

# Fault diagnosis based on multivariate statistical techniques

**Oscar Camacho, Delfina Padilla y José L. Gouveia**

*Postgrado en Automatización e Instrumentación, Universidad de los Andes.  
Mérida, Venezuela. Fax: +58-274-2402872. ocamacho@ula.ve, pdelfina@ula.ve,  
gouveia@ula.ve*

## Abstract

In this paper, multivariate statistical techniques such as Fisher Discriminant Analysis and Generalized Discriminant Analysis are utilized for fault diagnosis in an industrial process. The pair-wise FDA analysis is used to identify the fault, which determines the most related variable with the present fault. Therefore, the FDA is proposed to classify linearly separable faults and the GDA to classify faults where a nonlinear classifier is needed. A new procedure to study faults is proposed which include wavelet analysis in the extraction phase, to reduce and decorrelate the data. A continuous stirred tank reactor was simulated in presence of typical faults in order to study the proposed method.

**Key words:** Fault diagnosis, Fisher discriminant analysis, generalized discriminant analysis, Wavelet analysis.

# Diagnóstico de fallas utilizando técnicas estadísticas multivariantes

## Resumen

En este trabajo se usan técnicas estadísticas multivariantes tales como el Análisis Discriminante de Fisher FDA y el Análisis Discriminante Generalizado GDA para realizar el diagnóstico de fallas en un proceso industrial. La identificación de las fallas se realiza por medio del Análisis de pares FDA, que permite seleccionar las variables más relacionadas con la falla. Por tanto, para el diagnóstico de las fallas se propone el FDA en la clasificación de las fallas linealmente separables y el GDA para clasificar fallas donde la data requiere de un clasificador no lineal. Se propone un nuevo procedimiento para el estudio de las fallas, éste se incluye en la etapa de extracción, y se realiza por medio del análisis Wavelet, para decorrelacionar y reducir la dimensión de la data. Un tanque de reacción no isotérmico agitado continuamente fue usado mediante simulación en presencia de fallas típicas, para estudiar las bondades del método propuesto.

**Palabras clave:** Diagnóstico de fallas, análisis discriminante de Fisher, análisis discriminante generalizado, análisis Wavelet.

## 1. Introducción

Los métodos de detección y diagnóstico de fallas basados en data histórica son los más aplicados en las industrias de procesos, debido a que son fáciles de implementar, no necesitan un modelo matemático del proceso y requieren poco conocimiento a priori del proceso y las fallas [1]. El desa-

rollo de la instrumentación digital, las redes industriales y los sistemas de control SCADA y Control Distribuido, permiten almacenar un gran volumen de data de los procesos industriales. Esta data puede ser aprovechada para desarrollar sistemas de detección y diagnóstico de fallas; generando, a partir de esta información, patrones que permitan identificar condiciones similares de falla.

En los métodos basados en data histórica, la detección y diagnóstico de fallas se realiza mediante el procesamiento de un gran volumen de ella. Debido a esto, existen varias maneras en que la data pueda ser transformada y presentada como un conocimiento a priori para el sistema de diagnóstico. La primera etapa para realizar esta tarea es conocida como *extracción de características*, la cual puede ser cualitativa o cuantitativa [2]. Los sistemas expertos, los métodos basados en lógica difusa y los análisis de tendencia cualitativos son ejemplos de métodos de extracción cualitativa. Para el caso de métodos de extracción cuantitativa, en la literatura aparecen ampliamente usadas las redes neuronales y las técnicas estadísticas [3-9]. Técnicas estadísticas tales como el Análisis de Componentes Principales (PCA) [3, 6], Mínimos Cuadrados Parciales (PLS) [3, 7], el Análisis Discriminante de Fisher (FDA) [3, 8], el Análisis de Variables Canónicas (CVA) [3] y el Análisis de Componentes Independientes (ICA) [9] han sido aplicadas en la detección y diagnóstico de fallas con anterioridad. FDA es un método lineal para clasificar múltiples clases y permite reducir la dimensionalidad de la data. Ha sido aplicado con éxito en el diagnóstico de fallas, mostrando superioridad sobre PCA, PLS y CVA [3]. La reducción de dimensionalidad es útil cuando el número de variables medidas en el proceso es grande mientras que el número de observaciones sea pequeño, hecho que es muy común en las industrias de procesos actuales, donde se mide y almacena gran cantidad de variables. Los resultados con FDA muestran superioridad respecto a PCA [10].

