ventana de datos y calcular la descomposición *wavelet* en frecuencias de la ventana de datos para obtener nuevas lecturas D_1, \dots, D_l y A_l .
3. Normalizar la lectura actual y las componentes *wavelet* D_1, \dots, D_l y A_l y calcular los estadísticos.
4. Si el estadístico de A_l no supera el umbral considerarlo un dato normal y añadirlo a la ventana.
5. Si supera un umbral notificar una alarma. Si ocurre un número determinado de alarmas consecutivas notificar un fallo.

6. Volver al paso 2.

Si se provoca el fallo de bias del 20% en el sensor de nivel del tanque 1 éste es detectado sin ningún problema (figura 10).

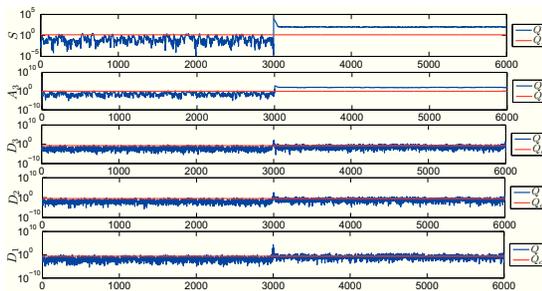


Figura 10: Monitorización de un fallo con MSPCA.

Cuando se provocan dos fallos consecutivos, el segundo de éstos es difícilmente detectable como puede observarse en la figura 11. El método de monitorización con MSPCA no es capaz de detectar dos fallos consecutivos puesto que el disparo de los estadísticos provoca que el segundo fallo no sea detectado.

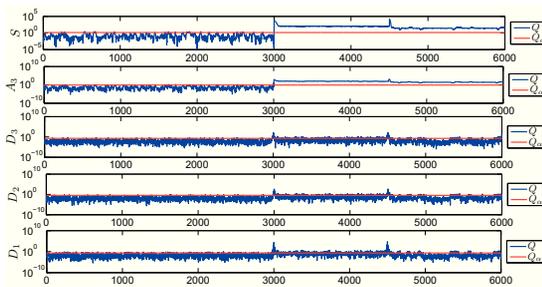


Figura 11: Monitorización de dos fallos con MSPCA.

Cuando la monitorización del proceso se hace sobre protocolos de funcionamiento con múltiples puntos de operación este método responde de manera muy similar al enfoque clásico de la monitorización con PCA, esto es, los distintos transitorios entre cambios en el modo de operación son detectados como fallos y, aunque el fallo provoca que algunas de los estadísticos superen durante un largo período de tiempo el umbral, es difícil poder distinguir entre el fallo y los cambios en el modo de operación, (figura 12).

En este método la varianza capturada por dos componentes en todos los casos tomó valores entre el 77% y el 95%.

4.4. Monitorización con EWPCA

Otro método, algo distinto a los anteriores, es el PCA pesado exponencialmente EWPCA (Exponentially Weighted Principal Component Analysis) descrito en Lane et al. (2003) y Tien et al. (2004). Este método no necesita un cálculo previo del PCA para poder monitorizar el proceso ya que lo calcula en línea a partir de una ventana de datos. El método consiste en un cálculo del PCA de forma adaptativa y exponencialmente pesada y se basa en la actualización recursiva de la matriz de

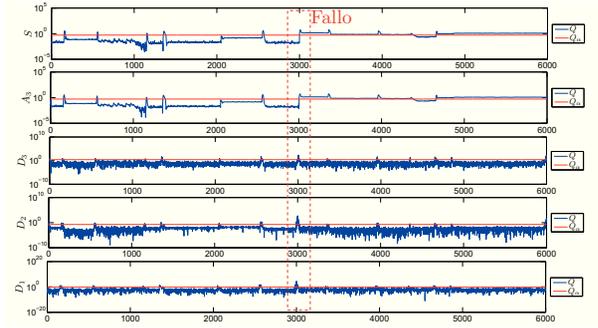


Figura 12: Monitorización de un fallo con MSPCA sobre un protocolo de funcionamiento con varios modos de operación.

covarianzas R . Mediante un factor de peso exponencial λ se da mayor importancia a las muestras más recientes con respecto a las más antiguas.

