

**METHODOLOGIES AND TECHNOLOGIES OF FAULT DETECTION AND
DIAGNOSIS APPLIED TO INDUSTRIAL PROCESSES****METODOLOGIAS Y TECNOLOGIAS DE DETECCION Y DIAGNOSTICO DE
FALLAS APLICADAS A PROCESOS INDUSTRIALES****MSc. Sandra Aranguren Zambrano, PhD. Rocco Tarantino Alvarado**

Universidad de Pamplona, Facultad de Ingenierías y Arquitectura
Investigación y Desarrollo de Tecnologías Avanzadas, IIDTA.
Ciudadela Universitaria. Pamplona, Norte de Santander, Colombia.
Tel.: 57-7-5685303 Ext. 164
E-mail: {saranguren, roccot}@unipamplona.edu.co

Abstract: The design of detection systems and fault diagnosis applied to industry, it requires prior knowledge of the levels of risk and criticality of each of its plants and equipment, as well as the dynamic characteristics of processes, number of input and output signals for each critical variable in order to determine which method or technique is more appropriate to apply. This paper presents theory, algorithms, applications and infrastructure deployment of some technologies and methodologies used for fault detection and diagnosis in industrial processes.

Resumen: En el diseño de los sistemas de detección y diagnóstico de fallas aplicados a la industria, se requiere del conocimiento previo de los niveles de riesgo y criticidad de cada uno de sus plantas y equipos, así como también de las características dinámicas de los procesos, número de señales de entrada y salida por cada variable crítica, con el fin de determinar que método o técnica es más apropiada aplicar. En este artículo se presentan fundamentos teóricos, algoritmos, aplicaciones e infraestructura de implantación de algunas metodologías y tecnologías más utilizadas para detección y diagnóstico de fallas en procesos industriales.

Keywords : Methodologies, Technologies, Detection, Diagnosis, Fault.

1. INTRODUCCION

Las fallas son acciones internas e impredecibles que ocurren dentro del sistema, autogenerada por el mal funcionamiento de uno o más componentes y que pueden llevar al mismo a un estado no deseado. Las fallas pueden ocurrir en diferentes tipos de sistemas de manera que el comportamiento en el tiempo puede ser descrito por medio de señales con ruidos, intermitentes, permanentes, transitorias y derivadas. En equipos electrónicos y software se muestran fallas sistemáticas, originadas

por malas especificaciones de diseño: tierra, códigos, lógica, cálculos, sobre flujos, entre otros. Las fallas en los sistemas mecánicos se pueden clasificar dentro de las fallas de mecanismos: distorsión (deformación), fatiga y fractura (fatiga cíclica y térmica), desgastes (abrasiva, adhesiva, cavitación) o corrosión (galvánica, química o biológica). En los sistemas eléctricos encontramos fallas como son: cortos circuitos, pérdidas o conexiones rotas, cambios en los parámetros, problemas en los contactos, contaminación. Estas fallas normalmente son aleatorias (Iserman, 2000).

Las fallas pueden ser detectadas utilizando distintos métodos y técnicas de detección y diagnóstico, y pueden ser aplicadas dependiendo de las características dinámicas del sistema y del número de señales disponibles por variable. Existen muchos métodos de detección de fallas, tales como: a. Chequeo de Límites y Detección de Cambios: Chequeos de Tendencias, Estimación de Media, Varianza y Pruebas Estadísticas b. Señales Modelos: Análisis para Señales Periódicas: Filtros Pasabanda, Análisis de Fourier, Transformada de Fourier, entre otras. Análisis para Señales Periódicas No Estacionaria: Transformada Wavelet. Análisis de Señales Estocásticas: Análisis de Espectrum, Correlación. Análisis de Vibración de Máquinas.

Detección de fallas por medio de Métodos de Identificación de Procesos, como son: Funciones de Correlación de Estimación, Estimación de Parámetros para procesos lineales y no lineales. Detección de Fallas con Ecuaciones de Paridad, Observadores de Estado, Estimación de Estados, Detección de Fallas en Lazos de Control, Detección de Fallas por medio de Análisis de Componentes Principales. Detección por Automatas y Redes de Petri y todas las posibles combinaciones entre estos métodos. (Blanke et al, 2006), (Iserman, 2006)

Entre los métodos de diagnóstico tenemos: Clasificación de Bayes, Clasificación Polinomial, Árboles de Decisión, Redes Neuronales. Métodos de Inferencia como Lógica Difusa, Sistemas Híbridos Neuro-Difusos, entre otros. En este trabajo sólo se van a describir algunos de estos métodos y técnicas de detección y diagnóstico de fallas, sus fundamentos teóricos, algoritmos, aplicaciones e infraestructura de implantación aplicados a los procesos industriales.

