



UNIVERSIDAD
DE LOS ANDES
MÉRIDA VENEZUELA


UNIVERSIDAD DE LOS ANDES
CONSEJO DE ESTUDIOS DE POSTGRADO
DIVISIÓN DE POSTGRADO INGENIERIA
POSTGRADO EN AUTOMATIZACIÓN E INSTRUMENTACIÓN

DETECCION Y DIAGNOSTICO DE FALLAS UTILIZANDO LA TRANSFORMADA WAVELET

**Proyecto de grado presentado ante la ilustre Universidad de los Andes como
requisito para optar al Título de Magíster Scientiae en
Automatización e Instrumentación**

Autor

Marcos Leonel Guillén Peña



Tutores

José L. Paredes, Ph. D.

Oscar E. Camacho, Ph. D.



Febrero, 2004

Licencia Creative Commons:
Atribución - No Comercial - Compartir Igual 3.0 Venezuela
(CC BY-NC-SA 3.0 VE)

Agradecimientos

A Dios Todopoderoso.

A toda mi familia, de manera especial a mis padres.

Al profesor José Luis Paredes, por sus consejos, recomendaciones y toda su ayuda en la elaboración y culminación de este trabajo.

Al profesor Oscar Camacho, por sus consejos y recomendaciones.

Al Postgrado en Automatización e Instrumentación y todo su personal.

A la Universidad de los Andes.

Al Fondo Nacional de la Ciencia, Tecnología e Innovación (FONACIT) por el apoyo económico prestado para la realización de esta Maestría.

RESUMEN

En este trabajo se propone un método basado en el uso de la Transformada Wavelet para detectar y diagnosticar fallas que se puedan presentar en la instrumentación de un proceso químico, concretamente fallas en los actuadores de las válvulas y en los transmisores.

Los procesos pueden presentar comportamientos no deseados en su régimen de operación debido a posibles desajustes en los actuadores de las válvulas y sensores del sistema. Las señales producidas por estos desajustes poseen características no estacionarias, por lo tanto, pueden ser estudiadas de forma satisfactoria a través de un análisis con la Transformada Wavelet (TW), ya que una de las ventajas de dicha transformada es su capacidad para analizar fenómenos no estacionarios y proporcionar información del momento en que ocurre determinado cambio de frecuencia.

En este trabajo, se presenta un esquema para la detección y el diagnóstico de fallas basado en el análisis de la señal de salida del transmisor utilizando para este fin un análisis de la señal de falla (salida del transmisor) en el dominio wavelet. Tanto la detección, como el diagnóstico de la falla se realizan en el mencionado dominio. Para diferenciar una falla de válvula de una falla de transmisor, se realiza primero una descomposición de la señal (falla) a través de la Transformada Discreta Wavelet (TDW), luego se extraen las características más resaltantes de la señal, para poder definir patrones que caractericen y distingan cada falla. Finalmente, se mide la diferencia entre las fallas utilizando técnicas de reconocimiento de patrones, en este caso Distancia Euclídeana y Distancia entre vecinos más cercanos (K-Nearest Neighbor) que permiten clasificar las fallas. El método propuesto es aplicado a un proceso químico. Los valores de las desviaciones bajo los cuales se simulaban las posibles fallas fueron desde 7.5% hasta 17.5%, igualmente para las perturbaciones se consideraron perturbaciones desde 10% hasta el 17.5%.

TABLA DE CONTENIDO

Agradecimiento	ii
Resumen	iii
Lista de Figuras	v
Lista de Tablas	vi
CAPITULO I	
INTRODUCCIÓN	1
CAPITULO II	
MARCO TEÓRICO SOBRE FALLAS	8
2.1 Conceptos Teóricos de Fallas	8
2.1.2 Detección y Diagnostico de Fallas	9
2.2 Modelado de Fallas en los Instrumentos	10
2.2.1 Modelado de fallas en un actuador de acción lineal	13
2.3 Enfoques para la Detección y Diagnóstico de Fallas	16
2.3.1 Análisis Frecuencial o Espectral	18
CAPITULO III	
LA TRANSFORMADA WAVELET	23
3.1 La Transformada Wavelet Continua	23
3.2 La Transformada Discreta Wavelet (TDW)	25
3.2.1 Análisis de Multiresolución	26
3.2.2 La Función Escala	27
3.2.3 La Función Wavelet	29
CAPITULO IV	
DESCRIPCIÓN DEL MÉTODO DE DETECCIÓN Y DIAGNOSTICO	34
4.1 Detección de la condición de falla	34
4.1.1 Índice de Funcionamiento	38
4.2 Descripción del método propuesto para el Diagnóstico de la Falla	41
4.2.1 Aplicación de la Transformada Discreta Wavelet	42
4.2.2 Extracción de características (Feature Extraction)	44
4.2.2.1 Generación de Patrones	47