El algoritmo que implementa este método consta de cuatro pasos:

■ PASO 1: Inicialización

1. Se toman n_0 observaciones de las variables medidas del proceso en operación normal y se genera la matriz de datos X , esta matriz de datos se normaliza con media cero y varianza unitaria para cada columna y se almacenan los valores de la media y la varianza de las muestras \bar{x}_0 y s_0 .
2. Se calcula la matriz de covarianza inicial:

$$R_0 = \frac{1}{n_0 - 1} X^T X \quad (12)$$

3. Se calcula el factor de peso inicial:

$$\lambda_0 = \left(1 - \frac{1}{n_0}\right) \quad (13)$$

■ PASO 2: Aplicación de EWPCA a la nueva observación:

1. Tomar el siguiente vector de medidas del proceso x_t . Normalizarlo con los datos de la media y la varianzas de la iteración anterior \bar{x}_{t-1} y s_{t-1} .
2. Recalcular la matriz de covarianzas utilizando el factor de peso:

$$R_t = \lambda_{t-1} R_{t-1} + (1 - \lambda_{t-1})(x_t^T x_t) \quad (14)$$

3. Realizar la descomposición SVD de la matriz de covarianzas R_t para poder calcular el número de componentes principales.
4. Calcular el valor de los estadísticos T_t^2 y Q_t para el vector de la observación actual.
5. Actualizar los umbrales T_α^2 y Q_α .
6. Si los dos estadísticos están por debajo del umbral ir al PASO 3, si no ir al PASO 4.

■ PASO 3: Actualización de los parámetros de EWPCA.

1. Actualizar la matriz X_t :

$$X_t = \lambda_{t-1} [X | x_t^T] \quad (15)$$

2. Actualizar los valores de la media y la varianza:

$$\bar{x}_t = \lambda_{t-1} \bar{x}_{t-1} \quad (16)$$

$$s_t = \lambda_{t-1} s_{t-1} \quad (17)$$

3. Actualizar el factor de peso exponencial:

$$\lambda_t = 1 - \frac{(1 - T_t^2) Q_t}{\sqrt{n_t - 1}} \quad (18)$$

con:

$$n_t = \lambda_{t-1} n_{t-1} + 1; \quad (19)$$

4. Volver al paso 2 y repetir la iteración con el siguiente vector de observaciones x_{t+1}

■ PASO 4: Acción cuando se detecta una alarma.

1. Almacenar el vector de observaciones que ha producido la alarma en una matriz X_{aux} .
2. Si la alarma no es persistente, es decir, no se han producido un número dado de alarmas consecutivas, volver al PASO 2.
3. Si la alarma es persistente, si la matriz X_{aux} supera un número n_{aux} de muestras, volver al PASO 1 y rehacer el modelo con la matriz X_{aux} , si no volver al PASO 3.

La figura 13 muestra como la monitorización con EWPCA detecta perfectamente un fallo del 20% de bias en el sensor de nivel de tanque 1. Con este método se reduce el número de falsas alarmas de forma drástica.

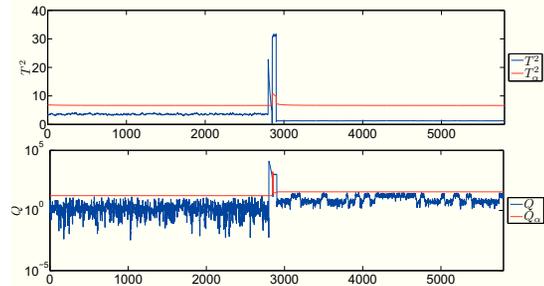


Figura 13: Monitorización de un fallo con EWPCA.

Gracias a su propiedad adaptativa los umbrales de los estadísticos de monitorización son capaces de adaptarse a la nueva situación de fallo y por lo tanto puede detectar un segundo fallo. La figura 14 muestra como el método detecta el primer fallo y como los umbrales se adaptan a la nueva situación, cuando se produce el segundo fallo, éste vuelve a ser detectado, en este caso sólo por el estadístico Q , y su umbral de nuevo se adapta al fallo.

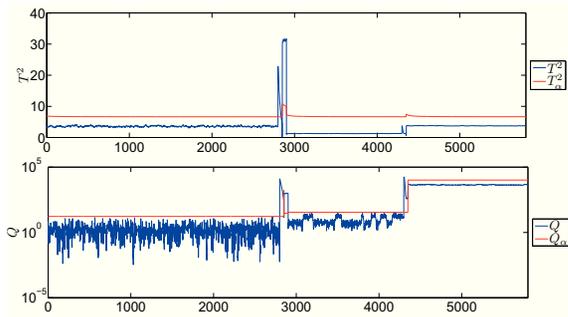


Figura 14: Monitorización de dos fallos con EWPCA.

Si este método se aplica a un protocolo de funcionamiento con múltiples modos de operación los resultados que se obtienen no presentan ninguna ventaja con respecto al resto de métodos. Cada uno de los cambios entre modos de operación es detectado como un fallo y provoca que los umbrales se adapten a la nueva situación de fallo. Tal y como puede observarse en la figura 15 el fallo provocado en el instante 3000 no es distinguible de los cambios entre los modos de operación.

