

CLASIFICACIÓN Y DETECCIÓN DE FALLAS EN SISTEMAS DINÁMICOS.

JAVIER HERNANDO PARDO MAYORGA

UNIVERSIDAD DE LOS ANDES

MAESTRÍA EN INGENIERÍA ELÉCTRICA Y ELECTRÓNICA

FACULTAD DE INGENIERÍA

BOGOTÁ D.C.

2006

CLASIFICACIÓN Y DETECCIÓN DE FALLAS EN SISTEMAS DINÁMICOS.

JAVIER HERNANDO PARDO MAYORGA

**Trabajo de optar por el título de
Magíster en Ingeniería Electrónica y de Computadores**

ASESOR

ALAIN GAUTHIER, Ph.D.

UNIVERSIDAD DE LOS ANDES

MAESTRÍA EN INGENIERÍA ELECTRICA Y ELECTRÓNICA

FACULTAD DE INGENIERÍA

BOGOTA D.C.

2006

TABLA DE CONTENIDO

1. MÉTODOS DE CLASIFICACIÓN.....	2
1.1. Métodos de agrupamiento.....	3
1.1.1. Determinísticos.....	3
1.1.1.1. K-means.....	3
1.1.2. Difusos.....	4
1.1.2.1. LAMDA.....	5
1.1.2.1.1. MAD con atributos cuantitativos.....	5
1.1.2.1.2. MAD con atributos cualitativos.....	6
1.1.2.1.3. Cálculo del GAD.....	7
1.1.2.1.4. Clasificación de los datos.....	7
1.1.2.1.5. C-means.....	7
1.2. Métodos Estadísticos.....	9
1.3. El vecino más próximo.....	9
1.3.1. K-Vecinos.....	10
2. FAULT DETECTION AND ISOLATION.....	11
2.1. Sistemas a considerar.....	12
2.2. Observadores para sistemas no lineales.....	12
2.3. Observadores adaptivos y generación de residuos.....	12
2.3.1. Observadores adaptivos, el caso general.....	13
2.3.2. Generación de residuos.....	13
2.4. Evaluación de residuos.....	14
2.4.1. Residuos sin ruido.....	15
2.4.2. Residuos en presencia de ruido.....	15
2.4.3. Evaluación residual para detección de fallas.....	16
2.4.4. Evaluación residual para aislamiento de fallas.....	17
3. ANÁLISIS DE COMPONENTES PRINCIPALES.....	19
3.1. Análisis de componentes principales.....	19
4. SISTEMA A ESTUDIAR.....	22
5. ANÁLISIS DE RESULTADOS.....	26
6. CONCLUSIONES.....	36
7. BIBLIOGRAFIA.....	38

INTRODUCCIÓN

En la actualidad cada vez los sistemas dinámicos son más complejos, es por esto que la detección y posterior corrección de fallos cobra cada vez más aceptación.

La detección de fallas permite conocer estados de funcionamiento del sistema y tener una idea más clara del comportamiento de sistemas complejos o en los que no se posee el modelo matemático completo.

El uso de datos para diagnóstico demanda recursos computacionales y tiempo, dependiendo de los algoritmos utilizados, pero no limita el área de aplicación que pueden ser en medicina, ingeniería, economía entre otros.

Los observadores adaptivos condicionan tener conocimiento del modelo matemático o una aproximación de este, para la generación de residuos los cuales podrán ser usados para la determinación de fallos en los sistemas dinámicos.

1. MÉTODOS DE CLASIFICACIÓN

Los métodos de clasificación tienen aplicaciones en casi todas las actividades humanas, desde siempre el hombre ha deseado clasificar cada una de las variables que gobiernan la vida, no es extraño que las personas prefieren clasificar a otros por grupos sociales, ingresos, raza, a animales de acuerdo a sus propiedades físicas, para extraer las características y minimizar las posibilidades de error o fallas cuando un “elemento” nuevo aparece.

Los métodos de clasificación se pueden dividir de acuerdo a su naturaleza, entre ellos se encuentran los estadísticos donde las características principales son entre otras la media varianza, árboles de decisión donde la clasificación se determina de acuerdo a opciones que guían al elemento entre sus atributos, métodos de agrupamiento de los cuales pueden ser determinísticos o difusos donde el objetivo es determinar los centros de las clases a las cuales cada elemento pertenecerá, y redes neuronales donde se pretende imitar el comportamiento del cerebro humano.

En esta parte de trabajo se dejarán a un lado en un principio las redes neuronales y los árboles de decisión para dar paso a un método determinístico, K-vecinos, y tres de agrupamiento de los cuales uno es determinístico K-means y dos difusos C-means y LAMDA.

1.1. Métodos de agrupamiento.

Estas técnicas también conocidas como técnicas de clustering, la filosofía es generar particiones en el espacio en la reagrupación de los elementos con naturaleza cuantitativa $x \in R^D$ con D atributos a una de la n clases $\Theta = (\theta_1, \theta_2, \dots, \theta_n)$, el concepto de similitud esta relacionado con la distancia entre el vector de datos y el centro del grupo.

Los métodos de agrupamiento están basados en la optimización iterativa de una función objetivo para generar las clases homogéneas y lo más distintas posibles.

1.1.1. Determinísticos

Los métodos determinísticos asignan a un objeto una clase exclusiva.

$$(\neg \exists)(x \in R^D \mid x \in \theta_i \wedge x \in \theta_j) \quad 1 \leq i, j \leq D \quad i \neq j \quad (1)$$

1.1.1.1.K-means

Este es uno de los algoritmos más conocidos y utilizados en los métodos de agrupamiento, realiza una partición estricta (hard), en general el algoritmo en un proceso iterativo simple agrupa en n clases un conjunto de individuos con d atributos.

Función objetivo:

$$J = \sum_{k=1}^K \sum_{n=1}^N D_{knA}^2 \quad (2)$$

Con D siendo la medida de distancia entre el objeto x_n y el centro de la clase k , v_k , con una matriz métrica A , si $A=I$ es la distancia euclidiana.

$$D_{knA}^2 = \|x_n - v_k\|_A^2 = (x_n - v_k)^T \cdot A \cdot (x_n - v_k) \quad (3)$$

Este es el algoritmo K-means, con una partición en hiper esferas de dimensión D , también D corresponde a las características dadas en el espacio.

Algoritmo K-means

- Elegir el número inicial de clases.
- Inicializar los centros de las clases, generalmente de forma aleatoria.
- Recalcular el centro v_k de cada grupo.
- Realizar el procedimiento anterior hasta que los centros estén estables.

1.1.2. Difusos

A diferencia de los determinísticos estos algoritmos permiten que elementos pertenezcan a dos o más clases asignándole un valor de pertenencia a cada clase.

En la práctica los datos no están bien distribuidos, y las clases no son fácilmente determinables, es por esto que hay que agregar una cierta difusión

en la formulación del problema, es en este caso donde los límites de los cluster ya dejan de ser rígidos “hard” y pasan a ser “soft” difusos, es decir ya un dato no tienen un nivel de pertenencia 1 o 0, sino que ahora tendrá un valor entre 1 y 0. Esta nueva característica permite flexibilidad computacional ya que existen derivadas a funciones de pertenencia y esto permite generar la dirección de movimiento de los centros de los cluster.

1.1.2.1.LAMDA

LAMDA es un algoritmo de clasificación difusa, permite clasificación cualitativa y cuantitativa, y analiza el grado de adecuación del elemento a cada clase.

MAD_i (Marginal Adequacy Degree) Grado de adecuación marginal, este corresponde al a cuanto contribuye el i -ésimo atributo a la clase m . MAD es un vector que muestra la ubicación del elemento con respecto a la clase m .

GAD m (Global Adequacy Degree) Grado de adecuación global, se combinan los grados de adecuación marginal mediante operaciones difusos.

1.1.2.1.1. MAD con atributos cuantitativos.

- Función Binomial

$$MADx_{jm} = \rho_{mj} (1 - \rho_{mj})^{1-x_j} \quad (4)$$

- Función distancia

$$MADx_{jm} = \rho_{mj}^{1-d_{mj}} (1 - \rho_{mj})^{1-d_{mj}} \quad (5)$$

$$d_{mj} = |x_j - c_{mj}| \quad (6)$$

- Función normal

$$MADx_{jm} = \frac{1}{\sigma_{mj}} e^{-\frac{(x_j - \mu_{mj})^2}{2\sigma_{mj}^2}} \quad (7)$$

1.1.2.1.2. MAD con atributos cualitativos

El MAD corresponde a la frecuencia de aparición de la clase m, para el atributo j en la modalidad que está presente en el individuo x, es decir,

$$MADx_{jm} = f_{mj} \quad (8)$$

Las frecuencias están dadas por:

$$f_{mj}^{(k)} = f_{mj}^{(k-1)} + \frac{x_f - f_{mj}^{(k-1)}}{n_m + 1} \quad (9)$$

Con x_f es 1 si el descriptor j del individuo x tiene la modalidad que se está analizando y 0 de lo contrario.

En el aprendizaje supervisado la actualización de las frecuencias se hace con los datos de aprendizaje y el no supervisado se actualiza con cada dato adicional.