2. METODOLOGIAS DE DETECCION Y DIAGNÓSTICOS DE FALLAS

2.1 Análisis Espectral

Fundamento o principio: Algunas equipos exhiben un espectro de frecuencia típica sobre condiciones de operaciones normal; cualquier desviación de éste es una indicación de anomalías o fallas. Ciertos tipos de fallas pueden tener características repetitivas en el espectro y facilitar el diagnóstico. El espectro de una señal se determina por medio de la Transformada de Fourier Discreta, (TFD). La TFD transforma una secuencia ordenada de datos

muestreados del dominio de tiempo al dominio de la frecuencia de manera que la información acerca de esa secuencia de datos pueda ser conocida explícitamente. (Pouliezos and Stavrakakis, 1994)

Expresión Matemática: La transformada directa de Fourier de un vector de datos provenientes de una señal. Esta dada por,

$$X_m = \sum_{k=0}^{N-1} x_k e^{-j(2\pi mk/N)} \quad m=0,1, 2,\dots, N/2, \quad (1)$$

Donde,

X_m : es la transformada discreta de Fourier de x_k .

m : es el índice de la frecuencia de cada componente de X_m .

x_k : es la secuencia de datos de una señal real.

k : es el índice del tiempo, $k=0,\dots,N-1$.

N : es el tamaño de la muestra.

$e^{-j(2\pi mk/N)}$: es una función sinusoidal compleja periódica.

Algoritmo:

En la figura 1. Se muestra el diagrama de flujo propuesto para detectar y diagnósticas fallas por medio de la transformada de Fourier.

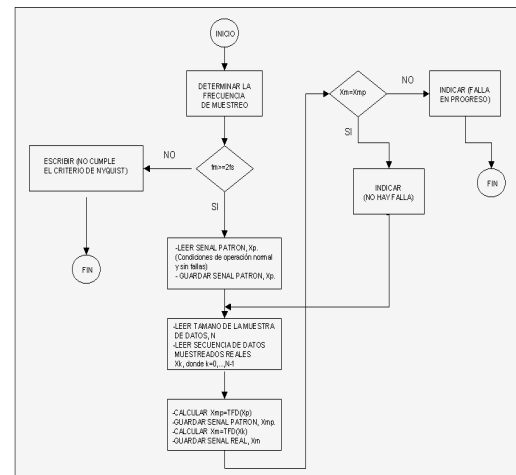


Fig. 1. Diagrama de Flujo por Análisis Espectral

Aplicaciones: - Detección y diagnóstico de fallas por vibraciones en el espectro de la señal de máquinas rotativas, ya sea por excitaciones internas (comportamientos involuntarios) o por excitaciones externas como desbalance de masas, desalineación, roce en cojinetes de la máquina vibrante, entre otros.

Infraestructura de Implantación: Una vez instrumentada la máquina con los respectivos

sensores de vibración, estas señales podrán ser monitoreadas por el sistema de control distribuido (DCS) y guardadas en una base de datos.

Los datos almacenados pueden ser analizados por el programa de simulación Matlab®, el cual interactúa tanto con las bases de datos como con el sistema de monitoreo de detección y diagnóstico de fallas. MatLab permite calcular la transformada discreta de Fourier y obtener los espectros de las señales que serán después comparadas con las señales patrones que servirá como modelo en el momento de detectar y diagnosticar fallas (ver figura 2). (Aranguren, 2001),

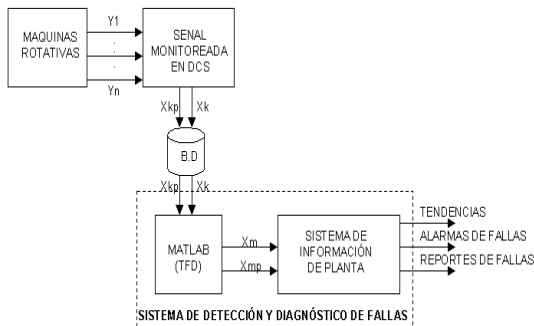


Fig. 2. Diagrama de Bloques para la TFD.

2.2 Distribuciones Probabilísticas

Fundamento o principio: La función de densidad de la distribución normal o Gaussiana permite estudiar la distribución de los errores o desviaciones (fallas) respecto al promedio aritmético. El gráfico de la distribución normal tiene la forma de una campana donde la mayor frecuencia de valores se encuentra en el centro coincidiendo con la media aritmética y sus extremos se acercan al eje horizontal sin que lleguen a unirse. Los datos se distribuyen simétricamente respecto a la media aritmética. La distribución normal esta completamente determinada en su forma y localización con los parámetros s y m , la desviación estándar y la media respectivamente. (Aranguren, 2001)

Expresión Matemática: La función de densidad de probabilidad de una variable simple distribuida normalmente está representada como :

$$f_x(\mathbf{x}) = \frac{1}{\sqrt{(2p)S_x}} \exp \left[-\frac{(\mathbf{x} - \mathbf{m}_x)^2}{2S_x^2} \right] \quad (2)$$

Donde,

$f_x(\mathbf{x})$: es la función de densidad de probabilidad de la variable aleatoria $x(t)$ de valor \mathbf{X} .

\mathbf{m}_x : es la media de $x(t)$.

S_x^2 : es la varianza de $x(t)$.

S_x : es la desviación estándar de $x(t)$.