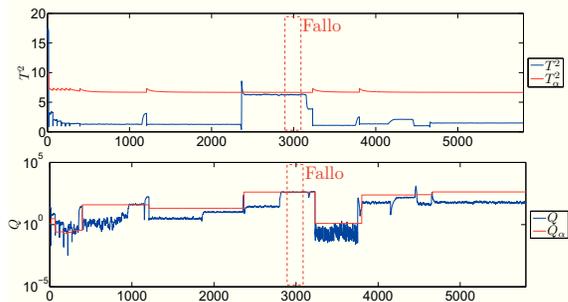


Figura 15: Monitorización de un fallo con EWPCA sobre un protocolo de funcionamiento con varios modos de operación.

En este caso la varianza capturada varía continuamente puesto que el modelo PCA varía a lo largo del tiempo.

4.5. Monitorización con PCAEA

Kano et al. (2004) propone dividir las variables medidas del proceso en dos grupos. El primer grupo consiste en las variables que representan las condiciones de operación, como por ejemplo los puntos de consigna. A este primer grupo se le denomina variables externas. El resto de variables son aquellas que son afectadas por las variables externas y perturbaciones no medidas, a este segundo grupo se le denomina variables principales. En este artículo a este método se le llamará PCAEA (PCA using external analysis)

La información de las variables principales se descompone en dos partes, por una parte la que está influenciada por las variables externas y por otra la que no se puede explicar con estas variables. Operando se puede llegar a eliminar la influencia de las variables externas de las variables principales.

Si se considera $X \in \mathcal{R}^{n \times m}$ que representa las n muestras tomadas de m variables del proceso de la siguiente manera:

$$X = [HG] \quad (20)$$

donde G son las variables externas y H las variables principales. Como ya se ha comentado H tiene una parte influenciada por G y otra que no lo está. Por eso, se puede utilizar un análisis de regresión lineal múltiple utilizando las variables externas como entradas y las principales como salidas, determinando una matriz de coeficientes de regresión C :

$$C = (G^T G)^{-1} G^T H \quad (21)$$

donde la matriz de error queda definida de la siguiente manera:

$$E = H - GC \quad (22)$$

La matriz de las variables principales puede ser dividida en dos partes, GC y E . GC es la parte de H influenciada por las variables externas y E la parte que no está bajo esta influencia.

Esta matriz de datos E no influenciada por G puede ser utilizada para realizar el análisis de componentes principales (PCA). De esta forma el análisis se realizará sobre datos no influenciados por los puntos de consigna.

A la hora de realizar la monitorización del proceso, los vectores de medidas de cada período de muestreo tienen que ser procesados, utilizando la matriz C para quitarles la influencia de las variables externas y posteriormente calcular los estadísticos T^2 y Q .

La figura 16 muestra como el método detecta perfectamente el fallo de un 20% de bias en el sensor de nivel del tanque 1 mediante ambas estadísticas.

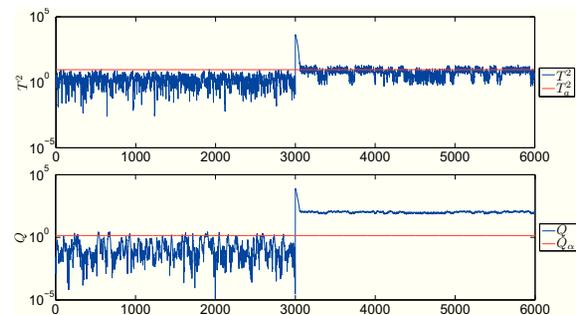


Figura 16: Monitorización de un fallo con PCAEA.

A la hora de detectar dos fallos consecutivos el método no consigue detectar el segundo fallo, como puede observarse en la figura 17

Cuando el método se aplica sobre un modo de funcionamiento que consta de diversos modos de funcionamiento, el resultado es muy similar al que se ha experimentado con otros métodos, ya que los cambios entre los modos de operación son detectados como fallos. En este caso, utilizando el estadístico T^2 en lugar del estadístico Q se puede observar que el comportamiento de éste es distinto cuando se produce un cambio en el modo de operación a cuando se produce un fallo, puesto que este último hace que la estadística no vuelva a situarse por debajo de su umbral (Figura 18).

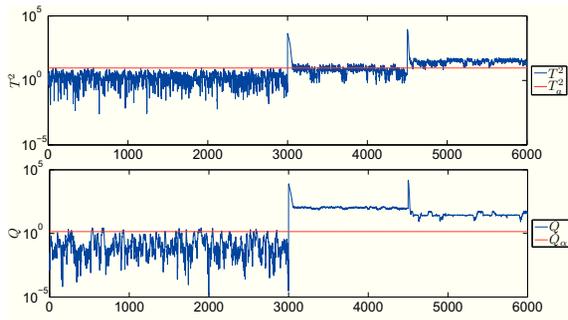


Figura 17: Monitorización de dos fallos con PCAEA.