1.1.2.1.3. Cálculo del GAD

$$GAD_{\alpha m} = \alpha T(MADx_{1m}, MADx_{2m}, \dots, MADx_{jm}) + (1 - \alpha) S(MADx_{1m}, MADx_{2m}, \dots, MADx_{jm})$$

(10)

Donde α es la exigencia esta entre 0 y 1 y T y S son las normas de agregación difusa.

1.1.2.1.4. Clasificación de los datos

El elemento pertenecerá a la clase que tenga el más alto GAD, si se supera el umbral estimado. Si el elemento no supera el umbral se asigna a la clase de no información (NIC), esto para el caso supervisado, para el no supervisado se genera una clase nueva con los elementos no clasificados.

1.1.2.2.C-means

Este algoritmo es una mejora del algoritmo K-means, ya que este permite que un elemento pertenezca a mas de una clase.

La idea es determinar los centros de las clases y asignan a cada elemento un grado de pertenencia a cada una de las clases.

El objetivo de fuzzy C-means es encontrar un $U = [u_{ik}] \in M_{fc}$ y

$V = (v_1, v_2, \dots, v_c)$ $v_i \in R^D$ de tal forma que:

$$J_m(U, V) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m \|x_k - v_i\|^2 \quad (11)$$

Sea mínima donde U la matriz que contiene el grado de pertenencia de cada punto con respecto a cada clase, y V el vector de centros de asociado a cada clase, m es una constante de peso.

Algoritmo Fuzzy C-means

- Paso 1. Para datos dados $X = \{x_1, \dots, x_n\}, x_i \in R^D$ con c clases $c \in \{2, 3, \dots, n-1\}$, $m \in (1, \infty)$ e inicializando $U^{(0)} \in M_{fc}$.
- Paso 2. Para cada iteración $l, l = 0, 1, 2, \dots$

$$v_i^{(l)} = \frac{\sum_{k=1}^n (u_{ik}^{(l)})^m x_k}{\sum_{k=1}^n (u_{ik}^{(l)})^m}, 1 \leq i \leq c \quad (12)$$

- Paso 3. Actualizar $U^{(l)} = [u_{ik}^{(l)}]$ con $U^{(l+1)} = [u_{ik}^{(l+1)}]$

$$u_{ik}^{(t+1)} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_k - v_i^{(t)}\|}{\|x_k - v_j^{(t)}\|} \right)^{\frac{2}{m-1}}}, 1 \leq i \leq c, 1 \leq k \leq n \quad (13)$$

- Paso 4. si $\|U^{(t+1)} - U^{(t)}\| < \varepsilon$, se determina la terminación de las iteraciones de otro modo se repite el algoritmo desde el paso 2.

Este algoritmo no garantiza la convergencia a un mínimo global y puede quedarse estacionado en un mínimo local, esto depende en gran medida de la inicialización de la matriz U.

1.2. Métodos Estadísticos.

1.2.1. El vecino más próximo

Este método clasifica los nuevos datos de acuerdo al elemento que se encuentra más cercano a este.

Paso 1. Buscar el elemento a menor distancia.

Paso 2. Se asigna la clase del elemento más cercano al nuevo elemento.

1.2.2. K-Vecinos

El método de los k-vecinos es más general que el del vecino más próximo, la filosofía es similar pero se utilizan preferiblemente un número impar y mayor a 1 de elementos para realizar la clasificación.

Paso 1. Buscar los k-elementos a menor distancia.

Paso 2. Se determina la clase con mayor frecuencia.

Paso 3. Se asigna la clase con mayor frecuencia al nuevo elemento.

2. FAULT DETECTION AND ISOLATION

El aumento en la complejidad en la ingeniería de los sistemas ha motivado el desarrollo de fault detection and isolation (FDI) desde el propósito de la supervisión.

Los sistemas linealizados son básicamente para el análisis en un punto de operación, es por esto que FDI utiliza el modelo original.

Alguna de la dificultad de FDI en sistemas no lineales la imposibilidad de medir algunas variables, para esto se utiliza la estimación y/o eliminación.

En este documento se trabajara FDI para modelos no lineales basado en observadores adaptivos. Un observador adaptivo es aquel el cual simultáneamente estima el estado y algunos parámetros del sistema. Este proceso requiere que solo se estime un parámetro a la vez adicionalmente a la estimación de las variables de estado.

FDI puede ser dividido en dos partes, la generación de los residuos y la evaluación de estos.

2.1. Sistemas a considerar

Por lo general los sistemas son determinísticos continuos en tiempo y están descritos en variables de estado así:

$$\begin{cases} \dot{x} = f(\theta, x, u) \\ y = g(\theta, x, u) \end{cases} \quad (14)$$

Donde x , u y y son respectivamente el estado la entrada y la salida del sistema, f y g son ecuaciones no lineales parametrizadas de x y u por el vector θ .

2.2. Observadores para sistemas no lineales

Dado un sistema como el descrito en (14), un observador típicamente tiene la estructura:

$$\dot{\hat{x}} = \hat{f}(\theta^0, \hat{x}, u, y, K) \quad (15)$$

Donde \hat{x} es el estimado de x , \hat{f} es una ecuación no lineal y K es el vector de los parámetros a determinar.

Para estos sistemas se asume que son observables.

Si \hat{x} es la estimación del estado dado por el observador entonces la salida estimada es $\hat{y}(t) \hat{=} h(\theta, \hat{x}(t), u)$, la predicción del error esta dada por $\hat{y}(t) - y(t)$ y es un candidato natural para los residuos de FDI.

2.3. Diseño de observadores adaptivos, basado en observadores de alta ganancia

Teniendo en cuenta el sistema en (1), asumiendo que $x \in R^n$ y $y \in R$ luego de cambios en las variables de estado, se tiene la forma triangular:

$$\begin{cases}
 y = h(x_1, u) \\
 \dot{x}_1 = f_1(x_1, x_2, u) \\
 \dot{x}_2 = f_2(x_1, x_2, x_3, u) \\
 \vdots \\
 \dot{x}_{n-1} = f_{n-1}(x_1, \dots, x_n, u) \\
 \dot{x}_n = f_n(x_1, \dots, x_n, u)
 \end{cases} \quad (16)$$

Donde $x = (x_1, \dots, x_n)^T$ y $f = (f_1, \dots, f_n)^T$, definiendo:

$$A(t) = \frac{\partial}{\partial t} f(x, u) \quad C(t) = \frac{\partial}{\partial t} h(x_1, u) \quad (17)$$

Entonces existe una matriz semidefinida positiva S tal que $K = S^{-1}(1, 0, \dots, 0)^T$

satisface:

$$(A(t) - KC(t))^T S + S(A(t) - KC(t)) \leq -I \quad (18)$$

y el observador:

$$\dot{\hat{x}} = f(\hat{x}, u) - K(\hat{y} - y) \quad (19)$$

Tiene convergencia exponencial, para cualquier condición inicial $\hat{x}(0)$. (Para mas detalles [2][3][7])

2.4. Observadores adaptivos y generación de residuos

2.4.1. Observadores adaptivos, el caso general

Cuando algunos parámetros en θ son desconocidos o cambian, los observadores convencionales no pueden ser usados para la estimación. Si se asume que todos los parámetros de θ son desconocidos o sujetos a cambios, los observadores adaptivos son de la forma:

$$\begin{cases} \dot{\hat{x}} = \varphi(\hat{\theta}, \hat{x}, u, y, K_x) \\ \dot{\hat{\theta}} = \Psi(\hat{\theta}, \hat{x}, u, y, K_\theta) \end{cases} \quad (20)$$

Donde \hat{x} y $\hat{\theta}$ son los estimados de x y θ , del mismo modo φ y Ψ son dos funciones no lineales a ser diseñadas, K_x y K_θ son los vectores de parámetros a sintonizar.

2.4.2. Generación de residuos

Asumiendo que se ha diseñado un observador para el monitoreo del sistema. Denotando que $\hat{x}(\theta^0)$ es el estimador de estado dado por el observador basado en los parámetros originales θ^0 . La correspondiente predicción de salida:

$$\hat{y}(\theta^0) = h(\theta^0, \hat{x}(\theta^0), u) \quad (21)$$

Entonces se puede definir el residuo como la correspondiente predicción de error:

$$\gamma_0 \hat{=} \hat{y}(\theta^0) - y \quad (22)$$

Ahora se define para cada uno de los parámetros a predecir un observador adaptivo $\theta_j, j = 1, 2, \dots, m$. Denotando $\hat{x}(\theta_j^0)$ el estado estimado dado por el observador adaptivo, donde θ_j^0 consiste en todos los parámetros nominales excepto el j-ésimo. La correspondiente predicción de salida es:

$$\hat{y}(\theta_j^0) = h(\theta_j^0, \hat{\theta}_j, \hat{x}(\theta_j^0), u) \quad (23)$$

De forma similar se define el residuo:

$$\gamma_j \hat{=} \hat{y}(\theta_j^0) - y \quad (24)$$

Se definen m+1 residuos para m parámetros a monitorear

2.5. Evaluación de residuos

FDI esta dividido básicamente en dos partes, generación y evaluación de los residuos, en este último se tienen m observadores adaptivos estimando m parámetros en paralelo, desafortunadamente como cada uno de los observadores estima un solo parámetro y asume que los demás son conocidos y constantes, el cambio en un solo parámetro modifica todos los parámetros estimados. Es por esto que en algunos casos es difícil determinar cual de los parámetros en realidad ha cambiado.