Un caso especial de la distribución normal es la distribución normal estandarizada la cual tiene $\mathbf{m}_x=0$ y $S_x=1$. La función de densidad de probabilidad es:

$$f_x(\mathbf{x}) = \frac{1}{\sqrt{(2p)}} \exp \left[-\frac{\mathbf{x}^2}{2} \right] \quad (3)$$

Algoritmo:

1. Determinar el tamaño de la muestra (N), la ventana de observación y la frecuencia de muestreo.
2. Determinar la frecuencia de ocurrencia de los valores.
3. Leer datos (muestra) de tamaño N.
4. Guardar en un vector los datos leídos.
5. Realizar procedimiento de búsqueda para comparar y contar la ocurrencia de cada uno de los valores observados.
6. Guarda en una matriz cada valor observado con su respectiva frecuencia.
7. Calcular la media de los datos de tamaño N y la desviación estándar.
8. Estandarizar los valores observados utilizando la ecuación de transformación de la función de distribución normal estandarizada $z = X - \mathbf{m}/S$, donde X es cada uno de los valores observados \mathbf{m} , la media de la muestra de tamaño N y S , la desviación estándar de la muestra.
9. Guardar en una matriz cada uno de los valores observados, su correspondiente valor estandarizado y la frecuencia de ocurrencia.
10. Graficar los valores estandarizados Vs. la frecuencia de ocurrencia de cada uno de estos.
11. Unir cada uno de los puntos obtenidos de la intersección (valores estandarizados Vs frecuencia) y de esta manera se obtendrá la gráfica de la función de distribución normal estandarizada.
12. Este procedimiento sirve para determinar tanto la gráfica la función de distribución normal estandarizada modelo ($\mathbf{m}_x=0$ y $S_x=1$) como la gráfica de la función de distribución normal estandarizada de los datos reales obtenida en cada ventana de observación.
13. Se visualizarán sobre la misma gráfica tanto la curva de la función de distribución normal

estándar modelo ($m=0, s=1$), como la curva de la distribución normal estandarizada real.

14. Si no se solapan indica fallas en progreso, de lo contrario, volver al paso 2.
15. Guardar los valores de las gráficas con sesgo y junto con la información suministrada por los expertos de las fallas ocurridas, permitirán crear una base de dato que servirán como patrón al momento de diagnosticar la falla detectada.

El residual se analizó utilizando una función de distribución normal. Cuando exista algún tipo de sesgo en la función de distribución o se produzca una corrida de la media de los datos, estamos en presencia de fallas incipientes

Aplicaciones: La dispersión de los datos detecta cambios y fallas de curvas características de los equipos. Puede diagnosticar desgaste en componentes móviles.

Infraestructura de Implantación:

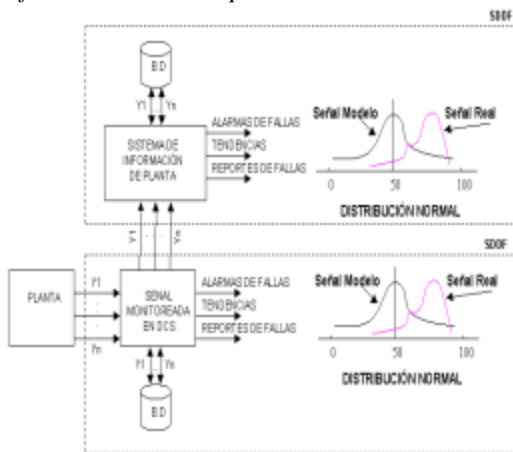


Fig. 3 Infraestructura de Implantación Utilizando Distribución Probabilística.

2.3 Gráficos de Control Estadístico

Fundamento o principio: Se basa en el muestreo constante de una variable que se encuentra bajo control. Este gráfico puede ser utilizado para detectar fallas en progreso, ya que permite registrar las variaciones que sobrepasan cualquier diferencia natural en el proceso durante un período determinado (variaciones por causa asignable).

Existen diferentes tipos de gráficos de control que ayudan a detectar las variaciones por causa asignable, como son: el gráfico \bar{X} , que tienen por objeto medir la variación de las medias muestrales

y el gráfico R que mide la variación del recorrido o rango de las muestras. (Aranguren, 2001)

Determinación del Gráfico \bar{X}

El gráfico \bar{X} se utiliza para medir la variación de las medias muestrales en torno a un valor generalmente aceptado. Como indica la figura 4, se establece un límite superior de control ($UCL_{\bar{X}}$) y un límite inferior de control ($LCL_{\bar{X}}$) a uno y otro lado de una medida aceptable, que se identifica con la media general y \bar{X} de varias medias muestrales. El valor de \bar{X} , sirve de estimación para m

Si las medias muestrales caen dentro del rango aceptable se dice que sólo existe variación aleatoria. Pero si las medias muestrales son superiores a $UCL_{\bar{X}}$ o inferiores $LCL_{\bar{X}}$, el proceso ha detectado una variación por causa asignable, por lo tanto estamos en presencia de una falla incipiente.

Así pues,

$$UCL_{\bar{X}} = \bar{X} + 3s_{\bar{X}} \tag{4}$$

y

$$LCL_{\bar{X}} = \bar{X} - 3s_{\bar{X}} \tag{5}$$

En la práctica $3s_{\bar{X}}$ se estima como $A_2\bar{R}$ donde \bar{R} es el recorrido medio de varias muestras y A_2 es una constante basada en el tamaño de la muestra. Los valores de A_2 se extrae de la tabla de factores críticos para gráficos de control. Cuando se utiliza $A_2\bar{R}$ en lugar de $3s_{\bar{X}}$ se obtienen resultados semejantes y el cálculo es bastante más sencillo. Entonces tendremos:

$$UCL_{\bar{X}} = \bar{X} + A_2\bar{R} \tag{6}$$

$$y \ LCL_{\bar{X}} = \bar{X} - A_2\bar{R} \tag{7}$$




Fig. 4 Gráfica de Medias.