El uso de la transformada Wavelet ha sido investigado en los últimos años, debido a su habilidad de decorrelacionar data autocorrelacionada [11]. Los coeficientes Wavelet proveen información compacta acerca de una señal en diferentes localizaciones de tiempo y frecuencia, lo que permite también reducir la dimensionalidad de la data, pero en este caso en la dirección del tiempo, a diferencia del FDA que lo hace en la dirección de las variables. En este trabajo no se realizará una explicación teórica de la misma, por lo que se recomienda a los lectores interesados consultar [12].

Para el caso de que la data requiere de un clasificador no lineal se propone el uso del Análisis Discriminante Generalizado (GDA), también

llamado Análisis Discriminante Linear Kernel (KLDA), el cual ha sido aplicado con éxito en la clasificación de patrones, obteniéndose buenos resultados en la clasificación de semillas y las flores Iris de Fisher [13]. También ha mostrado superioridad ante otras técnicas como el Análisis de Componentes Principales Kernel (KPCA) y el Análisis de Componentes Independientes Kernel (KICA) en el reconocimiento de voz [14]. La comprobación de la eficacia de esta técnica en diagnóstico de fallas es una de las motivaciones de este trabajo.

## 2. Breve Descripción de los Métodos

En esta sección se muestra una explicación resumida de los diferentes métodos estadísticos que fueron aplicados y el procedimiento propuesto para el estudio de las fallas.

### 2.1. Análisis Discriminante de Fisher (FDA)

FDA es una técnica lineal ampliamente usada para la clasificación de patrones, permite reducir la dimensionalidad de la data, es óptima en el término de maximizar la separación entre las clases y es usada para realizar la *extracción de características*. Esta técnica determina un conjunto de vectores FDA a partir de transformaciones lineales, con el fin de maximizar la dispersión entre las clases mientras se minimiza la dispersión de cada clase. Chiang *et al.* muestran una descripción matemática al respecto [3]. Dada una matriz  $X$  de dimensión  $n \times m$ , correspondiente a la data de entrenamiento para todas las fallas, donde la transpuesta de la  $i^{\text{th}}$  fila de  $X$  es el vector columna  $x_i$  y definiendo  $X_j$  como el conjunto de vectores  $x_i$  que pertenecen a la clase  $j$ , la matriz de dispersión-intra para la clase  $j$  es:

$$S_j = \sum_{x_i \in X} (x_i - \bar{x}_j)(x_i - \bar{x}_j)^T, \quad (1)$$

donde  $\bar{x}_j$  es el vector de media para la clase  $j$ , y  $c$  el número de clases o fallas. La matriz de dispersión-intra-clases es representada como sigue:

$$S_w = \sum_{j=1}^c S_j. \quad (2)$$

La matriz de dispersión-entre-clases es:

$$S_b = \sum_{j=1}^c n_j (\bar{x}_j - \bar{x})(\bar{x}_j - \bar{x})^T, \quad (3)$$

donde  $\bar{x}$  es el vector de media total, cuyos elementos corresponden a las medias de las columnas de  $X$  y  $n_j$  es el número de observaciones en la clase  $j$ . El objetivo del primer vector FDA  $\varphi_1$  es maximizar la matriz de dispersión-entre-clases mientras se minimiza la matriz de dispersión-intra-clases:

$$\left\{ \max_{\varphi_1 \neq 0} \frac{\varphi_1^T S_b \varphi_1}{\varphi_1^T S_w \varphi_1} \right\}.$$

El segundo vector FDA se calcula para maximizar la dispersión-entre-clases mientras se minimiza la dispersión-intra-clases entre todos los ejes perpendiculares al primer vector FDA y de la misma manera para el resto de vectores FDA. Matemáticamente se ha demostrado que los vectores FDA son iguales a los vectores propios  $\varphi_k$  del problema de valores propios generalizado:

$$S_b \varphi_k = \lambda_k S_w \varphi_k, \quad (4)$$

donde los valores propios  $\lambda_k$  indican el grado de separabilidad entre todas las clases proyectando la data en  $\varphi_k$ . Con los vectores FDA determinados, las observaciones son luego clasificadas en el espacio reducido usando Análisis Discriminante (AD).