2.5.1. Residuos sin ruido

Cuando en el sistema no se encuentra una falla todos los residuos $\gamma_0, \gamma_1, \dots, \gamma_m$ tienden a cero, luego de los transientes se puede decir que todos los residuos son prácticamente cero.

En la presencia de una falla se modifican los residuos una falla es detectada si alguno de los residuos γ_j tiende a dejar el cero. Si la falla corresponde al cambio en un simple parámetro, todos los residuos a excepción de uno

difieren de cero. Si γ_j tiende a regresar a cero luego del transiente, entonces la falla corresponde a un cambio en γ_j .

2.5.2. Residuos en presencia de ruido

Si en el caso en el que la salida posea ruido y este sea menor comparado con la magnitud de los residuos, el análisis puede seguir realizándose a simple inspección como en el caso de ausencia de ruido. En el caso que el ruido tenga mayor magnitud que “esconda” la presencia de una falla la decisión estadística no ayuda de la mejor manera, se pueden tomar decisiones erróneas.

2.5.3. Evaluación residual para detección de fallas

En general las fallas no modifican la media de la predicción del error. Es más común que las fallas modifiquen el espectro de los residuos, para esto se puede aplicar métodos para evaluar el cambio en los espectros de las señales, el éxito de este análisis depende del espectro del ruido y el efecto de las fallas en los residuos.

Otra alternativa es el uso de filtros para los residuos ya que la evaluación de estos en ausencia de ruido es más fácil. Antes que ocurra una falla las salidas de los predictores $\hat{y}(\theta^0)$ y $\hat{y}(\theta_j^0)$, dados por los observadores son versiones filtradas de y , entonces estas son casi idénticas.

Se definen los m diferencias entre residuos:

$$\zeta_j \hat{=} \gamma_0 - \gamma_i = \hat{y}(\theta^0) - \hat{y}(\theta_j^0), j = 1, 2, \dots, m \quad (25)$$

De este modo antes de ocurrir una falla las diferencias entre residuos es casi cero, se puede concluir entonces que la suma de las diferencias de residuos es cercana a cero en el caso libre de falla y mayor a cero si existe una falla.

$$S \hat{=} \sum_{j=1}^m |\zeta_j|$$

$$S \hat{=} \sum_{j=1}^m |\hat{y}(\theta^0) - \hat{y}(\theta_j^0)| \quad (26)$$

2.5.4. Evaluación residual para aislamiento de fallas

Para el aislamiento de una falla se asume que esta se presente por un cambio en un simple componente de θ . Para cambios simultáneos FDI deberá utilizar observadores adaptivos que puedan estimar múltiples parámetros y el diseño de estos observadores es poco realista.

La idea es calcular las correlaciones entre las salidas estimadas de los observadores y la salida real o medida.

Tomando y^* como la salida real del sistema.

$$\varepsilon \hat{=} y - y^* \quad (27)$$

$$e_0 \hat{=} \hat{y}(\theta^0) - y^* \quad (28)$$

$$e_j \hat{=} \hat{y}(\theta_j^0) - y^*, \quad j = 1, 2, \dots, m \quad (29)$$

Se nota que ε es la medida del ruido, e_0 es el error filtrado del observador-0 y e_j es del observador-j. Cuando se presenta un cambio en θ_i se asume que $E e_i^2$ es pequeño y para cualquier j , e_0 - e_j no esta linealmente correlacionado con e_0 .

3. ANÁLISIS DE COMPONENTES PRINCIPALES

Análisis de componentes principales es un análisis estadístico que permite la transformación de datos multivariados a un espacio de menos dimensiones sin mayor pérdida de generalidad.

Los nuevos componentes son una combinación lineal de las variables originales y adicionalmente son independientes.

En la interpretación de los resultados es importante el conocimiento que posea el experto sobre el proceso dado el análisis de magnitud y signo de las correlaciones de las variables iniciales.

3.1. Análisis de componentes principales

Dado que los procesos día a día son cada vez más complejos, esto implica que cada vez hay mas variables y estas pueden estar correlacionadas, estas relaciones son útiles en FDI (Fault Detection and Isolation).

Este análisis permite reducir las variables originales en k componentes principales.

Dada una matriz de observaciones de $m \times n$, $X = [x_1, x_2, \dots, x_n]$, el algoritmo es:

- Paso 1. Normalizar los datos.

\check{X} Medias de X.

\hat{X} Extracción de las medias y división por la desviación estándar.

- Paso 2. Obtener la matriz de covarianza S de X.
- Paso 3. Calcular los valores propios de S.
- Paso 4. Calcular los vectores propios de magnitud unitaria.
- Paso 5. Hallar la matriz de transformación de m x k (con k factores principales), $V_T = [V_1, V_2, \dots, V_m]$.
- Paso 6. Hallar la k componentes principales:

$$Y = \check{X}V_T \quad (30)$$

$$Y_{(j)} = u_{(j)1}\check{X}_1 + \dots + u_{(j)m}\check{X}_m, j = 1, 2, \dots, k \quad (31)$$

4. SISTEMA A ESTUDIAR

El sistema dinámico a analizar consiste en dos tanques acoplados, uno con área transversal constante dependiendo la altura y otro cuya área varía dependiendo de la altura.




Ilustración 1 Diagrama de tanques acoplados.

El sistema corresponde a dos tanques, una bomba que alimenta al sistema con agua, una salida en el tanque de área variable dependiendo de la altura y dos válvulas en cada uno de los tanques que simulan fugas en el sistema, estas fugas serán las fallas que se pueden presentar.

Área Tanque lineal

$$A_{il} = 121\text{cm}^2 \quad (32)$$

Área Tanque no Lineal

$$A_{nl} = \begin{cases} 0cm \leq h_2 < 10cm & \Rightarrow 100cm^2 \\ 10cm \leq h_2 < 20cm & \Rightarrow \{10[21 + 2(h_2 - 10)]\}cm^2 \\ 20cm \leq h_2 < 30cm & \Rightarrow \{10[21 - 2(h_2 - 20)]\}cm^2 \\ 30cm \leq h_2 < 40cm & \Rightarrow 200cm^2 \end{cases} \quad (33)$$

A. Ecuaciones de la dinámica del sistema

$$\begin{cases} \dot{h}_1 = \frac{q_1}{A_{tl}} - \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{tl}} \\ \dot{h}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{A_d \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} \end{cases} \quad (34)$$

B. Sistema más fallas

$$\begin{cases} \dot{h}_1 = \frac{q_1}{A_{tl}} - \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{tl}} - \frac{A_{fil} \cdot \sqrt{2 \cdot g \cdot h_1}}{A_{tl}} \\ \dot{h}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{(A_d + A_{fil}) \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} \end{cases} \quad (35)$$

Nótese que en la primera ecuación de estado la falla es aditiva y en la segunda se puede modelar como la variación de un parámetro.

Sea el observador ordinario:

$$\begin{cases} \dot{h}_1 = \frac{q_1}{A_{tl}} - \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{tl}} - K_1 (\hat{h}_2 - h_2) \\ \dot{h}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{A_d \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} - K_2 (\hat{h}_2 - h_2) \end{cases} \quad (36)$$

Y los observadores adaptivos:

Observador 1

$$\begin{cases} \dot{h}_1 = \frac{q_1}{A_{tl}} - \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{tl}} - K_1 (\hat{h}_2 - h_2) \\ \dot{h}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{\theta_1 \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} - K_2 (\hat{h}_2 - h_2) \\ \dot{\hat{\theta}}_1 = K_{\theta_1} (\hat{h}_2 - h_2) \end{cases} \quad (37)$$

Observador 2

$$\begin{cases} \dot{h}_1 = \frac{q_1}{A_{tl}} - \frac{\theta_2 \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{tl}} - K_1 (\hat{h}_2 - h_2) \\ \dot{h}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{A_d \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} - K_2 (\hat{h}_2 - h_2) \\ \dot{\hat{\theta}}_2 = K_{\theta_2} (\hat{h}_2 - h_2) \end{cases} \quad (38)$$

Y los residuos:

Observador ordinario:

$$\gamma_0 = \hat{y}(\theta^o) - y \quad (39)$$

Y de los observadores adaptivos.

$$\gamma_1 = \hat{y}(\theta_1^o) - y \quad \gamma_2 = \hat{y}(\theta_2^o) - y \quad (40)$$

5. ANÁLISIS DE RESULTADOS

Los resultados están basados en la clasificación con la metodología LAMDA de los residuos generados por los observadores adaptivos y el ordinario, la acción del controlador y el nivel de referencia, posterior al análisis de componentes principales para realizar la reducción de variables a ser analizadas.

$$\begin{aligned}
 A_u &= 0.317 & A_{fl} &= 0.0396 & A_d &= 0.173 & A_{fml} &= 0.0432 \\
 K_1 &= 0.0086 & K_2 &= 6.0505e-6 & K_{\theta_1} &= -0.0009 \\
 K_{\theta_2} &= -0.00030425 \\
 T.Muestreo &= 4seg
 \end{aligned}
 \tag{41}$$

Sea la acción de control:




Figura 1 Referencia de entrada al controlador, variación del nivel de 25 cms a 10 cms.

Cada 5000 s.

Teniendo en cuenta el cálculo del MAD.