Determinación del Gráfico R : El gráfico R es un indicador de la variación de la dispersión de las mediciones dentro del proceso.

Para el recorrido se calculan un límite inferior de control (LCL_R) y un límite superior de control (UCL_R) que, como los del gráfico \bar{X} , tiene tres errores típicos por encima y por debajo de la media. En principio, se determinan del modo siguiente: (ver figura 5)

$$UCL_R = \bar{R} + 3s_R \quad (8)$$

y

$$LCL_R = \bar{R} - 3s_R \quad (9)$$

Donde s_R es la desviación típica de los recorridos muestrales. Otra manera de determinar los límites es utilizando la siguiente expresión:

$$UCL_R = D_4 \bar{R} \quad (10)$$

y

$$LCL_R = D_3 \bar{R} \quad (11)$$

Los valores de D_4 y D_3 se toman de tablas.




Fig. 5. Gráfico de Rango

Algoritmo:

1. Leer datos de entrada de la(s) variable(s), e inicializar variables, contador = 0.
2. Dividir la muestra de tamaño N en submuestras mayores o igual que 30.
3. Calcular el promedio de cada submuestra.
4. Obtener el promedio de las medias de las submuestras.
5. Calcular el rango para cada una de las submuestras
6. Obtener el promedio de los rangos de las submuestras.
7. Calcular los límites de control para los gráficos de la media móvil, a partir de las ecuaciones (6) y (7).

8. Calcular los límites de control para los gráficos del rango móvil, a partir de las ecuaciones (10) y (11).
9. Construir una matriz con los siguientes columnas: en la columna 1 se enumera los subgrupos, de la columna 2 hasta la columna i se representa la media de cada una de las submuestras. En la columna i+1, se representa el valor promedio de la media de las submuestras $\bar{\bar{X}}$. En la columna i+2 contiene el recorrido máximo de la variable (diferencia entre el valor menor y mayor de las submuestras).
10. Construir los gráficos de media y de rangos.
11. Si los valores observados de la variable medida sobrepasan los límites de control entonces el contador se incrementa. Si el contador = 7 valores por encima o por debajo de los límites de control entonces enviar mensaje ("Falla en Progreso"), de lo contrario contador = 0 y actualizar datos (regresar al paso 1).

Infraestructura de Implantación: Los diferentes estados de las variables, de los instrumentos como de los equipos de las plantas son monitoreados y controlados por el Sistema de Control Distribuido. Estos datos son obtenidos por medio de una red de área local y almacenada en una base de datos en tiempo real del Sistema de Información de Planta (PI). El sistema PI contiene dos módulos el PI-Datalink y el PI-ProcessBook. Para la implantación del SDDF se utilizan los dos módulos, el PI-Datalink para proporcionar un enlace dinámico entre el sistema PI y la hoja de cálculo en Microsoft Excel, permitiendo acceder rápidamente a los datos actuales e históricos, y el PI-ProcessBook, como una interfaz gráfica donde se interpreta la información del sistema PI, se muestran esquemáticos y las tendencias del proceso.

2.4 Generación de residual

Fundamento o principio: un generador de residual es un algoritmo dinámico, lineal y discreto, que basado en conceptos geométricos produce un vector de residuales (ver figura 6).




Fig. 6 Generador Genérico de Residuales

Expresión Matemática:

Es importante aclarar que los sistemas de detección aquí descritos, están basados en un vector innovación $\mathbf{g}(t)$, siendo su expresión matemática

$$\mathbf{g}(t) = V(\mathbf{f})u(t) + W(\mathbf{f})y(t), \quad (12)$$

Donde,

$\mathbf{g}(t)$: representa el vector innovación de residuales.

$V(\mathbf{f}), W(\mathbf{f})$: son matrices de transferencia o funciones de transferencia matriciales o mapas de aplicación.

Para que se cumpla que

$$\mathbf{g}(t) = 0 \Rightarrow V(\mathbf{f})u(t) = -W(\mathbf{f})y(t), \quad (13)$$

$$\text{Si } y(t) = M(\mathbf{f})u(t), \quad (14)$$

Donde, $M(\mathbf{f})$ es la función de transferencia del sistema.

$$\text{Tenemos } V(\mathbf{f}) = -W(\mathbf{f})M(\mathbf{f}). \quad (15)$$

Sustituyendo la ecuación (15) en la ecuación (12) tenemos,

$$\mathbf{g}(t) = W(\mathbf{f})[y(t) - M(\mathbf{f})u(t)] \quad (16)$$

La ecuación (16) representa el algoritmo de un generador de residual geométrico. (Gertler, 1998)

Infraestructura de implantación:

La implantación de residuales geométricos está intrínsecamente relacionada con la infraestructura computacional sobre la cual se soporta.

Para sistemas de dinámica lenta, es posible que los algoritmos de detección y diagnóstico residan en computadores de alto nivel jerárquico (nivel supervisorio o nivel de planificación), cuyo tiempo de muestreo y cálculo de la variable no sea un compromiso. El criterio debe estar soportado por la mínima frecuencia de muestreo requerida para la recuperación de la información.

Para sistema con dinámica rápida se recomienda ubicar el cálculo del algoritmo a niveles de baja jerarquía (nivel de control), ejemplo DCS, o computadores dedicados localmente en campo; de esta forma se asegura que los tiempos de muestreo pueda observar cambios de naturaleza rápida o abrupta.