## 2.2. Análisis Discriminante Generalizado (GDA)

Para el caso en que se requiere de un clasificador no lineal, el FDA ha sido generalizado a su versión Kernel. El Discriminante de Fisher Kernel (KFD) fue formulado para clasificación binaria [15], mientras que el GDA fue desarrollado para problemas multi-clases [13]. Si  $\phi: z \in R^N \rightarrow \phi(z) \in F$  es una proyección no lineal desde el espacio original a un espacio característico de alta dimensionalidad, donde las diferentes clases pueden ser linealmente separables,  $S_{WF}$  la matriz de dispersión de cada clase y  $S_{BF}$  la matriz de dispersión entre las clases en el espacio característico  $F$ :

$$S_{BF} = \frac{1}{L} \sum_{i=1}^c C_i (\bar{\phi}_i - \bar{\phi})(\bar{\phi}_i - \bar{\phi})^T \quad (5)$$

$$S_{WF} = \frac{1}{L} \sum_{i=1}^c \sum_{j=1}^{C_i} (\phi(z_{ij}) - \bar{\phi}_i)(\phi(z_{ij}) - \bar{\phi}_i)^T \quad (6)$$

$$\bar{\phi}_i = \frac{1}{C_i} \sum_{j=1}^{C_i} \phi(z_{ij}); \quad \bar{\phi} = \frac{1}{L} \sum_{i=1}^c \sum_{j=1}^{C_i} \phi(z_{ij});$$

$$L = \sum_{i=1}^c C_i, \quad (7)$$

donde  $C_i$  es el número de elementos en  $z_i$ .

Similarmente a FDA, GDA determina un conjunto óptimo de vectores discriminantes tal que se maximice la matriz de dispersión entre las clases mientras se minimiza la matriz de dispersión de cada clase. Asumiendo que  $\Psi = [\Psi_1, \dots, \Psi_m]$ , la maximización puede ser alcanzada resolviendo el siguiente problema de valores propios:

$$\Psi = \arg \max_{\Psi} \frac{|\Psi^T S_{BF} \Psi|}{|\Psi^T S_{WF} \Psi|}. \quad (8)$$

El espacio característico  $F$  puede ser considerado como un “espacio de linealización”, sin embargo, su dimensión puede ser arbitrariamente grande y posiblemente infinita. El  $\phi(z)$  exacto no es necesitado ya que el espacio característico puede volverse implícito usando los métodos Kernel, donde productos punto en  $F$  son reemplazados con una función Kernel en el espacio original  $R^N$  tal que la proyección no lineal es realizada implícitamente en  $R^N$  [16]. En este trabajo se utilizó la función gaussiana RBF que es una de las funciones Kernel más usadas:

$$k(z_1, z_2) = \exp\left(-\frac{\|z_1 - z_2\|^2}{\sigma}\right), \quad \sigma \in R. \quad (9)$$

Con los vectores discriminantes determinados, las observaciones son luego clasificadas en el espacio reducido usando análisis discriminante.

## 2.3. Análisis de pares FDA

Este método propuesto en [10], permite *identificar las fallas* (selección de las variables más relacionadas con la falla) aplicando el análisis de pares FDA a la data en condiciones normales y la data en presencia de cada clase de falla. Al incluir sólo estas dos clases en el análisis de pa-

res FDA y resolviendo el problema de valores propios generalizado (4) se obtendrá sólo un valor propio significativo  $\lambda_i$  y una dirección de Fisher, que corresponde al vector propio  $\varphi_i$ . Se define la dirección de Fisher  $\varphi_i$  como la dirección de falla para  $X_i$ . Los pesos en  $\varphi_i$  son usados para generar el gráfico de contribución para la falla  $X_i$  donde:

$$\varphi_i = [\phi_1, \phi_2, \dots, \phi_j, \dots, \phi_m]^T. \quad (10)$$

El  $j^{\text{th}}$  elemento  $\phi_j$  corresponde a la contribución de la  $j^{\text{th}}$  variable.

## 2.4. Análisis Discriminante (AD)

El diagnóstico de las fallas es realizado a partir del análisis discriminante; la clasificación de las fallas se efectúa asignando una observación a la clase o falla  $i$ , si ésta presenta el máximo valor de la función discriminante:

$$g_i(x) > g_j(x), \quad (11)$$

donde  $g_j(x)$  es la función discriminante para la clase  $j$  dado un vector de data  $x \in R^m$ . Usando la regla de Bayes, asumiendo que la data, para cada clase, esta normalmente distribuida y que la probabilidad a priori es la misma, la función discriminante resulta:

$$g_i(x) = (x - \bar{x}_i)^T \sum_i^{-1} (x - \bar{x}_i) - \ln(\det(\sum_i)), \quad (12)$$

donde  $\bar{x}_i$  y  $\sum_i$  son el vector de media y la matriz de covarianza para la clase  $i$  respectivamente.