4.2.3 Reconocimiento y Clasificación	49
4.2.3.1 Distancia Euclideana	50
4.2.3.2 K-Nearest Neighbor	51
4.2.4 Determinación del valor de porcentaje de la Falla	53
CAPITULO V	
SIMULACIONES Y RESULTADOS	58
5.1 Especificaciones para la Simulación	58
5.2 Descripción del proceso industrial	58
5.3 Simulación de las Fallas	61
5.4 Resultados Experimentales	62
5.4.1 Clasificador por Distancia Euclideana	62
5.4.2 Clasificador por K-Nearest Neighbor	73
5.5 Comparación entre el clasificador por Distancia Euclideana y K-Nearest Neighbor	76
CONCLUSIONES.....	80
REFERENCIAS BIBLIOGRAFICAS.....	82

LISTA DE FIGURAS

2.1. Variable real vs. Lectura del Instrumento	10
2.2. Desviaciones de la recta ocasionadas por fallas en el instrumento	11
2.3. Fallas en el Actuador de la Válvula	13
2.4. Fallas en el Actuador de la Válvula vistas desde la salida del transmisor.....	14
2.5. Falla en el actuador de la válvula y en un sensor	20
3.1. Representación tiempo-frecuencia de la señal.	24
3.2. Espacio Vectorial expandido con la función escala. Multiresolución.....	27
3.3. Función Escala y espacio vectorial. Función Wavelet.....	29
3.4. Representación grafica de la Transformada Wavelet Discreta.....	32
4.1. Diagrama general de un lazo de control por retroalimentación.....	34
4.2. Esquematización del cambio de estado x_0 al estado x_1	41
4.3. Tareas implicadas en el Diagnostico de la Falla.	41
4.4. TDW realizada sobre una falla en el actuador de la válvula.	43
4.5. Representación en forma de árbol de la TDW.	46
4.6. Ejemplos de patrones de fallas.	48
4.7. Espacio de clases de fallas generadas en un proceso.	49
4.8. Espacio de patrones de fallas generadas en un proceso.	52
4.9. Curva utilizada para interpolar y determinar el porcentaje de la Falla.	54
5.1. Tanque de Mezclado.....	59
5.2. Fallas sin ruido.	64
5.3. Fallas con ruido de fondo	65
5.4. Comparación de las Tablas 5.6a y 5.8a.....	77
5.5. Comparación de las Tablas 5.6b y 5.8b.....	77
5.6. Comparación de las Tablas 5.6c y 5.8c.....	78
5.7. Comparación de las Tablas 5.8 y 5.10b.....	79
5.8. Comparación de las Tablas 5.8 y 5.10b.....	79
5.9. Comparación de las Tablas 5.8 y 5.10b.....	79

LISTA DE TABLAS

4.1. Número de muestras de los coeficientes que conforman la señal W_y	45
5.1. Información del proceso y valores en estado estacionario.....	59
5.2a Desviaciones presentadas en el actuador de la válvula.....	61
5.2b Desviaciones presentadas en el transmisor.....	61
5.3a. Índices de funcionamiento en condiciones normales de operación.....	63
5.3b. Índices de funcionamiento para las condiciones de fallas presentadas.....	63
5.4. Descripción de los Vectores Features.....	66
5.5. Vectores característicos utilizados para la clasificación de las fallas. Wavelet usada db4.....	67
5.6. Selección de la wavelet mas apropiada para el diagnostico de las fallas.....	69
5.7. Matriz de clasificación usando distancia Euclídeana.....	70
5.8. Porcentaje de desajuste estimado utilizando la Fig. 3.9.....	72
5.9. Matriz de clasificación usando K-nearest neighbor.....	73
5.10. Porcentaje de desajuste estimado con la media de las distancias.....	74
5.11. Porcentaje de desajuste estimado con la media ponderada de las distancias.....	75
5.12 Comparación entre el clasificador por Distancia Euclídeana K-Nearest Neighbor..	76

CAPITULO I

INTRODUCCION

En un contexto general, las fallas se pueden definir como salidas no deseadas, es decir, desviaciones no permitidas del comportamiento normal de la planta o de su instrumentación [1]. Por ejemplo, si el porcentaje de apertura de una válvula en condiciones normales de operación es del 50%, y debido a una falla o una perturbación cambia a 57%, esta sería una salida no deseada que afecta el desempeño normal del proceso o de la planta.