MAD con atributos cuantitativos:

- Lamda 1

$$\rho^x \cdot (1-\rho)^{1-x} \quad (42)$$

- Lamda 2

$$K \cdot \rho^x \cdot (1-\rho)^{1-x} \quad K = \frac{\log\left(\frac{\rho}{1-\rho}\right)}{2 \cdot \rho - 1} \quad (43)$$

- Lamda 3

$$\rho^{1-|x-c|} \cdot (1-\rho)^{|x-c|} \quad (44)$$

- Lamda 4

$$K \cdot \rho^{1-|x-c|} \cdot (1-\rho)^{|x-c|}, K = \frac{\log\left(\frac{\rho}{\rho-1}\right)}{2 \cdot \rho - \rho^c \cdot (1-\rho)^{|x-c|} - \rho^{1-c} \cdot (1-\rho)^{|1-c|}} \quad (45)$$

- Gauss 1

$$e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (46)$$

- Gauss 2

$$K \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad K = \frac{\sigma_e}{\sigma} \quad (47)$$

C. Falla tanque no lineal

La falla en el tanque no lineal se presenta cuando la válvula correspondiente es activada, esta falla es modelada como la variación del valor del área que determina el caudal de salida.

La variación del parámetro se presenta en $t=10000$ y desaparece en $t=20000$.

Los resultados a continuación se presentan cuando los datos a clasificar son:

- Nivel de agua en el tanque NO Lineal
- Derivada del nivel de agua en el Tanque NO Lineal
- Nivel de agua en el Tanque Lineal
- Acción del controlador
- Derivada de la acción del controlador

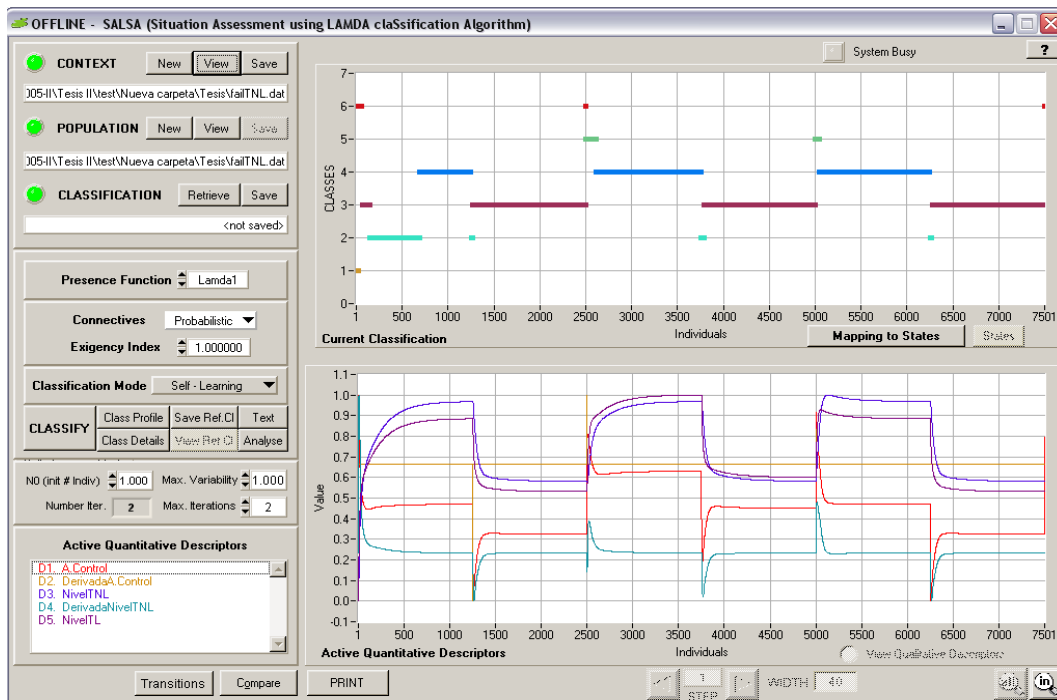


Figura 2 Resultados de la clasificación en ausencia de los residuos.

Los resultados que se obtienen en la clasificación con las variables anteriormente mencionadas, no logran identificar el momento en el que se presenta la falla en el tanque NO lineal, el cual es una falla aditiva. Simplemente las clases resultantes muestran claramente 2 clases que están determinando los dos niveles de referencia que se trabajan en la simulación, los resultados no revelan demasiado ya que las variables que se tomaron para el análisis no poseen gran variación en la presencia de la falla.




Figura 3 Residuos generados por la variación de A_d .

El residuo generado por el observador ordinario muestra la presencia de la variación de un parámetro entre $t=10000$ y 20000 . El residuo generado por el observado adaptivo del parámetro A_d muestra que entre el tiempo 10000 y 11000 , el observador detecta la falla y se adapta el parámetro a esta. El tercer residuo detecta la falla, empieza a realizar la

adaptación de la misma, pero en las variaciones del nivel se presentan oscilaciones que muestran que el parámetro A_a no en el que se presento la falla.

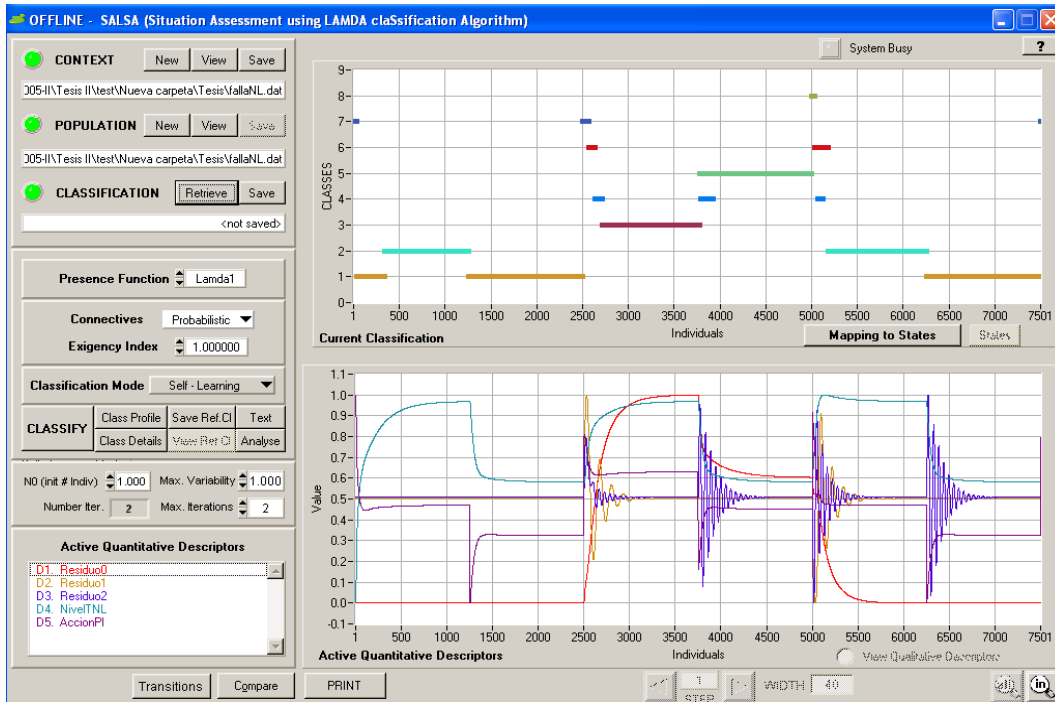


Figura 4 Clases resultantes por los residuos en la variación de A_d . Creación de clases Lamda 1.

En los resultados con clasificación Lamda1 se pueden determinar con facilidad que las dos clases inferiores son generadas por el sistema libre de fallos y las clases superiores con mayor número de individuos son generadas en los momentos donde se presentan las fallas y las restantes por los transientes.

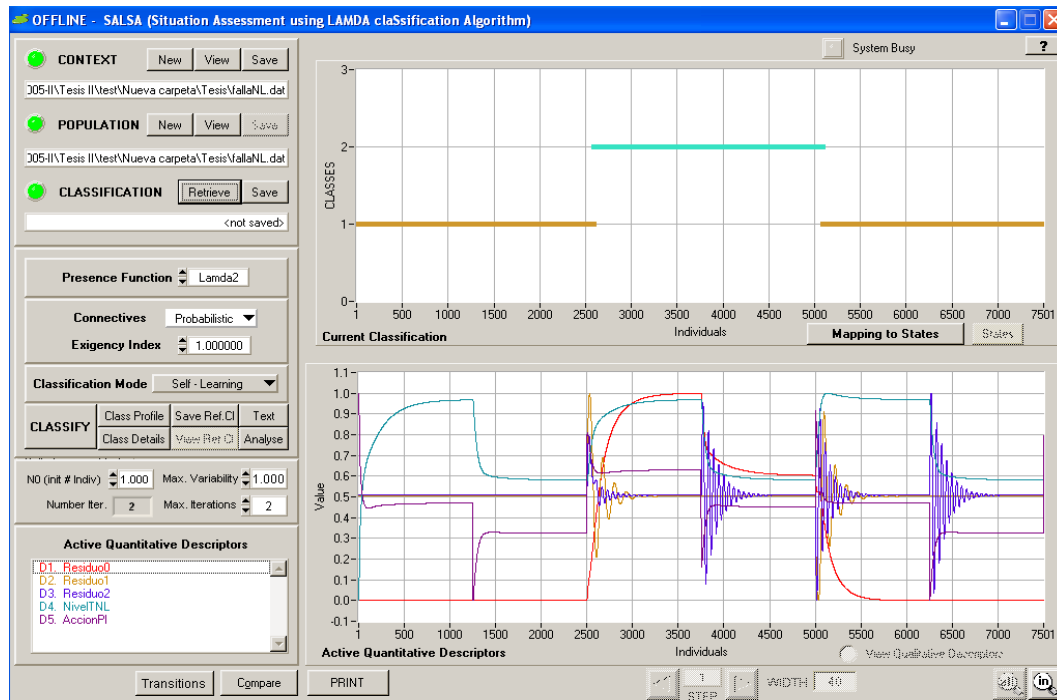


Figura 5 Clases resultantes por los residuos en la variación de A_d . Creación de clases Lambda 2.