2.4.1 Relaciones de Paridad

a. Fundamento o principio: Este método usado para la detección y diagnóstico de fallas, básicamente establece esquemas de redundancia para examinar la consistencia de la información obtenida bien por medición directa de las variables, o a partir de relaciones analíticas indirectas de la misma variable.

Típicamente existen dos arreglos de relaciones de paridad, utilizados para fines de detección y diagnóstico de fallas; uno de ellos es el uso de sensores/transmisores, los cuales tienen funciones de medición idénticas o similares de la misma variable del proceso, el otro uso típico es el utilizar sensores/transmisores que miden variables distintas, pero sus medidas o valores están relacionado uno con otro, debido a la misma fenomenología interna del proceso que están midiendo. La idea básica del método de relaciones de paridad, es facilitar la revisión de la consistencia entre las variables medidas del sistema en estudio. (Patton, 1999).

Expresión Matemática:

Para evaluar matemáticamente este método, consideremos el problema general de medir un sistema n-dimensional, utilizando m sensores/transmisores. La ecuación (algebraica) para esta medición está dada por:

$$y(k) = Cx(k) + f(k) + \mathbf{x}(k), \quad (17)$$

Donde,

$y(k) \in \mathfrak{R}^m$: representa el vector de medidas (salidas del sistema).

$x(k) \in \mathfrak{R}^n$: representa el vector de estado.

$f(k)$: es el vector de fallas, el cual se supone aditivo. Este vector representa las fallas que ocurren únicamente en los sensores/transmisores.

$\mathbf{x}(k)$: representa el vector de ruido de cada medida.

C : es el mapa de proyección del vector de estado $x(k)$ hacia el espacio de salida o vector de medidas $y(k)$.

Caso: Residual Físico

Fundamento o principio: Consiste en aprovechar la redundancia física existente en transmisores midiendo la misma cantidad física del proceso para detectar fallas. Cualquier discrepancia seria entre las mediciones indica fallas en los transmisores. Si tenemos solamente dos sensores en paralelo, el diagnóstico no es posible, en cambio si contamos

con tres sensores/transmisores, un esquema de votación puede ser formado para separar las fallas en los mismos.

Expresión Matemática:

El diseño de sistemas de detección y diagnóstico de fallas basado en residuales físicos, supone la generación de dicho residual como resultado de la comparación de al menos dos señales disponible físicamente siendo $\mathbf{g}(t)$ el vector residual.

Tenemos entonces que puede sintetizarse

$$\mathbf{g}(t) = y_1(t) - y_2(t), \quad (18)$$

Donde $y_1(t)$, $y_2(t)$ representan señales disponibles físicamente y provenientes de la medición de la misma variable en el proceso por canales distinto. Supongamos el sistema lineal invariante en el tiempo (SLIT):

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) \\ y_1(t) &= C_1x(t) \\ y_2(t) &= C_2x(t) \end{aligned} \quad (19)$$

Donde,

$x(t) \in \mathcal{R}^n$: representa el vector de estado,

$u(t) \in \mathcal{R}^p$: pertenece al espacio de los controles de entrada

$y(t) \in \mathcal{R}^q$: pertenece al estado de salida

A, B, C_1, C_2 : son las matrices o mapas lineales de dimensión apropiada.

$$\text{Dado que } \mathbf{g}(t) = \begin{cases} = 0 & \text{sin falla} \\ \neq 0 & \text{con falla} \end{cases} \quad (20)$$

$$\mathbf{g}(t) = C_1x(t) - C_2x(t) \Rightarrow (C_1 - C_2)x(t) \quad (21)$$

Si

$$\mathbf{g}(t) \neq 0 \Rightarrow \{C_1 \neq C_2, \forall x(t) \neq 0\} \quad (22)$$

Esta situación estaría detectando una discrepancia en los mapas de proyección C_1, C_2 hacia la salida, significando la detección de fallas en algunos de los canales del sistema de medición de ambas señales. [9]

Caso: Residual Analítica

Fundamento o principio: La idea básica de la generación de residuales por el método de redundancia analítica, consiste en la comparación del comportamiento de la planta real y el comportamiento estimado basado en un modelo

matemático (ver figura 7) o bien basado en el cálculo indirecto producto de una combinación lineal o no, de los otros parámetros de la planta.




Fig. 7. Generación de Residual Analítico

Expresión Matemática:

Generación de residuales basada en modelos. Dado el siguiente sistema

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t), \\ y(t) &= Cx(t). \end{aligned} \quad (23)$$

Donde,

$x(t) \in \mathcal{R}^n$, representa el vector de estado,

$u(t) \in \mathcal{R}^p$, pertenece al espacio de los controles de entrada,

$y(t) \in \mathcal{R}^q$, pertenece al estado de salida,

A, B, C , son las matrices o mapas lineales de dimensión apropiada.

Y si se dispone de un modelo matemático en lazo abierto del comportamiento de la planta,

$$y_e(t) = M(\mathbf{f})u(t), \quad (24)$$

Donde $M(\mathbf{f})$ representa el mapa de aplicación de los controles de entrada hacia el espacio de salida. $M(\mathbf{f})$, también se puede definir como la función de transferencia del sistema.