En este trabajo se propone un nuevo procedimiento para el estudio de las fallas (Figura 1); éste incluye para la etapa de detección el conocido estadístico  $T^2$  de Hotelling. Una primera etapa de extracción de características es realizada por medio del Análisis Wavelet, para decorrelacionar y reducir la dimensión de la data. El diagnóstico de fallas se efectúa en dos etapas, un primer diagnóstico por medio de FDA+AD que logra clasificar las fallas linealmente separables y una segunda etapa, para aquellas fallas que requieren de un clasificador no lineal, que incluye un paso intermedio para la identificación de las fallas por medio del Análisis de pares FDA, que permite realizar la Selección de Variables (SV) más relacionadas con la falla, siendo éstas sólo utilizadas en la segunda clasificación que se hace combinando GDA, SV y AD.

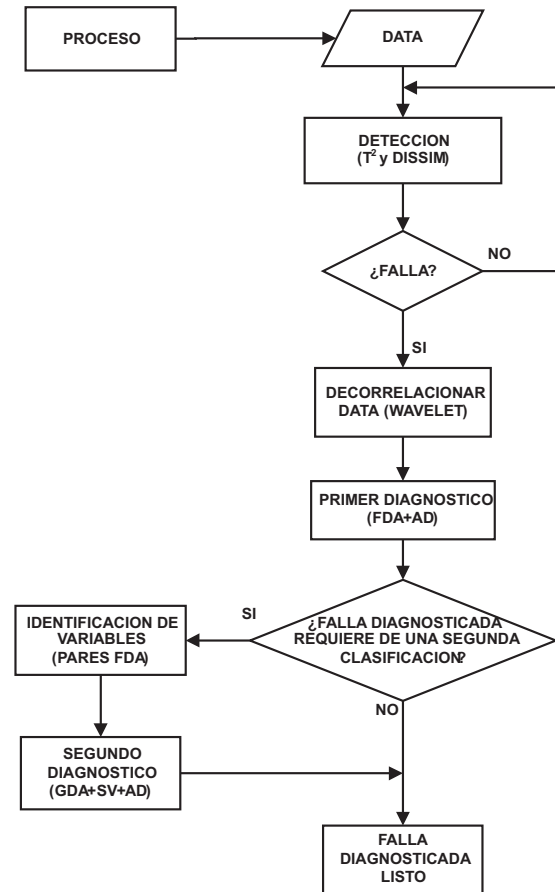


Figura 1. Algoritmo propuesto para la detección y diagnóstico de fallas.

## 3. Caso de Estudio

Para probar el desempeño de estas técnicas estadísticas es necesario contar con una data histórica de un proceso real en presencia de fallas. Debido a que este tipo de data no se encuentra a la mano públicamente por motivo de seguridad de las empresas, muchos investigadores han optado por probar los métodos en procesos industriales simulados en computador. La data histórica fue obtenida a partir de simulaciones de un tanque de reacción isotérmico agitado continuamente (CSTR). Este proceso ha sido utilizado previamente en un buen número de publicaciones [9, 17, 18].

### 3.1. Descripción del proceso CSTR

El CSTR está compuesto por un tanque, una chaqueta enfriadora, un agitador, una bom-

ba y la instrumentación tales como válvulas de control, transmisores de nivel, flujo y temperatura, así como de controladores retroalimentados del tipo PI (Figura 2).

Las variables controladas son la temperatura del reactor ( $T$ ) y el nivel del tanque ( $h$ ), las variables manipuladas son el flujo de alimentación del refrigerante de la chaqueta ( $Q_C$ ) y el flujo de salida del reactor ( $Q$ ). Las 14 fallas y perturbaciones mostradas en la Tabla 1 pueden encontrarse en una base de datos histórica típica de los procesos CSTR. Las fallas 4, 6, 7, 8, 9, 10, 11 y 12, pueden ser tanto positivas como negativas, resultando en un total de 22 fallas que fueron simuladas para la generación de la base de datos históricos.

### 3.2. Generación de la data histórica

La data histórica se generó por medio de simulación, utilizando el software Simulink del paquete Matlab. La condición normal de operación y cada una de las fallas fueron simuladas por un tiempo de 150 min, introduciendo la falla luego de transcurridos 50 min. Mediciones de 14 variables del proceso mostradas en la Tabla 2 fueron almacenadas cada 5 s, el número de observaciones generadas para cada corrida fue  $n=1801$  para cada una de las variables ( $m=14$ ).