Los resultados con clasificación Lambda 2, son mas claras las clases, la inferior determina al sistema libre de fallas y la superior en presencia de la falla.

Como puede ser observado con la adición de los residuos en la clasificación se puede establecer con mayor claridad los instantes en el que la falla se produce.

D. Falla tanque lineal

La falla presentada en el tanque lineal es una falla aditiva, dado que su representación matemática es un término más en las ecuaciones de estado iniciales de la planta.

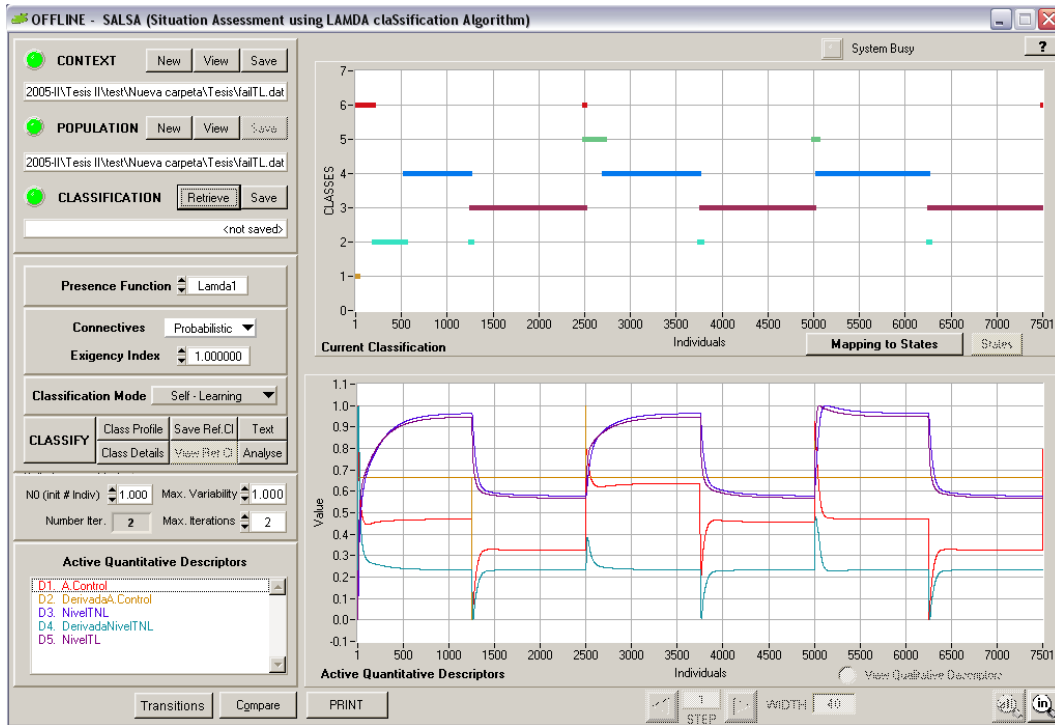


Figura 6 Resultado de la clasificación en ausencia de los residuos.




Figura 7 Residuos generados por la fuga en el tanque lineal.

Los resultados demuestran que ninguno de los residuos es capaz de adaptarse a la falla presentada, para el residuo 1 en el cambio de nivel ($t=15000$) se presenta oscilación menor a las generadas lo que indica que este parámetro no es en el que se presentó la variación del mismo modo que el residuo 2.

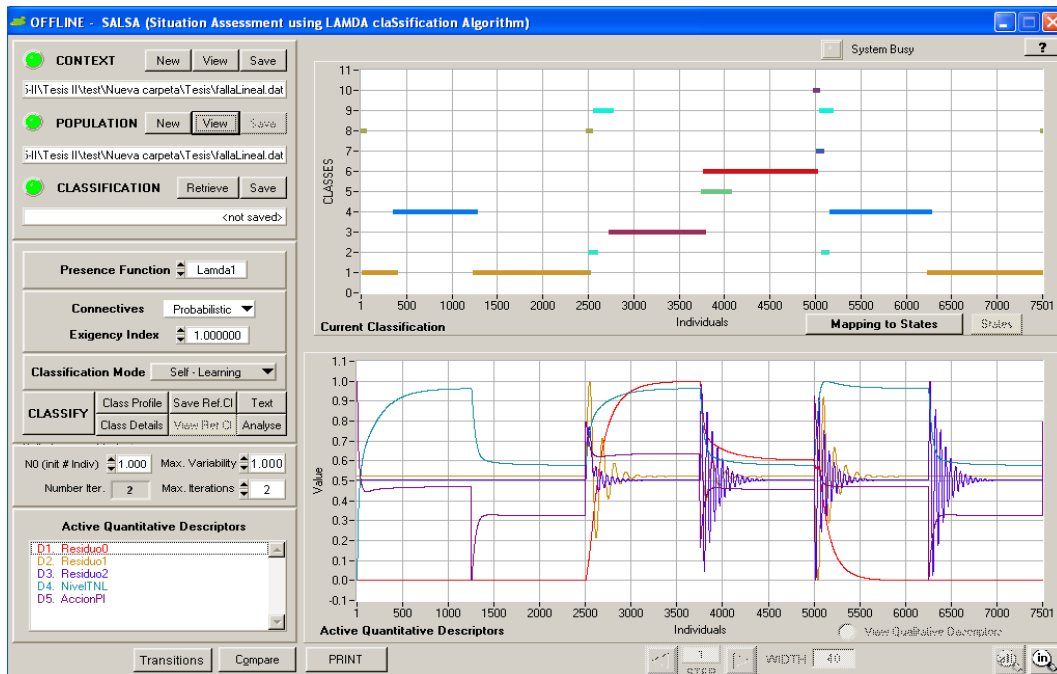


Figura 8 Clases resultantes en el sistema en presencia de fuga en el tanque lineal.

Creación de clases Lamda 1.

En la presencia de cualquiera de las fallas los resultados en las clases son similares, en la fuga presentada en el tanque lineal hay mayor número de clases, con clasificación Lamda 1, pero igual número en la clasificación Lamda 2 para cualquier falla.

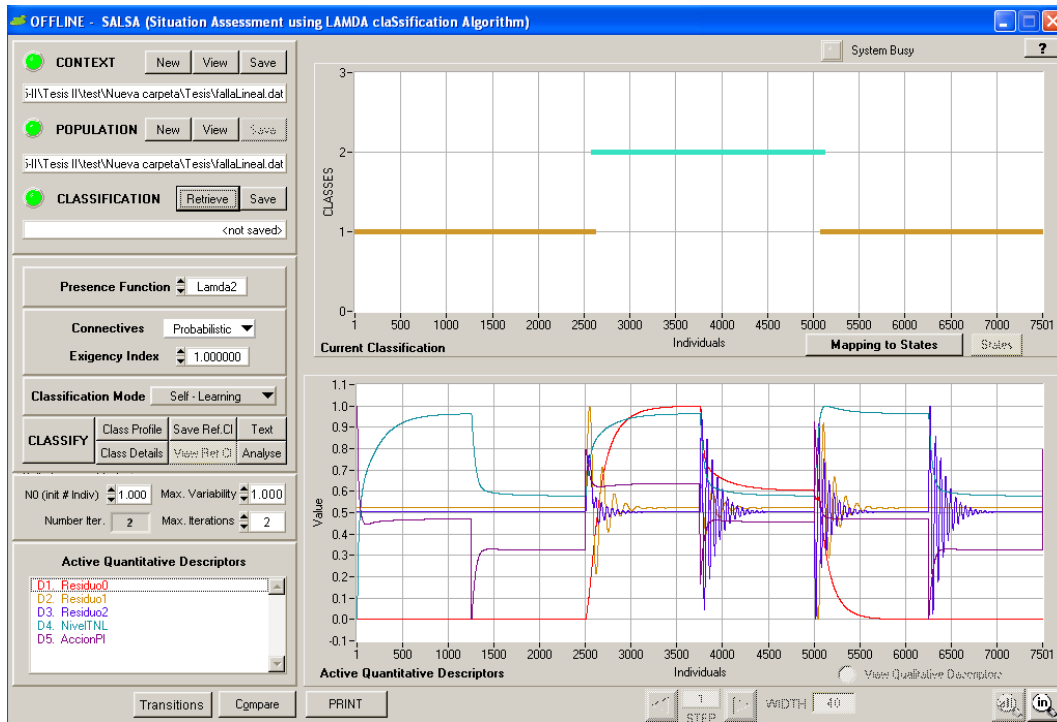


Figura 9 Clases resultantes en el sistema en presencia de fuga en el tanque lineal.