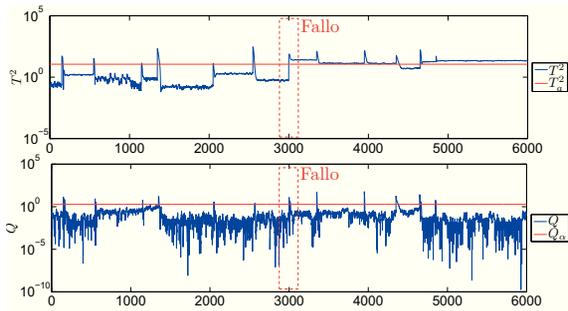


Figura 18: Monitorización de un fallo con PCAEA sobre un protocolo de funcionamiento con varios modos de operación.

Este último caso de monitorización se puede intentar tratar con una variante del método que añade información dinámica. Cuando un proceso es dinámico la influencia de los cambios en las variables externas no puede ser ignorada de la información de operación mediante un análisis estático. En estos casos debe construirse un modelo dinámico (PCADEA).

En ocasiones la influencia que ejercen las variables externas sobre las variables principales queda definido por una relación no lineal por lo que para tratar de quitar la influencia que las variables externas ejercen sobre las variables principales no se debería de utilizar una regresión lineal. Una solución podría ser utilizar una red neuronal. Este método se denominará en este artículo como PCANLEA (PCA using non-linear external analysis) también presentado Kano et al. (2004).

Si se construye una red neuronal con una estructura tal que las entradas sean el valor actual de las variables externas $g(t)$ y sus valores pasados $g(t - 1), g(t - 2), \dots, g(t - s)$, y su salida el valor actual de las variables principales $h(t)$, se conseguiría un aproximador de H con la influencia de las variables externas: \hat{H} , de manera similar al caso lineal donde se calculaba como GC. Con H y \hat{H} se puede construir la matriz E :

$$E = H - \hat{H} \quad (23)$$

$E \in \mathcal{R}^{n \times m}$ representa los datos de las variables principales sin la influencia de las variables externas.

Sobre esta matriz E se puede hacer el análisis de componentes principales y con los datos que se obtengan realizar la monitorización del proceso.

La estructura de la red neuronal que se ha utilizado para hacer las pruebas sobre la planta es de una red neuronal no realimentada con un valor de $s = 6$, es decir, con 6 valores pasados de las variables externas. La red consta de una capa de entrada de $s \times p$ (p número de variables externas) entradas, 16 neuronas sigmoideas en la capa oculta y m neuronas lineales en la capa de salida. El entrenamiento se llevó a cabo durante 500 épocas con un error esperado de 0.01.

La figura 19 muestra como este método detecta el fallo de bias en el sensor de nivel del tanque 1 del 20%. La figura 20 muestra la incapacidad del método para detectar dos fallos consecutivos. Y, finalmente, la figura 21 permite observar que el método no presenta grandes mejoras a la hora de distinguir entre un cambio en el modo de operación y un fallo.

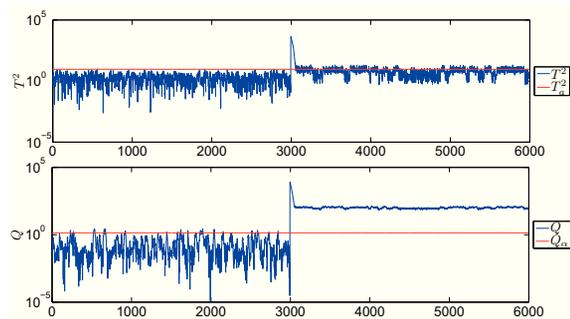


Figura 19: Monitorización de un fallo con PCANLEA.

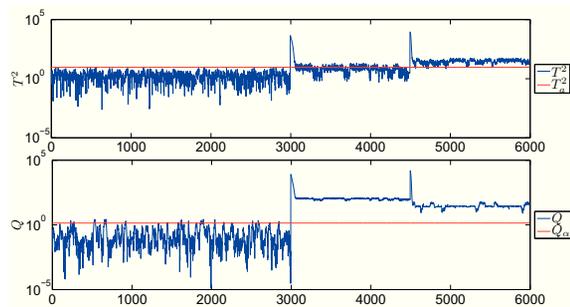


Figura 20: Monitorización de dos fallos con PCANLEA.