Se generaron dos conjuntos de datos para el entrenamiento y la validación. La data de entrenamiento consistió en una corrida para el caso sin falla y para cada una de las 22 fallas. La data de validación consistió en 10 corridas para la data sin falla y para cada falla se realizaron 10 corridas donde el tamaño de la falla o perturbación para los casos 3, 5, 13 y 14 era fijo y para el resto fue cambiado aleatoriamente en un porcentaje que variaba entre el 25% al 125%, esto con el fin de probar la capacidad de generalización del sistema de detección y diagnóstico de fallas propuesto. Se realizaron en total 230 corridas para la validación, resultando un total de 414.230 puntos para cada variable. Todas las señales fueron contaminadas con ruido blanco, con el fin de simular la variabilidad presente en un proceso real, la semilla (*seed*) del ruido fue cambiada aleatoriamente para cada corrida.

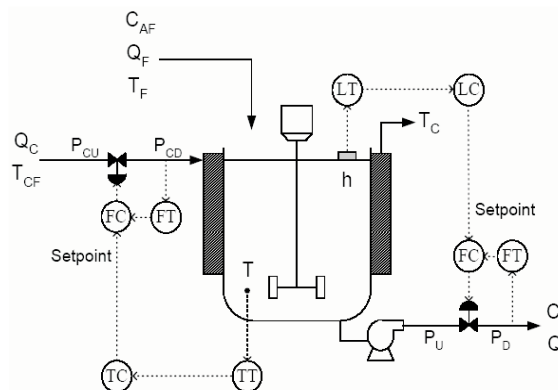


Figura 2. Proceso del CSTR con control cascada.

## 4. Resultados y Discusión

### 4.1. Identificación de fallas utilizando las direcciones de falla en pares FDA

La identificación de la falla nos permite determinar las variables más relacionadas con la falla ocurrida, si al aplicar los métodos de diagnóstico sólo incluimos estas variables podemos disminuir el error de clasificación, conclusión que se muestra en los resultados más adelante. En la Figura 3 se presenta un ejemplo de la gráfica de contribución FDA para la falla 8n (cambio tipo rampa negativo en  $T_F$ ). Como observamos las variables que tienen una mayor contribución en el gráfico son la 1 y la 9, lo que desde el punto de vista del proceso es correcto ya que la variable 9 es precisamente la temperatura  $T_F$  y la variable 1 es la concentración del reactor  $C_A$ , que es afectada directamente por la variación de  $T_F$ . La Figura 3 muestra también cuales fueron las variables identificadas para todas las fallas con la data de entrenamiento, seleccionando únicamente aquellas que presentaron una contribución mayor de 0,3.

### 4.2. Diagnóstico de las fallas utilizando FDA, GDA y análisis discriminante

Para diagnosticar o clasificar una falla mediante las técnicas estadísticas multivariantes estudiadas en este trabajo, es necesario que ésta se encuentre, previamente, en una base de datos histórica, correspondiendo ésta a la data de en-

Tabla 1  
Fallas y perturbaciones del CSTR

Falla	Descripción	Valor
<b>1.</b> Desactivación catalítica	La energía de activación aumenta en rampa por 100 min.	La rampa para E/R es +3K/min
<b>2.</b> Falla en el intercambiador de calor	El coeficiente UA <sub>c</sub> baja en rampa por 100 min.	Rampa para UA <sub>c</sub> de -125(J/(min-K))/min
<b>3.</b> Falla en el transmisor de flujo de refrigerante	El flujo de refrigerante se mantiene a su último valor por 100 min.	N/A
<b>4p</b> y <b>4n.</b> Bías en la medición de temperatura (T)	Bías en la medición de temperatura del reactor por 100 min.	± 4K
<b>5.</b> Fricción estática en la válvula de refrigerante	La posición de la válvula de refrigerante no cambia a menos que el valor de la posición deseada difiera de la posición actual 5% o más del span de la válvula.	N/A
<b>6p</b> y <b>6n.</b> Cambio escalón en $Q_F$	El flujo de alimentación se mantiene en su nuevo valor por 100 min.	± 10L/min
<b>7p</b> y <b>7n.</b> Cambio tipo rampa en $C_{AF}$	La concentración de la alimentación aumenta y disminuye en rampa por 100 min.	La rampa es de $\pm 6 \times 10^{-4}$ (mol/L)/min
<b>8p</b> y <b>8n.</b> Cambio tipo rampa en $T_F$	La temperatura de la alimentación aumenta y disminuye en rampa por 100 min.	La rampa es de $\pm 0,1K/min$
<b>9p</b> y <b>9n.</b> Cambio tipo rampa en $T_{CF}$	La temperatura de la alimentación del refrigerante aumenta y disminuye en rampa por 100 min.	La rampa es de $\pm 0,1K/min$
<b>10p</b> y <b>10n.</b> Cambio escalón en $P_{RE}$	La presión en la línea de alimentación del refrigerante a la entrada de la válvula se mantiene en el nuevo valor por 100 min.	± 2,5 psi
<b>11p</b> y <b>11n.</b> Cambio escalón en $P_S$	La presión en la línea de descarga del reactor a la salida de la válvula se mantiene en el nuevo valor por 100 min.	± 5 psi
<b>12p</b> y <b>12n.</b> Cambio en el Set Point de temperatura	El S. P. para la temperatura del reactor se mantiene en el nuevo valor por 100 min.	± 3 K
<b>13.</b> Juego en la válvula de refrigerante	La válvula del refrigerante presenta juego.	20% del span
<b>14.</b> Válvula del flujo de salida del reactor atascada.	La válvula del flujo de salida del reactor se mantiene a su última apertura por 100 min.	N/A