Luego la generación del residual geométrico como producto de esta comparación, puede presentarse por el siguiente algoritmo matemático computarizado. Si la ecuación 23, representa al sistema sin la presencia de fallas entonces,

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) + S(\mathbf{f})p(t), \\ y(t) &= Cx(t) + y_f(t). \end{aligned} \quad (25)$$

Representa al mismo sistema pero con la presencia de fallas $S(\mathbf{f})p(t)$ en el espacio de estado y $y_f(t)$ en el espacio de salida. Bajo estas suposiciones tenemos que la estructura del residual está expresado por

$$\mathbf{g}(t) = y(t) - y_e(t) = Cx(t) + y_f(t) - M(\mathbf{f})u(t) \quad (26)$$

La ecuación (26) sintetiza la generación de residual basado en el conocimiento del modelo $M(\mathbf{f})$.

Igual a los casos anteriores, este residual geométrico es comparado con niveles de umbrales para cada tipo de falla, para la generación de la firma de la falla respectiva:

$$\mathbf{g}_i(t) = \begin{cases} 1 & \forall |\mathbf{g}_i(t)| \geq K_i \\ 0 & \forall |\mathbf{g}_i(t)| < K_i \end{cases} \quad (27)$$

Nótese de la ecuación (27), que las consideraciones de diseño para lograr una alta capacidad de diagnóstico dependen casi exclusivamente de la matriz de observabilidad (C'). Esta es una condición muy fuerte a menos que se proceda a una reinstrumentación apropiada para la detección y diagnóstico del patrón de falla de interés. (Pouliezos, 1994), (Gertler, 1998), (Patton, 1999)

Aplicaciones: La redundancia analítica se aplica en aquellos sistemas donde puede calcularse y/o analizarse la consistencia de la información, como una combinación lineal de la información proveniente de otros canales, que de alguna forma están relacionados intrínsecamente por la misma fenomenología interna del proceso.

En la industria, la podemos conseguir en: Balances de masa reconciliadas, Balances de energías, Inventario de productos, Productos de mezcla en línea.

Infraestructura de Implantación:

Este algoritmo no debe residir en los computadores (DCS) debido a la posible complejidad del cálculo analítico requerido por el modelo, lo cual compite con el tiempo mínimo de muestreo para ejercer control en el resto de las aplicaciones.

Debe preferiblemente ubicarse en computadores/procesadores locales que permitan una rápida detección sin afectar al sistema de control.

2.6 Filtros Detectores de Fallas

Fundamento o principio: El filtro de detección está intrínsecamente ligado con la teoría de los sistemas de observación, donde se trata de reconstruir el vector de estado del sistema original, con el único objeto de generar un vector residual, como resultado de la diferencia vectorial de la dinámica del sistema real y la estimada por el sistema de observación.

La teoría del filtro de detección contempla las siguientes premisas:

1. Las fallas pueden considerarse como términos aditivos a la dinámica del proceso.
2. Las fallas son vectores en \mathfrak{R}^n , donde n representa la dimensión del espacio del sistema.
3. Las fallas están estructuradas por un patrón de falla L_i y un modo de falla $V_i(t)$.
4. El patrón de falla es conocido.
5. El modo de falla $V_i(t)$ es una función desconocida, arbitraria y que depende del tiempo. (Tarantino, 1999), (Tarantino, 2000).

Expresión Matemática:

Consideremos la siguiente dinámica de un sistema, descrito por un conjunto de ecuaciones diferenciales

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) \\ y(t) &= Cx(t) \end{aligned} \quad (28)$$

Donde

$x(t) \in \mathfrak{R}^n$, Espacio de las variables de estado,

$u(t) \in \mathfrak{R}^p$, Espacio de los controles de entrada

$y(t) \in \mathfrak{R}^q$, Espacio de salida

A, B, C, L_i , son las matrices o mapas lineales de dimensión apropiada.

En un sistema así descrito pueden aparecer términos adicionales en las ecuaciones de estado, debido a cambios en los parámetros del sistema nominal. Estos términos adicionales los llamaremos fallas.

De ahora en adelante afirmaremos que el sistema en presencia de fallas tiene la siguiente dinámica:

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) + \sum_{i=1}^k L_i V_i(t) \\ y(t) &= Cx(t) \end{aligned} \quad (29)$$

En la ecuación (29), $V_i(t) \in V_i$ representa las funciones arbitrarias de fallas, donde la $\dim(V_i) = p_i$, representa los modos de fallas desconocidos y los mapas $L_i : V_i \rightarrow \mathfrak{R}^n$ son los patrones de fallas.

Aplicaciones: Este tipo de sistema de detección de fallas, tiene su aplicación principalmente, donde la generación de residuales físicos no es posible y cuando se dispone del modelo matemático del proceso.

Infraestructura de Implantación:

El algoritmo generador de residuales debe residir en un sistema de computación diferente al DCS. Puede estar ubicado en un sistema local (dedicado) o a niveles de mayor jerarquía (nivel supervisorio, nivel de optimización o planificación).

3. TECNOLOGÍAS DE DETECCIÓN Y DIAGNÓSTICO DE FALLAS

3.1 Redes Neuronales

Fundamento o principio: Las redes neuronales son entrenadas para detectar y diagnosticar fallas usando un conjunto representativo de datos del proceso y el conocimiento de expertos. El esquema presentado en la figura 8, se muestra que el detector de fallas debe ser ajustado de acuerdo al error encontrado.