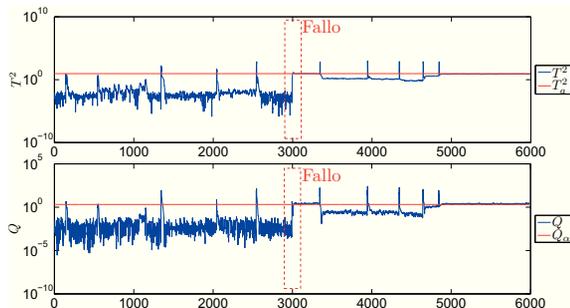


Figura 21: Monitorización de un fallo con PCANLEA sobre un protocolo de funcionamiento con varios modos de operación.

La varianza capturada en ambos métodos tomo unos valores similares al resto de métodos variando ligeramente de un conjunto de datos a otro.

4.6. Monitorización con NLPCA

Si las relaciones entre las variables del espacio de partida y las variables comprimidas son relaciones lineales el PCA es la técnica adecuada. Pero, si estas relaciones son no lineales hay que pensar en otras técnicas para tratar de conseguir combinaciones no lineales entre el espacio de partida y el espacio reducido.

Las redes neuronales autoasociativas (Kramer, 1991, 1992; Dong and McAvoy, 1996; Fourie and de Vaal, 2000; Tan and Mavrouniotis, 1995) son capaces de producir dichas combinaciones no lineales útiles si la información de partida contiene relaciones no lineales: NLPCA (PCA non-linear).

En las redes autoasociativas la función a aprender es la identidad: *entradas de la red = salidas de la red*. Para que la red autoasociativa no aprenda la función identidad exactamente debe haber una restricción interna que consiste en una capa de cuello de botella, es decir, una capa oculta de la red con dimensión menor a la de la entrada y la salida. Con a neuronas en el cuello de botella y m entradas y salidas, $a < m$ la red autoasociativa puede reproducir la función m -dimensional usando sólo a variables independientes.

La arquitectura de una red autoasociativa válida para el problema presentado puede ser la de una red no realimentada con la siguiente estructura (Figura 22):

- La primera de las capas ocultas se la denomina *capa de mapeo*. La función de transferencia de las neuronas de esta capa es sigmoidea.
- La segunda capa oculta es denominada *capa del cuello de botella*. La función de transferencia de las neuronas de esta capa puede ser lineal o sigmoidea. La dimensión de esta capa debe ser menor que la de las capas de entrada y salida.
- La tercera capa oculta es denominada *capa de demapeo*. La función de transferencia de las neuronas de esta capa debe de ser sigmoidea.

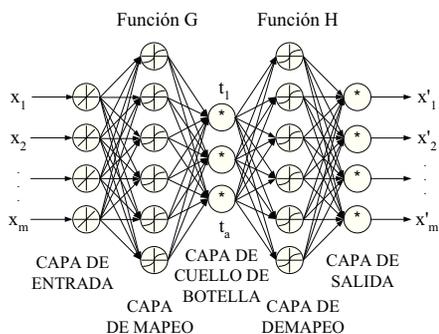


Figura 22: Estructura de red autoasociativa para PCA no lineal

La entrada, la capa de mapeo y el cuello de botella forman la función no lineal G , la cual proyecta las entradas en un espacio de menor dimensión. Este mapeo se puede describir como:

$$t_i = G_i(X), i = 1, \dots, a \tag{24}$$

donde t_i es la salida i -ésima del cuello de botella y $X = \{x_1, x_2, \dots, x_m\}$ es la entrada a la red.

La capa del cuello de botella, la capa de demapeo y la capa de salida forman otra función no lineal H que reproduce una aproximación de las entradas a partir de las salidas de la capa de demapeo.

$$x'_j = H_j(T), j = 1, \dots, m \tag{25}$$

donde $T = \{t_1, t_2, \dots, t_a\}$ son las salidas del cuello de botella.

Las fases de mapeo y demapeo representan una generalización no lineal del análisis de componentes principales. La pérdida de información involucrada en este proceso es medida mediante la suma del cuadrado de la diferencia entre el vector de entrada y de salida en la etapa de entrenamiento.

$$E = \sum_{p=1}^n \sum_{i=1}^m (X_i - X'_i)^2 \tag{26}$$

donde n es el número de muestras de entrenamiento. Como en otras redes neuronales, el entrenamiento consiste en minimizar E .