Tabla 2  
Variables medidas del CSTR

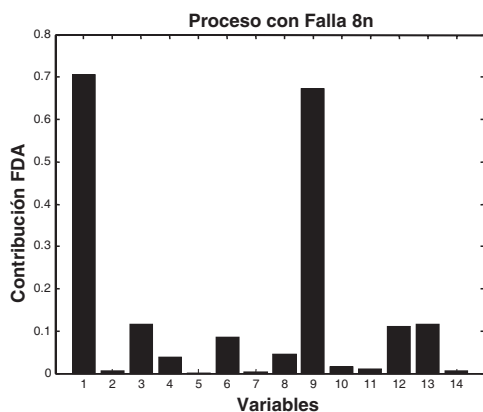
Descripción	Símbolo
Concentración del reactor	$C_A$
Temperatura del reactor	$T$
Temperatura del refrigerante	$T_c$
Nivel del reactor	$h$
Flujo de salida del reactor	$Q$
Flujo del refrigerante	$Q_C$
Flujo de alimentación del reactor	$Q_F$
Concentración de alimentación	$C_{AF}$
Temperatura de alimentación	$T_F$
Temperatura de alimentación del refrigerante	$T_{CF}$
Señal de control de nivel	$hC$
Señal de control de flujo	$QC$
Señal de control de temperatura	$TC$
Señal de control de flujo de refrigerante	$Q_C C$

trenamiento del clasificador. La detección de las fallas se realizó por medio del estadístico  $T^2$  de Hotelling, que es una técnica ampliamente usada para el monitoreo de procesos multivariantes [1, 3, 7], una descripción matemática detallada se puede obtener en Chiang *et al.* [3].

La Tabla 3 muestra el error de clasificación %ec (porcentaje de corridas que fueron clasifica-

das incorrectamente) y el error de clasificación individual %eci (porcentaje de las observaciones de una corrida que fueron clasificados incorrectamente) para las 22 fallas con la data de validación, aplicando AD, FDA+AD y Wavelet+FDA+AD. Para aplicar el FDA fue necesario determinar primero el número de vectores FDA, por medio de validación cruzada se obtuvo un  $N=12$ . Al aplicar el Análisis Wavelet las señales fueron reducidas temporalmente utilizando para ello, luego de un estudio exhaustivo por medio de validación cruzada, una Wavelet del tipo Daubechies 3 (db3), un nivel de descomposición igual a 1 y utilizando solamente el coeficiente de aproximación (ca) para formar el vector característico. Al incluir el FDA junto con el AD se observa como el error de clasificación disminuye considerablemente de 15% a 10%. El uso de la transformada Wavelet trae como ventaja una reducción del error de clasificación de 10% a 9,1% y una reducción de 48% de los datos, siendo este último muy importante para disminuir el tiempo de cálculo requerido para realizar la clasificación. Observamos además en la Tabla 3 que las fallas 7p, 10p-12n, fueron clasificadas incorrectamente en varios de los casos, lo que justifica el uso de un clasificador no lineal como el GDA para mejorar el error de clasificación.