Este error no es más que la diferencia entre la decisión correcta realizada por el experto y los valores generados por la red neuronal en entrenamiento. El ajuste de los parámetros internos (llamados también pesos) de la red neuronal permitirá tomar decisiones más reales en el momento de detectar y diagnosticar fallas.

El proceso de detección de fallas se basa en la comparación de la respuesta actual y la respuesta anticipada del sistema. La respuesta anticipada del sistema es generada por la red neuronal basada en un modelo de predicción.

En el proceso de diagnóstico de fallas se utilizará un clasificador neuronal, que permitirá la ubicación e identificación de la falla ocurrida. (Mo- Yuen Chow, 1997), (Kartalopoulos, 1996), (Tarantino, 2001).

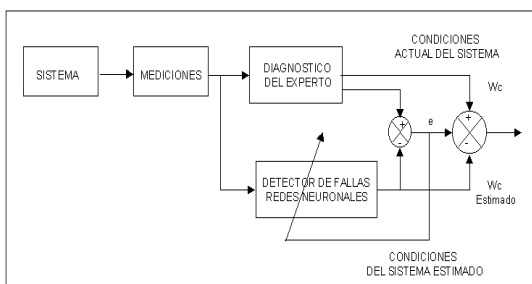


Fig. 8. Diagrama de un Sistema de Detección por Redes Neuronales

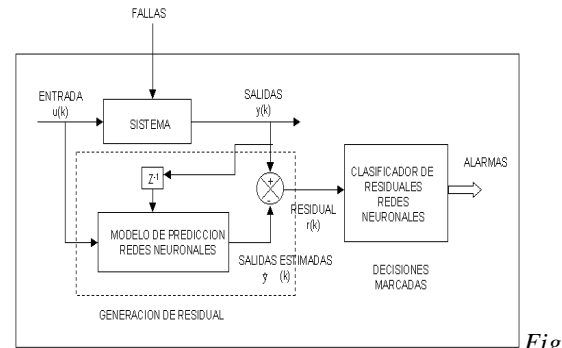


Fig. 9 Esquema de Detección y Diagnóstico usando dos Redes Neuronales

Expresión Matemática:

El esquema de detección y diagnóstico se muestra en la figura 9. El vector de residuales se encuentra conformado por la salida actual y la salida anticipada del sistema, el cual está dado por:

$$g(k) = y(k) - \hat{y}(k),$$

Donde

$$\hat{y}(k) = RN(W, y(k-1), \dots, y(k-n), u(k), \dots, u(k-n))$$

Donde,

$RN(\dots)$ representa una red neuronal basada en un mapa funcional no lineal. El residual generado de esta manera debe ser independiente del estado de operación del sistema sobre las condiciones de operación nominal del mismo. En ausencia de fallas, el residual es debido únicamente a perturbaciones externas o ruidos.

En el proceso de diagnóstico se generará un conjunto de patrones residuales, por medio del clasificador de fallas detectadas. Este clasificador es usado para partición del vector residual en patrones correspondientes a las diferentes situaciones del sistema en falla. (Pouliezos, 1994), (Mo- Yuen Chow, 1997),

Aplicaciones:

Las redes neuronales se aplican para detectar y diagnosticar fallas cuando:

- Se tiene definidos los patrones (con fallas) de las variables del proceso.
- El desacoplamiento del vector de fallas no es posible obtener.

Infraestructura de Implantación:

En la figura 1.23, se presenta la infraestructura de implantación del sistema de detección y diagnóstico de fallas utilizando la tecnología de Redes Neuronales.

Los algoritmos de detección y diagnóstico residen en computadores de alto nivel jerárquico (nivel supervisorio o nivel de planificación (Soporte de Ingeniería)).

3.2 Lógica Difusa

Fundamento o principio: Aproximaciones basadas en reglas han sido propuestas como un método capaz de realizar detección y diagnóstico flexible. Las reglas son descritas como la relación entre las causas y los síntomas de las fallas. El conocimiento elegido que permite la interpretación y el diagnóstico, esta organizado en la base de conocimiento como un conjunto de estados condicionales difusos, que relaciona los resultados de la prueba con las conclusiones acerca de las condiciones del proceso o de las posibles fallas. (Mo- Yuen Chow, 1997), (Kartaloupoulos, 1996), (Tarantino, 2001).

Expresión Matemática:

Los estados condicionales son de la forma

Si $A_{1,1}$ y $A_{1,2}$ y ... y $A_{1,n}$ entonces B_1 ó,

Si $A_{2,1}$ y $A_{2,2}$ y ... y $A_{2,n}$ entonces B_2 ó,

.....

Si $A_{n,1}$ y $A_{n,2}$ y ... y $A_{n,n}$ entonces B_n ,

Donde:

A_{ij} es una variable lingüística. Una variable lingüística es una variable cuyo valor puede ser presentado en los términos lingüísticos usados por expertos tales como "alto", "normal" o "bajo". Una variable lingüística incluye un adjetivo, un modificador y un conectivo. El modificador es una medida de intensidad que está asociada con la selección adecuada de la distribución, el modificador también es llamado función de membresía. Los conectivos lógicos difusos son aquellos conocidos como conjunción, disyunción y operadores de negación. El valor de la variable lingüística puede ser representado por un conjunto difuso la cual permite la definición de la función de membresía m reflejando el grado de pertenencia de un elemento a ese conjunto (ver figura 10). Y B_i es la posible conclusión de la falla o el tipo de falla.