Creación de clases Lamda 2.

6. CONCLUSIONES

Los resultados de las simulaciones han mostrado buen desempeño en la detección de las fallas. La generación de los residuos se ha basado en observadores adaptivos diseñados a partir de observadores de alta ganancia, este método es válido tanto para plantas lineales como No lineales.

Para la detección de fallos en varios parámetros al tiempo se requiere de observadores adaptivos con un mayor número de parámetros lo que lo hace más complicado para su diseño, menos realista y más susceptible a fallos en la interpretación de resultados.

Los resultados de la clasificación LAMDA muestra los instantes en los que se presentan las fallas, de este modo alertar al operador que puede determinar con exactitud la falla observando los resultados generados por los residuos.

El análisis por componentes principales contribuye para minimizar los datos a clasificar sin mayor pérdida de generalidad, para este caso los resultados no difieren mucho al eliminar la variable que por el análisis es la menos representativa.

Existen gran variedad de métodos de clasificación, algunos más antiguos y limitados y otros mas recientes y sofisticados, todos estos y algunos otros más que en este documento

no están presentes permiten generar clasificación de datos de los sistemas dinámicos para de acuerdo al análisis correspondiente determinar los estados funcionales de la planta.

Análisis en componentes principales reduce la dimensionalidad de los datos, aporta una transformación de con menor número de variables sin perder objetividad en gran parte.

Los resultados que se obtienen con los métodos de clasificación dependen de la naturaleza de los datos.

FDI puede detectar fallos como los generados por los sensores y actuadores y son modelados como cambios en parámetros y los observadores pueden ser diseñados para estimar estos parámetros.

FDI puede detectar fallos en presencia o no de ruido, dependiendo la naturaleza y magnitud del mismo.

7. BIBLIOGRAFIA

- [1] ISAZA C., KEMPOWSKY T., AGUILAR J., GAUTHIER A., Clasificación Cualitativa con la Metodología LAMDA, Comparación con dos Técnicas de Clasificación, Universidad de los Andes.
- [2] J. P. Gauthier, H. Hammouri, A simple observer for nonlinear systems applications to bioreactors, *IEEE Trans. On automatic control*, 37 (6):875-880. 1992.
- [3] J. P. Gauthier, A. Kupka, I.A.K. Observability and observers for nonlinear systems. *SIAM Journal Control and Optimization.*, 32 (4):975-994. 1994.
- [4] KEMPOWSKY T., Surveillance de Procédés à base de Méthodes de Classification : Conception d'un Outil d'aide pour la Détection et le Diagnostic des Défaillances. Versión provisional, 2004.
- [5] N. Kabbaj, M. Polit., Adaptive Observers based Fault Detection and Isolation for an Alcoholoc Fermentation Process. 8th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA'2001). 2001.
- [6] Nakkabi, Youssef., Kabbaj, Nabil. A combined analytical and Knowledge based Method for fault detection and isolation. 2003 IEEE Conference on Emergin Technologies and Factory Automation.
- [7] Q. Zhang, Fault detection and Isolation based on adaptive observers for non-linear dynamic systems, publication interne no. 1261, IRISA, Rennes, France, 1999.
- [8] Fandiño, Juan Carlos. Método Lamda para clasificación de estados funcionales y plataforma de clasificación de fallas en procesos industriales. Bogotá 2004. Trabajo de Grado. Universidad de Los Andes.
- [9] Wang, Li. A Course in Fuzzy Systems and Control. Prentice Hall. 1997.
- [10] T. Kourti, Process Analysis and Abnormal Situation Detection: From theory to practice, *IEEE Conrol Systems Magazine*, October, 2002.

Clasificación y Detección de Fallas en Sistemas Dinámicos

Javier Hernando Pardo Mayorga, Alain Gauthier Sellier PhD.
Departamento de Ingeniería Eléctrica y Electrónica
Universidad de los Andes

Abstract—En los sistemas dinámicos se pueden presentar falla en cualquier instante de tiempo, estas fallas pueden ser generadas en gran cantidad de casos por la variación de uno o mas parámetros de la planta o del sistema dinámico. En este trabajo se propone la detección de fallas en una planta no lineal de dos tanques acoplados uno con área constante y variable con la altura basado en observadores adaptivos y sustentado con clasificación LAMDA y análisis de componentes principales. Se presenta la aplicación del algoritmo al control de nivel en una planta no lineal, así como el análisis de resultados, conclusiones y perspectivas futuras.

Palabras claves— Análisis de Componentes Principales, Inecuaciones Lineales Matriciales, método LAMDA de clasificación, Observadores adaptivos.

I. INTRODUCCION

En la actualidad la operación de procesos industriales no solo esta basada en su controlabilidad también en la supervisión y detección de fallas para de este modo aumentar la confiabilidad, seguridad y disminuir costos. La integración de detección de fallos con diagnostico y controladores en los procesos industriales pueden presentar un gran adelanto para la industria.

Detección de fallas y aislamiento (FDI, por sus siglas en ingles) basado en observadores adaptivos se presenta como alternativa para la determinación de los fallos que se presentan en un proceso durante su operación o las degradaciones que se presenten para establecer las acciones correctivas y de mantenimiento necesarias.

El uso de los observadores adaptivos en la determinación de fallas en los sistemas dinámicos es una herramienta valida para modelos por representación de estados, en los casos en el que existen variables que no son medibles el problema de la estimación es un poco más complejo. En este trabajo se propone la utilización de un observador por cada uno de los parámetros a estimar.

Análisis de componentes principales (ACP) es el análisis estadístico que permite la transformación de datos multivariados a un espacio de menos dimensiones sin mayor pérdida de generalidad.

Clasificación LAMDA (Learning Algorithm for Multivariable Data Analysis) es un método de clasificación difusa basada en el grado de adecuación de un elemento a una clase que se puede comparar con el grado de pertenencia de un objeto a un conjunto difuso.

En la segunda parte se muestra la demostración matemática con la que se fundamentan los observadores adaptivos. En la tercera parte se mostraran algunos detalles de la clasificación LAMDA. En la cuarta sección se darán las principales características del análisis de componentes principales. En la quinta parte se trataran el sistema dinámico donde se aplicaron las metodologías. La sexta mostrara los resultados obtenidos. La séptima parte tratará las conclusiones.

II. FAULT DETECTION AND ISOLATION (FDI)

El método es basado en observadores adaptivos para la detección y diagnostico de fallas en sistemas no lineales.

Los cuales podrán determinar la variación de uno o más parámetros [7].

A. Considere el sistema

$$\begin{cases} \dot{x} = f(\theta, x, u) \\ y = h(\theta, x, u) \end{cases} \quad (1)$$

Donde x , y y u son respectivamente los estados, las salidas y las entradas del sistema, f , h son funciones no lineales de x y u caracterizadas por los parámetros θ sujetos a variaciones.

B. Modelamiento de fallas

FDI permite el modelamiento de fallas basado en variaciones de parámetros en el sistema (1) o como parámetros aditivos, en este trabajo se presentaran los dos posibles tipos de fallos.

Los fallos están determinados por variaciones de uno o más parámetros, se asume θ^0 como valores nominales de los parámetros caracterizando así al sistema libre de fallos. Por lo tanto se puede decir que existe una falla cuando hay una desviación en los valores de los parámetros θ^0 , de esta forma el método presentado en este paper puede determinar la presencia de fallas en uno o más parámetros.

C. Observadores para sistemas no lineales

Dado el sistema en la forma (1), el observador es estimador del estado $x(t)$ para observaciones en $u(t)$ y $y(t)$. Entonces el observador es de la forma:

$$\dot{\hat{x}} = \hat{f}(\hat{\theta}^0, \hat{x}, u, y, K) \quad (2)$$

Donde \hat{x} es la estimación de x , \hat{f} es una función no lineal y K es el vector de sintonización de los parámetros θ .

D. Observadores adaptivos

En la presencia de cambios o cuando algunos parámetros de los sistemas no son conocidos, los observadores clásicos no son los mejores para la estimación de estados, los observadores adaptivos pueden ser usados para estimación de estados al mismo tiempo que estimar los parámetros desconocidos, suponiendo que los parámetros θ no son conocidos o son sujetos a cambios el observador es de la forma:

$$\begin{cases} \dot{\hat{x}} = \lambda(\hat{\theta}, \hat{x}, u, y, K_x) \\ \dot{\hat{\theta}} = \beta(\hat{\theta}, \hat{x}, u, y, K_\theta) \end{cases} \quad (3)$$

Donde \hat{x} y $\hat{\theta}$ la estimación de x y θ respectivamente, λ y β son funciones no lineales y K_x y K_θ son las ganancias sintonización.

Es claro que un observador adaptivo puede ser usado tanto para la identificación como la estimación de los parámetros θ en variaciones lentas.

Es más práctica la estimación de un solo parámetro más el estado por observador que varios parámetros más el estado.

Luego de haber determinado la sensibilidad de la predicción del error con un observador ordinario, se puede proceder a estimar los parámetros susceptibles a variaciones con su correspondiente constante de sensibilidad.