Debido al gasto computacional que requiere el método GDA, no es factible realizar la clasificación de las fallas utilizando todas las posibles fallas en la data de entrenamiento, por lo que sólo se clasificó con GDA aquellas fallas que habían sido clasificadas incorrectamente previamente con la combinación de Wavelet+FDA+AD. En la



Fallas	Variables Identificadas	Fallas	Variables Identificadas
1	1	8n	1,9
2	1,3	9p	1,10
3	3,1,13,12	9n	1,10
4p	3,12,13,6,1	10p	1,12
4n	3,12,13,6,1	10n	1,12
5	1,12	11p	1,14
6p	11,1,7,14,12	11n	1,14
6n	1,11,7,14	12p	3,12,13,6,1
7p	8	12n	3,1,12,13,6
7n	8	13	1,12,8
8p	1,9	14	14,11

Figura 3. Izquierda: gráfica de contribución FDA para la falla 8n. Derecha: variables identificadas.

Tabla 3  
Error de clasificación para la data de validación

Falla	AD		FDA+AD		Wavelet+FDA+AD		Falla diagnosticada
	%ec	%eci	%ec	%eci	%ec	%eci	
1	0	0,0	0	0,1	0	0,0	1
2	0	1,7	0	5,4	0	5,3	2
3	100	100,0	0	23,0	0	37,4	3
4p	0	5,8	0	8,6	0	7,5	4p
4n	0	10,9	10	16,4	0	11,7	4n
5	0	27,4	0	25,3	0	26,8	5
6p	0	4,0	0	5,0	0	3,8	6p
6n	0	2,1	0	2,5	0	1,9	6n
7p	50	48,5	50	47,5	40	47,2	7p-7n
7n	0	8,3	0	11,4	0	12,5	7n
8p	0	19,1	0	13,5	0	17,0	8p
8n	0	8,1	0	7,5	0	7,7	8n
9p	0	14,3	0	22,5	0	22,5	9p
9n	0	3,6	0	5,9	0	4,7	9n
10p	40	47,4	40	42,3	40	43,6	10p-5-13
10n	40	50,4	30	42,8	40	44,7	10n-13
11p	10	11,9	10	13,2	10	13,2	11p-14
11n	30	34,7	30	35,7	30	34,9	11n-14
12p	30	43,8	30	42,1	30	41,3	12p-2
12n	30	31,3	20	29,2	10	27,5	12n-2
13	0	22,1	0	28,4	0	28,1	13
14	0	6,2	0	5,9	0	5,5	14
Promedio	15,0	22,8	10,0	19,7	9,1	20,2	

Tabla 3 se observa una columna que corresponde a la falla diagnosticada, de allí se formaron los subgrupos de fallas a ser clasificados con GDA. En la Tabla 4 se muestran los 4 subgrupos que han sido formados. Se comprobó además que el uso de Selección de Variables (SV) mejora la clasificación en ambas técnicas FDA y GDA, siendo ésta realizada por medio de las direcciones de fallas en pares FDA, y seleccionando sólo aquellas variables que tenían una mayor contribución. Como se observa en la Tabla 4, el uso de la SV dis-

minuyó el error de clasificación utilizando FDA de 8,3% a 7,5%. Para el caso del GDA observamos como el método reduce el error de clasificación a valores de 7,5% sin Selección de Variables y 5,0% con Selección de Variables. Para aquellas fallas que requieren de una segunda clasificación, por medio de SV+Wavelet+GDA+AD, se obtiene un error promedio, para las 22 fallas, de 2,7%, valor que satisface las expectativas del procedimiento propuesto.



Tabla 4  
Error de clasificación de subgrupos de fallas, utilizando SV, Wavelet, FDA, GDA y AD, para el periodo de tiempo correspondiente a 100 observaciones luego de detectada la falla

Subgrupo	Falla	Wavelet+FDA +AD		SV+Wavelet+FDA +AD		Wavelet+GDA +AD		SV+Wavelet+GDA +AD			
		%ec	N	%ec	N	SV	%ec	$\sigma^2$	%ec	$\sigma^2$	SV
1	7p	0	3	0	1	8	10	46	0	1	8
	7n	10		0			0		0		
2	5	0		0			0		0		
	10p	30	12	30	2	1, 12	30	71	30	0,5	1, 12
	10n	30		30			30		30		
	13	0		0			0		0		
3	11p	0		0			0		0		
	11n	0	2	0	1	1, 4, 14	0	76	0	6	1, 4, 14
	14	0		0			0		0		
4	2	0		0			0		0		
	12p	20	6	20	2	1, 3	10	50	0	1	1, 3
	12n	10		10			10		0		
Promedio	8,3		7,5			7,5		5,0			

## 5. Conclusiones

Se mostró la aplicabilidad del Análisis Discriminante Generalizado (GDA), para mejorar el diagnóstico de las fallas, en aquellos casos donde técnicas de clasificación lineales tales como el FDA no presentan buenos resultados. Adicionalmente, se presentó un nuevo procedimiento para la detección, identificación y diagnóstico de fallas, que incluye el uso del estadístico Hotelling para la detección de las fallas, el Análisis Wavelet para decorrelacionar y reducir la dimensión de la data.