No existe un método *a priori* para decidir la dimensión de las capas de mapeo y demapeo. Deberían de tener la suficiente dimensión para adecuar su capacidad de representación evitando el sobreaprendizaje. La siguiente ecuación da una aproximación del tamaño de dichas capas en función del resto de parámetros de la red:

$$M_1 + M_2 \ll m(n - a)/(m + a + 1) \tag{27}$$

donde M_1 es el número de neuronas de la capa de mapeo y M_2 el número de neuronas de la capa de demapeo. También se debería utilizar la técnica de la validación cruzada para determinar la estructura de la red. Tampoco existe un método para determinar el número de neuronas de la capa de cuello de botella, una opción podría ser calcular el número de componentes principales lineales.

En la figura 23 puede observarse como la monitorización basada en NLPCA es capaz de detectar el fallo de bias del 20 % en el sensor de nivel del tanque 1.

Sin embargo, como ocurre con otros métodos, este tipo de monitorización no es capaz de detectar dos fallos consecutivos debido a que la detección del fallo provoca que los estadísticos disparen sus valores por encima del umbral. (Figura 24).

Cuando se monitoriza el protocolo de funcionamiento con diferentes puntos de operación tampoco presenta mejores resultados, ya que, como muestra la figura 25 el fallo provocado no es detectado.

Para la monitorización del protocolo de funcionamiento más simple, la red se entrenó con datos relativos a ese protocolo. En el caso del protocolo con múltiples punto de operación la red se entrenó con datos recogidos bajo este protocolo.

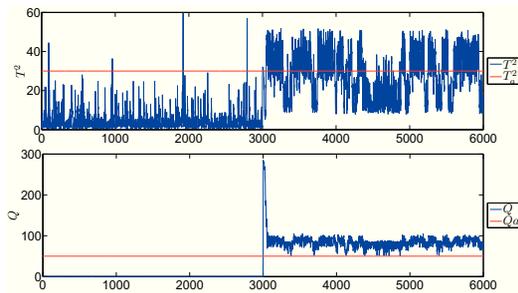


Figura 23: Monitorización de un fallo con NLPCA

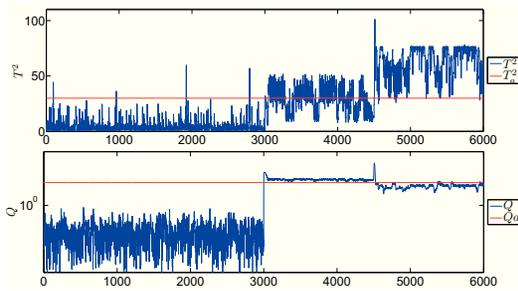


Figura 24: Monitorización de dos fallos con NLPCA

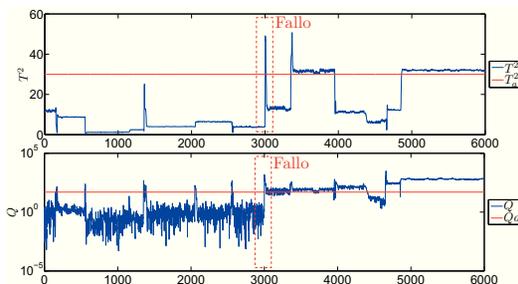


Figura 25: Monitorización de un fallo con NLPCA sobre un protocolo de funcionamiento con varios modos de operación

5. Resultados

En el cuadro 1 se especifica un análisis comparativo de los métodos evaluando distintos parámetros. Estos parámetros pueden dividirse en dos grupos, por un lado los que evalúan el método de forma cuantitativa, estos son los fallos de tipo 1, el tiempo medio de cómputo, el retardo de detección y el tamaño mínimo de fallo detectado, y por otro lado los parámetros cualitativos, que son los que se han evaluado en la descripción de los distintos métodos y se refieren a la detección de múltiples fallos y la adaptación a cambios en el modo de operación.

Tabla 1: Análisis comparativo

	ET1	TC	RT	DMF	ACM	FMD
PCA	4,62 %	$8,03 \cdot 10^{-5}$	10	No	No*	10 %
APCA	2,90 %	$4,2615 \cdot 10^{-4}$	10	Si	No	5 %
MSPCA	2,82 %	$1,8054 \cdot 10^{-4}$	10	No	No*	3 %
EWPCA	0 %	0,0029	12	Si	No	3 %
PCAEA	2,92 %	$9,2721 \cdot 10^{-5}$	12	No	No*	2 %
PCANLEA	2,83 %	0,0027	10	No	No*	18 %
NLPCA	0	0,0034	10	No	No	19 %

A continuación se describen los parámetros usados para el estudio comparativo:

- ET1:** Fallos de tipo 1 o número de falsos positivos. Representa el porcentaje de falsos positivos en las que los estadísticos superaron los umbrales sin que apareciera un fallo. El porcentaje de alarmas que aparece en la tabla es para un total de 6001 muestras. Todos los métodos reducen el número de alarmas con respecto a la monitorización clásica con PCA. Los dos métodos que hacen que desaparezcan las falsas alarmas para el ejemplo utilizado son EWPCA y NLPCA.
- TC:** Tiempo cómputo medio en segundos en procesar una muestra. En el procesado de una muestra, en general, las tareas que se realizan son: el escalado de la muestra, las transformaciones típicas de cada método, el cálculo de las estadísticas y la comprobación de si ha ocurrido un fallo. Para este cálculo se utilizó un PC con un procesador Intel Core Duo a 3 GHz y una memoria RAM de 3Gb, dotado con el sistema operativo WINDOWS XP® y MATLAB® 7.0. Todos los métodos muestran tiempos de cálculo similares al PCA clásico, salvo el EWPCA, PCANLEA y NLPCA, que presentan tiempos de cómputo significativamente mayores.
- RT:** Retardo de detección. Se refiere al número de muestras que se analizaron desde que ocurrió el fallo hasta que éste se detectó. Todos los métodos a excepción de EWPCA y PCAEA detectaron el fallo de manera instantánea, ya que la restricción de detección de fallo fue de 10 alarmas consecutivas, que para el período de muestreo de esta planta que es un segundo el retardo de detección mínimo es de 10 segundos. Para el caso del EWPCA y PCAEA el retardo fue de 2 segundos a mayores.

- **DMF:** Detección de múltiples fallos. Este parámetro hace referencia a la posibilidad de que una vez que se ha detectado un fallo si el método sería capaz de detectar un segundo fallo. Sólo los métodos APCA y EWPCA son capaces de detectar un nuevo fallo gracias a su capacidad adaptativa que hace que las estadísticas vuelvan a la situación nominal.
- **ACM:** Adaptación a cambios en el modo de operación. Se refiere a la capacidad del método a distinguir entre fallos y cambios en el modo de operación debidos, por ejemplo, a cambios en las referencias. Ningún método consiguió diferenciar claramente entre los cambios en los modos de operación y los fallos. Algunos de ellos como el PCA clásico, MSPCA, PCAEA y PCANLEA detectaron de forma diferente los fallos y los cambios en el modo de operación, provocando que las estadísticas a partir del fallo no volviesen a situarse por debajo de los umbrales. Estos métodos han sido marcados con un asterisco.
- **FMD:** Tamaño de fallo mínimo. Esta medida se refiere al tamaño de fallo mínimo que se debe dar para que el método sea capaz de detectarlo. Como las señales medidas están afectadas por un señal aleatoria que simula el ruido éste puede enmascarar el fallo. Todas las modificaciones lineales del PCA reducen este parámetro. Sin embargo, las basadas en redes neuronales aumentan considerablemente este parámetro, seguramente debido a su capacidad de generalización.

6. Conclusión

En este artículo se han detallado siete métodos de detección de fallos basados en el Cálculo de Componentes Principales (PCA). En primer lugar se ha considerado el sistema de monitorización más sencillo que se puede implementar con esta técnica. Posteriormente se han descrito otros seis métodos de monitorización basados en PCA, los cuales presentan variaciones y modificaciones a la versión más básica a fin de solventar las limitaciones que éste presenta. Todos ellos han sido probados en una planta piloto simulada.

También se ha realizado un estudio comparativo a fin de establecer las diferencias entre los métodos y analizar en que situaciones es más útil utilizar un método u otro. Este estudio comparativo se ha basado en el análisis de diferentes parámetros. Cuatro de estos parámetros evalúan el método de forma cuantitativa: el número de falsas alarmas, el tiempo medio de computo, el retardo de detección y el tamaño mínimo de fallo detectado. Por otro lado se han estudiado dos parámetros cualitativos, esto es, la detección de múltiples fallos y la adaptación a cambios en el modo de operación.

English Summary

A comparative study of fault detection techniques based on Principal Components Analysis (PCA)

Abstract

This paper describes and compares different variations of fault detection using principal components analysis (PCA). PCA is a multivariate statistical technique. The paper describes how to design a fault detection system based on PCA, also it describes different statistics, these statistics are calculated to monitor the process state. The different methods compared in this paper are: adaptive PCA (APCA), multi-scale PCA (MSPCA), exponentially weighted PCA (EWPCA), PCA using linear and non-linear external analysis (PCAEA and PCANLEA) and non-linear PCA (NLPCA). The comparative study is based on several quantitative and qualitative parameters.

Keywords:

Statistical methods/Signal analysis for fault detection Process monitoring/statistical process control.