De acuerdo a esto se tendrán $n+1$ observadores, un observador ordinario y n observadores adaptivos correspondientes a cada uno de los parámetros susceptibles a variaciones.

E. Diseño de observadores adaptivos, basado en observadores de alta ganancia

Teniendo en cuenta el sistema en (1), asumiendo que $x \in R^n$ y $y \in R$ luego de cambios en las variables de estado, se tiene la forma triangular:

$$\begin{cases} y = h(x_1, u) \\ \dot{x}_1 = f_1(x_1, x_2, u) \\ \dot{x}_2 = f_2(x_1, x_2, x_3, u) \\ \vdots \\ \dot{x}_{n-1} = f_{n-1}(x_1, \dots, x_n, u) \\ \dot{x}_n = f_n(x_1, \dots, x_n, u) \end{cases} \quad (4)$$

Donde $x = (x_1, \dots, x_n)^T$ y $f = (f_1, \dots, f_n)^T$, definiendo:

$$A(t) = \frac{\hat{c}}{\partial t} f(x, u) \quad C(t) = \frac{\hat{c}}{\partial t} h(x_1, u) \quad (5)$$

Entonces existe una matriz semidefinida positiva S tal que $K = S^{-1}(1, 0, \dots, 0)^T$ satisface:

$$(A(t) - KC(t))^T S + S(A(t) - KC(t)) \leq -I \quad (6)$$

y el observador:

$$\dot{\hat{x}} = f(\hat{x}, u) - K(\hat{y} - y) \quad (7)$$

Tiene convergencia exponencial, para cualquier condición inicial $\hat{x}(0)$. (Para mas detalles [2][3][7])

F. Generación de residuos

La operación sin fallos es caracterizada por el vector de valores nominales θ^0 el cual es conocido, sean los residuos definidos como la correspondiente predicción del error:

$$\gamma_o = \hat{y}(\theta^0) - y \quad (8)$$

Sabiendo que para cada parámetro a estimar se tiene un observador y definido de la misma forma su correspondiente residuo es:

$$\gamma_j = \hat{y}(\theta_j^o) - y \quad (9)$$

III. METODOLOGÍA LAMDA

LAMDA, algoritmo de clasificación difusa, permite clasificación cualitativa y cuantitativa, y analiza el grado de adecuación del elemento a cada clase.

MAD_i (Marginal Adequacy Degree) Grado de adecuación marginal, este corresponde a cuanto contribuye el i -ésimo atributo a la clase m . MAD es un vector que muestra la ubicación del elemento con respecto a la clase m .

MAD con atributos cuantitativos.

- Función Binomial

$$MADx_{jm} = \rho_{mj} (1 - \rho_{mj})^{1-x_j} \quad (a)$$

- Función distancia

$$MADx_{jm} = \rho_{mj}^{1-d_{mj}} (1 - \rho_{mj})^{1-d_{mj}} \quad (b)$$

$$d_{mj} = |x_j - c_{mj}| \quad (c)$$

- Función normal

$$MADx_{jm} = \frac{1}{\sigma_{mj}} e^{-\frac{(x_j - \mu_{mj})^2}{2\sigma_{mj}^2}} \quad (d)$$

GADm (Global Adequacy Degree) Grado de adecuación global, se combinan los grados de adecuación marginal mediante operaciones difusas.

Para cada elemento que se va a clasificar se determina el grado de adecuación marginal (GAD) de cada descriptor del individuo, respecto al descriptor de cada clase. [1][4].

IV. ANÁLISIS DE COMPONENTES PRINCIPALES

Análisis de componentes principales es un análisis estadístico que permite la transformación de datos multivariados a un espacio de menos dimensiones sin mayor pérdida de generalidad.

Los nuevos componentes son una combinación lineal de las variables originales y adicionalmente son independientes.

En la interpretación de los resultados es importante el conocimiento que posea el experto sobre el proceso dado el análisis de magnitud y signo de las correlaciones de las variables iniciales.

V. SISTEMA DE TANQUES ACOPLADOS

El sistema dinámico a analizar consiste en dos tanques acoplados, uno con área transversal constante dependiendo de la altura y otro cuya área varía dependiendo de la altura.




Ilustración 1 Diagrama de los tanque acoplados.

El sistema corresponde a dos tanques, una bomba que alimenta al sistema con agua, una salida en el tanque de área variable dependiendo de la altura y dos válvulas en cada uno de los tanques que simulan fugas en el sistema, esta fugas serán las fallas que se pueden presentar.

Área Tanque lineal

$$A_{tl} = 121\text{cm}^2 \quad (10)$$

Área Tanque no Lineal

$$A_{nl} = \begin{cases} 0\text{cm} \leq h_2 < 10\text{cm} & \Rightarrow 100\text{cm}^2 \\ 10\text{cm} \leq h_2 < 20\text{cm} & \Rightarrow \{10[21 + 2(h_2 - 10)]\}\text{cm}^2 \\ 20\text{cm} \leq h_2 < 30\text{cm} & \Rightarrow \{10[21 - 2(h_2 - 20)]\}\text{cm}^2 \\ 30\text{cm} \leq h_2 < 40\text{cm} & \Rightarrow 200\text{cm}^2 \end{cases} \quad (11)$$

A. Ecuaciones de la dinámica del sistema

$$\begin{cases} \dot{h}_1 = \frac{q_1}{A_{tl}} - \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{tl}} \\ \dot{h}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{A_d \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} \end{cases} \quad (12)$$

B. Sistema más fallas

$$\begin{cases} \dot{h}_1 = \frac{q_1}{A_{tl}} - \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{tl}} - \frac{A_{f1l} \cdot \sqrt{2 \cdot g \cdot h_1}}{A_{tl}} \\ \dot{h}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{(A_d + A_{f2l}) \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} \end{cases} \quad (13)$$

Nótese que en la primera ecuación de estado la falla es aditiva y en la segunda se puede modelar como la variación de un parámetro.

Sea el observador ordinario:

$$\begin{cases} \dot{\hat{h}}_1 = \frac{q_1}{A_{tl}} - \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{tl}} - K_1(\hat{h}_2 - h_2) \\ \dot{\hat{h}}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{A_d \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} - K_2(\hat{h}_2 - h_2) \end{cases} \quad (14)$$

Y los observadores adaptivos:

Observador 1

$$\begin{cases} \dot{h}_1 = \frac{q_1}{A_{il}} - \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{il}} - K_1(\hat{h}_2 - h_2) \\ \dot{h}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{\theta_1 \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} - K_2(\hat{h}_2 - h_2) \\ \hat{\theta}_1 = K_{\theta_1}(\hat{h}_2 - h_2) \end{cases} \quad (15)$$

Observador 2

$$\begin{cases} \dot{h}_1 = \frac{q_1}{A_{il}} - \frac{\theta_2 \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{il}} - K_1(\hat{h}_2 - h_2) \\ \dot{h}_2 = \frac{A_a \cdot \sqrt{2 \cdot g \cdot (h_1 - h_2)}}{A_{nl}} - \frac{A_d \cdot \sqrt{2 \cdot g \cdot h_2}}{A_{nl}} - K_2(\hat{h}_2 - h_2) \\ \hat{\theta}_2 = K_{\theta_2}(\hat{h}_2 - h_2) \end{cases} \quad (16)$$

Y los residuos:

Observador ordinario:

$$\gamma_0 = \hat{y}(\theta^o) - y \quad (17)$$

Y de los observadores adaptivos.

$$\gamma_1 = \hat{y}(\theta_1^o) - y \quad \gamma_2 = \hat{y}(\theta_2^o) - y \quad (18)$$

VI. ANÁLISIS DE RESULTADOS

Los resultados están basados en la clasificación con la metodología LAMDA de los residuos generados por los observadores adaptivos y el ordinario, la acción del controlador y el nivel de referencia, posterior al análisis de componentes principales para realizar la reducción de variables a ser analizadas.

$$\begin{aligned} A_a &= 0.317 & A_{fil} &= 0.0396 & A_d &= 0.173 & A_{fil} &= 0.0432 \\ K_1 &= 0.0086 & K_2 &= 6.0505e-6 & K_{\theta_1} &= -0.0009 \\ K_{\theta_2} &= -0.00030425 \end{aligned} \quad (19)$$

Teniendo en cuenta el cálculo del MAD.

MAD con atributos cuantitativos:

- Lamda 1

$$\rho^x \cdot (1 - \rho)^{1-x} \quad (20)$$

- Lamda 2

$$K \cdot \rho^x \cdot (1 - \rho)^{1-x} \quad K = \frac{\log\left(\frac{\rho}{1-\rho}\right)}{2 \cdot \rho - 1} \quad (21)$$

- Lamda 3

$$\rho^{1-x-d} \cdot (1 - \rho)^{x-d} \quad (22)$$

- Lamda 4

$$K \cdot \rho^{1-x-d} \cdot (1 - \rho)^{x-d} \quad ,$$

$$K = \frac{\log\left(\frac{\rho}{\rho-1}\right)}{2 \cdot \rho - \rho^c \cdot (1 - \rho)^{x-d} - \rho^{1-c} \cdot (1 - \rho)^{1-d}} \quad (23)$$

- Gauss 1

$$e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (24)$$

- Gauss 2

$$K \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad K = \frac{\sigma_o}{\sigma} \quad (25)$$

Sea la acción de control:




Figura 1 Referencia de entrada al controlador, variación del nivel de 25 cms a 10 cms. Cada 5000 s.