Los resultados obtenidos en la detección y diagnóstico de fallas del proceso CSTR, comprobaron la eficiencia del algoritmo propuesto, al mejorarse los resultados con errores de clasificación bajos.

## Referencias Bibliográficas

1. Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. and Yin K. "A review of process fault detection and diagnosis. Part III: Process history based methods". *Comput. Chem. Eng.* 27. 327-346. (2003).
2. Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. and Yin K. "A review of process fault detection and diagnosis. Part I: Quantitative model-based methods". *Comput. Chem. Eng.* 27. 293-311. (2003).
3. Chiang, L., Russell, E. and Braatz, R. "Fault detection and diagnosis in industrial systems". Springer-Verlag. Great Britain. (2001).
4. Venkatasubramanian, V. and Vaidyanathan, R. "Process fault detection and diagnosis using neural networks. I. Steady-state processes". *Comput. Chem. Eng.* 14. 699-712. (1990).
5. Zhou, Y., Hahn, J. and Mannan, M. "Fault detection and classification in chemical processes based on neural networks with feature extraction". *ISA Transactions* 42. 651-664. (2003).

6. Kano, M., Hasebe, S., Hashimoto, I. and Ohno, H. "A new multivariate statistical process monitoring method using principal component analysis". *Comput. Chem. Eng.* 25. 1103-1113. (2001).
7. Choi, S., Yoo, C. and Lee, I. "Overall statistical monitoring of static and dynamic patterns". *Ind. Eng. Chem. Res.* 41, 4303-4317. (2002)
8. Chiang, L., Kotanchek, A. and Kordon, A. "Fault diagnosis based on Fisher discriminant analysis and support vector machines". *Comput. Chem. Eng.* 28. 1389-1401. (2001).
9. Kano, M., Tanaka, S., Hasebe, S. and Hashimoto, I. "Monitoring independent components for fault detection". *AIChE Journal*. Vol. 49, N° 4, 969-976. (2003).
10. He, P., Wang, J. and Qin, J. "A new fault diagnosis method using fault directions in Fisher discriminant analysis". *AIChE Journal*, Vol. 51, N° 2, 555-571, (2005).
11. Aradhye, H. B., Bakshi, B. R., Strauss, R. A., and Davis, J. F. "Multiscale SPC using wavelets: Theoretical analysis and properties". *AIChE Journal*, 49 (4), 939-958 (2003).
12. Burrus, C., Gopinath, C. and Guo, H. "Introduction to Wavelets and Wavelet Transform". Prentice Hall. (1998.).
13. Baudat, G. and Anouar, F. "Generalized discriminant analysis using a Kernel approach". *Neural Computation*, vol. 12, 2385-2404. (2000).
14. Koscor, A. and Tóth, L. "Kernel-Based Feature Extraction with a Speech Technology Application". *IEEE Transactions on Signal Processing*, vol. 52, N° 8, 2250-2263. (2004).
15. Mika, S., Rätsch, G., Weston, J., Schölkopf, B. and Müller, K. "Fisher discriminant analysis with kernels". *Neural Networks for Signal Processing IX*, Y.-H. Hu et al., Eds. New York. IEEE, 41-48. (1999).
16. Juwei Lu, Plataniotis, K.N. and Venetsanopoulos, A.N. "Kernel Discriminant Learning with Application to Face Recognition", in "Support Vector Machines: Theory and Applications", Wang L., ed., Springer-Verlag (2005).
17. Johannesmeyer, M. "Abnormal situation analysis using pattern recognition techniques and historical data". M.Sc. Thesis, University of California, Santa Barbara, CA. (1999).
18. Johannesmeyer, M., Singhal, A. and Seborg, D. "Pattern matching in historical data". *AIChE Journal*. Vol. 48, N° 9, 2022-2038. (2002).

Recibido el 19 de Junio de 2006

En forma revisada el 02 de Julio de 2007