Referencias

- Blanke, M., Kinnaert, M., Lunze, J., Staroswiecki, M., 2003. *Diagnosis and Fault Tolerant Control*. Springer.
- Chiang, L., Russell, E., Braatz, R., 2000. *Fault Detection and Diagnosis in Industrial Systems*. Springer, Nueva York.
- Dong, D., McAvoy, T., 1996. Nonlinear principal component analysis based on principal curves and neural networks. *Computers & Chemical Engineering* 20, 65–78.
- Fourie, S., de Vaal, P., 2000. Advanced process monitoring using an on-line non-linear multiscale principal component analysis methodology. *Computers & Chemical Engineering* 24, 755–760.
- Fuente, M., Garcia, G., Sainz, G., 2008. Fault diagnosis in a plant using fisher discriminant analysis. *Proceeding of the 16th Mediterranean Conference on Control and Automation Congress Centre, Ajaccio, France*, 53–58.
- Garcia-Alvarez, D., Fuente, M., 2008. Analisis comparativo de tecnicas de deteccion de fallos utilizando analisis de componentes principales (pca). *Proceeding of the 29th Spanish Conference on Automation, Tarragona, Spain*.
- Jackson, J., 1991. *A user's guide to principal components*. Wiley.
- Jackson, J., Mudholkar, G., 1979. Control procedures for residuals associated with principal component analysis. *Technometrics* 21, 341–349.
- Kano, M., Hasebe, S., Hashimoto, I., Ohno, H., 2004. Evolution of multivariable statistical process control: application or independent component analysis and external analysis. *Computers & Chemical Engineering* 28, 1157–1166.
- Kourti, T., 2005. Application of latent variable methods to process control and multivariable statistical process control in industry. *International journal of adaptative control and signal processing* 19, 213–246.
- Kourti, T., MacGregor, J., 1996. Multivariate spc methods for process and product monitoring. *Journal of Quality Technology* 28, 409–428.
- Kramer, M., 1991. Nonlinear principal component analysis using autoassociative neural network. *The American Institute of Chemical Engineers Journal* 37, 233–243.
- Kramer, M., 1992. Autoassociative neural networks. *Computers & Chemical Engineering* 16 (4), 313–328.
- Lane, S., Martin, E., Morris, A., Gower, P., 2003. Application of exponentially weighted principal component analysis for the monitoring of a polymer film manufacturing process. *Transactions of the Institute of Measurement and Control* 25, 17–35.
- MacGregor, J., Kourti, T., 1995. Statistical process control of multivariate processes. *Control Engineering Practice* 3 (3), 403–414.
- Misra, M., Yue, H., Qin, S., Ling, C., Septiembre 2002. Multivariable process monitoring and fault diagnosis by multi-scale pca. *Computers & Chemical Engineering* 26, 1281–1293.
- Peña, D., 2002. *Análisis multivariante de datos*. McGraw-Hill.

- Puigjaner, L., Ollero, P., Prada, C., Jiménez, L., 2006. Estrategias de modelado, simulación y optimización de procesos químicos. Editorial Síntesis.
- Shlens, J., 2005. A tutorial on principal component analysis. La Jolla, CA 92037: Salk Institute for Biological Studies.
- Tan, S., Mavrouniotis, M., 1995. Reducing data dimensionality through optimizing neural network inputs. *The American Institute of Chemical Engineers Journal* 41, 1471–1480.
- Tien, D., Lim, K., Jun, L., November 2-6 2004. Comparative study of pca approaches in process monitoring and fault detection. The 30th annual conference of the IEEE industrial electronics society, 2594–2599.
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S., Yin, K., 2003a. A review of process fault detection and diagnosis. part i: Quantitative model-based methods. *Computers & Chemical Engineering* 27, 291–311.
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S., Yin, K., 2003b. A review of process fault detection and diagnosis. part ii: Qualitative models and search strategies. *Computers & Chemical Engineering* 27, 313–326.
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S., Yin, K., 2003c. A review of process fault detection and diagnosis. part iii: Process history based methods. *Computers & Chemical Engineering* 27, 327–346.
- Weighell, M., Martin, E., Morris, A., 2001. The statistical monitoring of a complex manufacturing process. *Journal of Applied Statistics* 28, 409–425.
- Wold, S., 1987. Principal component analysis. *Chemometrics and intelligent laboratory systems* 2, 37–52.
- Zarzo, M., 2004. Aplicación de técnicas estadísticas multivariantes al control de la calidad de procesos por lotes. Ph.D. thesis, Universidad Politécnica de Valencia.
- Zumoffen, D., Basualdo, M., 2007. From large chemical plant data to fault diagnosis integrated to decentralized fault tolerant control: pulp mill process application. *Industrial & Engineering Chemistry Research* 47, 1201–1220.