A. Falla tanque no lineal

La falla en el tanque no lineal se presenta cuando la válvula correspondiente es activada, esta falla es modelada como la variación del valor del área que determina el caudal de salida. La variación del parámetro se presenta en $t=10000$ y desaparece en $t=20000$,




Figura 2 Residuos generados por la variación de A_d .

El residuo generado por el observador ordinario muestra la presencia de la variación de un parámetro entre $t=10000$ y 20000 . El residuo generado por el observado adaptivo del parámetro A_d muestra que entre el tiempo 10000 y 11000 , el observador detecta la falla y se adapta el parámetro a esta. El tercer residuo detecta la falla, empieza a realizar la adaptación de la misma, pero en las variaciones del nivel se presentan oscilaciones que muestran que el parámetro A_d no en el que se presento la falla.

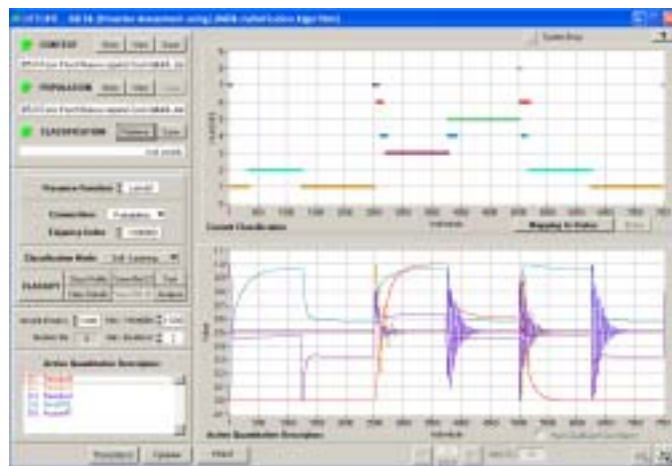


Figura 3 Clases resultantes por los residuos en la variación de A_d . Creación de clases Lamda 1.

En los resultados con clasificación Lamda1 se pueden determinar con facilidad que las dos clases inferiores son generadas por el sistema libre de fallos y las clases superiores con mayor número de individuos son generadas en los

momentos donde se presentan las fallas y las restantes por los transientes.

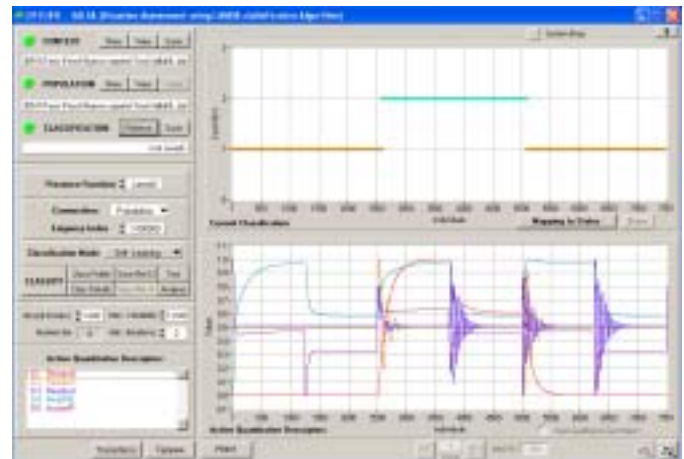


Figura 4 Clases resultantes por los residuos en la variación de A_d . Creación de clases Lamda 2.

Los resultados con clasificación Lamda 2, son mas claras las clases, la inferior determina al sistema libre de fallas y la superior en presencia de la falla.

B. Falla tanque lineal




Figura 5 Residuos generados por la fuga en el tanque lineal.

Los resultados demuestran que ninguno de los residuos es capaz de adaptarse a la falla presentada, para el residuo 1 en el cambio de nivel ($t=15000$) se presenta oscilación menor a las generadas lo que indica que este parámetro no es en el que se presentó la variación del mismo modo que el residuo 2.

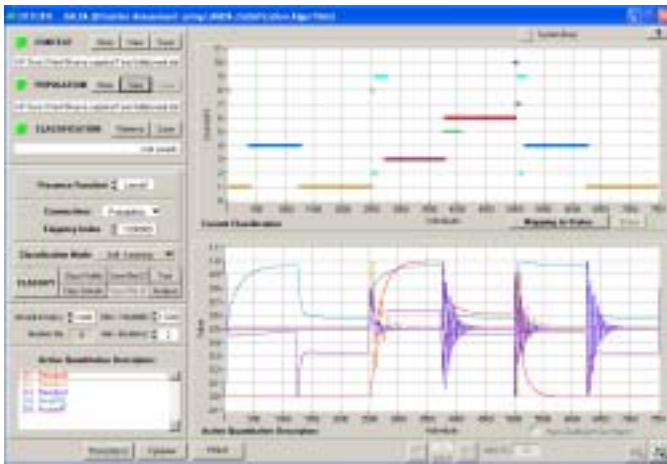


Figura 6 Clases resultantes en el sistema en presencia de fuga en el tanque lineal. Creación de clases Lamda 1.

En la presencia de cualquiera de las fallas los resultados en las clases son similares, en la fuga presentada en el tanque lineal hay mayor número de clases, con clasificación Lamda 1, pero igual número en la clasificación Lamda 2 para cualquier falla.

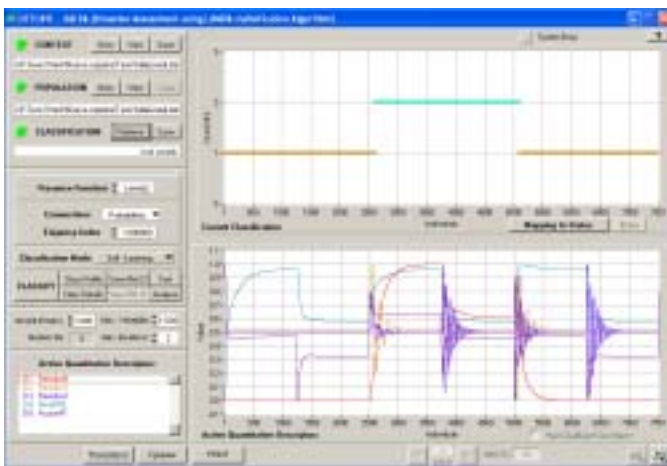


Figura 7 Clases resultantes en el sistema en presencia de fuga en el tanque lineal. Creación de clases Lamda 2.

VII. CONCLUSIONES Y PERSPECTIVAS

Los resultados de las simulaciones han mostrado buen desempeño en la detección de las fallas. La generación de los residuos se ha basado en observadores adaptivos diseñados a partir de observadores de alta ganancia, este método es válido tanto para plantas lineales como No lineales.

Para la detección de fallos en varios parámetros al tiempo se requiere de observadores adaptivos con un mayor número de parámetros lo que lo hace más complicado para su diseño, menos realista y más susceptible a fallos en la interpretación de resultados.

Los resultados de la clasificación LAMDA muestra los instantes en los que se presentan las fallas, de este modo

alertar al operador que puede determinar con exactitud la falla observando los resultados generados por los residuos.

El análisis por componentes principales contribuye para minimizar los datos a clasificar sin mayor pérdida de generalidad, para este caso los resultados no difieren mucho al eliminar la variable que por el análisis es la menos representativa.

REFERENCIAS

- [1] ISAZA C., KEMPOWSKY T., AGUILAR J., GAUTHIER A., Clasificación Cualitativa con la Metodología LAMDA, Comparación con dos Técnicas de Clasificación, Universidad de los Andes.
- [2] J. P. Gauthier, H. Hammouri, A simple observer for nonlinear systems applications to bioreactors, IEEE Trans. On automatic control, 37 (6):875-880. 1992.
- [3] J. P. Gauthier, A. Kupka, I.A.K. Observability and observers for nonlinear systems. SIAM Journal Control and Optimization., 32 (4):975-994. 1994.
- [4] KEMPOWSKY T., Surveillance de Procédés à base de Méthodes de Classification : Conception d'un Outil d'aide pour la Détection et le Diagnostic des Défaillances. Versión provisional, 2004.
- [5] N. Kabbaj, M. Polit., Adaptive Observers based Fault Detection and Isolation for an Alcoholoc Fermentation Process. 8th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA'2001). 2001.
- [6] Nakkabi, Youssef., Kabbaj, Nabil. A combined analytical and Knowledge based Method for fault detection and isolation. 2003 IEEE Conference on Emergin Technologies and Factory Automation.
- [7] Q. Zhang, Fault detection and Isolation based on adaptive observers for non-linear dynamic systems, publication interne no. 1261, IRISA, Rennes, France, 1999.

Javier Hernando Pardo Mayorga Estudiante de último semestre de Magíster en Ingeniería Electrónica y Computadores en la Universidad De Los Andes. Este documento hace parte de la tesis de Maestría para optar al título de Magíster en Ingeniería Electrónica y Computadores. Su principal área de interés es el control y la automatización industrial además de su experiencia en sistemas de telefonía celular y administración de redes de networking en proceso de certificación CCNA (Cisco Certified Network Associate).

ja-pardo@uniands.edu.co

Alain Gauthier Sèller
agauthie@uniandes.edu.co