Fig. 10 Representación de una Función Difusa

El análisis cuantitativo de la posibilidad de una verdadera situación de falla en un sistema descrito por los estados condicionales difusos, son hechos a través de la evaluación de su grado de membresía de acuerdo a la ecuación de Zadeh's.

$$m_{B^s}(y) = \max_{1 \leq i \leq m} (\min(n_{B_i}(y), \min_{1 \leq j \leq n} (\max(\min(n_{A_j^s}(x_j), m_{i,j}(x_j))))))$$

Aplicaciones:

Esta tecnología se aplica si se cuenta con la información suministrada por el experto en el proceso o equipos el cual se necesita detectar y diagnosticar las fallas. La implantación esta relacionada con la infraestructura computacional sobre la cual se soporta. Los algoritmos de detección y diagnóstico de fallas deben residir en los computadores de alto nivel jerárquico (nivel supervisorio o nivel de planificación).

Infraestructura de Implantación:

En la figura 1.25, se presenta la infraestructura de implantación del sistema de detección y diagnóstico de fallas utilizando el método Lógica Difusa. Los algoritmos de detección y diagnóstico residen en computadores de alto nivel (nivel supervisorio o nivel de planificación).

3.3 Sistemas Expertos

Fundamento o principio: Los sistemas expertos no es más que una herramienta para organizar y codificar en un computador, la experiencia, el proceso del pensamiento humano y la experticia que mantienen en la operación de los procesos tecnológicos, una planta industrial o un conjunto de equipos o materiales dados. (Aranguren, 2001)

Expresión Matemática:

Los sistemas expertos son programas complejos de Inteligencia Artificial. Estos sistemas representan el conocimiento del dominio en un conjunto de reglas de producción. Las reglas consisten de antecedentes y consecuentes. Un antecedente es parte de la condición y un consecuente es una acción y parte de una regla. Si las condiciones son ciertas entonces encontramos algunas acciones por ejecutar. Las reglas son frecuentemente llamadas reglas *IF- THEN*.

Aplicaciones:

Se aplica en aquellos sistemas que cuentan con una base de conocimiento sobre el dominio del proceso. Cuando se tienen mecanismos de razonamiento para aplicar el conocimiento suministrado en las bases de datos para responder a las fallas que se presentan.

Infraestructura de Implantación:

En la figura 1.26, se presenta la infraestructura de implantación de un Sistema Experto para detectar y diagnosticar fallas.

4. CONCLUSIONES

La cantidad de métodos y técnicas existente nos permiten detectar y diagnosticar fallas ocurridas en la etapa incipiente en sistemas críticos y tomar acciones adecuadas para disminución de las mismas.

La detección, la ubicación y el tipo de fallas ocurridas nos facilitan el mantenimiento predictivo, reduciendo los costos de mantenimiento y disminuyendo de paradas de plantas en procesos industriales.

La combinación de instrumentación inteligente, las tecnologías de comunicación y computacional y las técnicas de diagnóstico nos facilita la implementación de sistemas de detección en la industria.

REFERENCIAS

- Aranguren, S., (2001), "Estudio y Diseño de las Normas, Ingeniería, Metodologías y Tecnologías de los Sistemas de Detección y Diagnóstico de Fallas (SDDF), para los Elementos de los Sistemas de Automatización del Centro de Refinación Paraguaná (CRP), PDVSA". *Tesis de Maestría. Universidad de los Andes. Facultad de Ingeniería*. Mérida-Venezuela.
- Blanke, M., Kinnaert, M., Lunze, J., Staroswiecki, M. (2006). "Diagnosis and Fault-Tolerant Control". Springer. Germany.
- Chen J., and Patton R., (1999). Robust Model-Based Fault Diagnosis for Dynamic Systems. Kluwer Academic Publishers.
- Gertler J., (1998). Fault Detection and Diagnosis in Engineering Systems. Marcel Dekker, Inc. Printed USA.
- Iserman, Rolf. (2006). "Fault-Diagnosis Systems. An Introduction from Fault Detection to Fault Tolerance," Springer. Germany.
- Kartalopoulos (1996). Understanding Neural Networks and Fuzzy Logic. Basic Concepts and Applications. IEEE.
- Mo-Yuen Chow, (1997). Methodologies of Using Neural Network and Fuzzy Logic for Motor Incipient Fault Detection. World Scientific.
- Pouliezios and Stavrakakis. (1994), "Real Time Fault Monitoring of Industrial Processes", Kluwer Academic Publishers.
- Tarantino R., (1999). "Detección de Fallas en Sistemas Dinámicos Lineales Variante en el Tiempo". *Tesis de Doctorado publicada. Universidad de los Andes. Facultad de Ingeniería*. Noviembre, Mérida-Venezuela.
- Tarantino R., Szigeti F., Colina E., (2000) "Generalized Luenberger Observer-Based Fault-Detection Filter Design: An Industrial Application". *Control Engineering Practice*. Julio, pp. 665-671.
- Tarantino R., Cabezas, K., Rivas, F., Colina E. (2001). "Failure Detection and Diagnostic System Based on a Hybrid Method", *Conference Applications and Science of Computational Intelligence*. April.