La detección y el diagnóstico de fallas en los procesos de ingeniería son de gran importancia, ya que una temprana detección de la ocurrencia de una falla podría evitar el deterioro de la producción, degradación de la eficiencia de los procesos, daños mayores en la maquinaria implicada en el proceso y operaciones inseguras de la planta, que podrían poner en riesgo al personal que participa en las operaciones del proceso. El diagnóstico rápido y correcto del componente que está fallando facilita la toma de decisiones, las acciones correctivas y por supuesto las reparaciones que sean necesario realizar [2].

Los métodos para la detección y diagnóstico de fallas en general pueden ser clasificados dentro de dos grupos, los que utilizan un modelo matemático de la planta y los que no utilizan un modelo matemático [2]. Los métodos basados en modelo utilizan una representación matemática del proceso que describe el comportamiento del proceso.

Una propuesta aplicada para la detección y el diagnóstico de fallas en la instrumentación de un proceso, el cual requiere de un modelo matemático de la planta y que adicionalmente requiere de un análisis matemático de considerable complejidad es el desarrollado por R. Tarantino [3]. En esta propuesta, se diseñan filtros y observadores para la detección de la falla, necesitando conocimiento del modelo del sistema dinámico al que se le quiere diseñar el filtro.

Igualmente, A. Ríos-Bolívar en [4] desarrolla una metodología para la implementación de los esquemas de compensación a través de la síntesis de filtros de detección de fallas para los sistemas lineales multivariantes. El filtro de detección permite utilizar la señal de saturación la cual se realimenta para la compensación, según el esquema adoptado. El método es un control tolerante a fallas ya que en línea, los cambios por efectos de la saturación del control son detectados a través del filtro y al mismo tiempo permiten la compensación al momento. Esto significa que no es necesario precisar a priori los niveles de saturación.

Otra técnica usada para la detección y el diagnóstico de fallas en la instrumentación de un proceso, está basada en reconocimiento de patrones, dicha técnica utiliza asociaciones entre datos de patrones y clases de fallas sin la necesidad de tener un modelado de los estados ni de la estructura interna del proceso. El trabajo desarrollado en S. Garcés Rosas [5] utiliza esta técnica y está orientado al diseño de modelos de fallas y análisis del error entre el valor de referencia y la variable controlada. Las posibles fallas son representadas por modelos matemáticos y patrones que son capaces de reconocer la ocurrencia de una falla en un instante determinado. Se plantea un sistema de detección y diagnóstico de fallas, de dos etapas que por medio de un indicador permite determinar la existencia de anomalías en el proceso y luego, a partir de la generación de un patrón define el origen de dicho desajuste.

Otra solución al problema de detección y diagnóstico de fallas es la propuesta por B. Sánchez [1] la cual utiliza la técnica “*Estructura de transición robusta para los sistemas con retraso de tiempo*”. El método permite generar modelos para representar las posibles anomalías que se podrían presentar en el proceso. Una vez que la falla se ha presentado, el sistema de detección reconocerá, mediante un análisis del error, cual modelo de los hallados previamente se aproxima más a la falla en estudio.

Las redes neuronales son otra herramienta que está siendo usada ampliamente para la detección y el diagnóstico de fallas. Y Zhou [6] desarrolla una red neuronal para diagnosticar fallas en procesos químicos, especialmente procesos tipo “batch”. El uso del error residual del modelo neuronal es analizado para el diagnóstico de la falla en el sensor y

en el componente que este fallando. Para reducir el tiempo de entrenamiento de la red neuronal, un proceso de extracción de características es implementado a la entrada del modelo neuronal. Igualmente, A. Ríos-Bolívar [7] presenta un método para la detección y el diagnóstico de fallas, en sistemas no lineales afines en las fallas, basado en la reconstrucción de los modos de dichas fallas. Para reconstruir las fallas se utilizan modelos inversos que se obtienen por el diseño de redes neuronales las cuales permiten aproximar el patrón de comportamiento de las salidas del sistema a las fallas. La técnica consiste en establecer una condición de invertibilidad para el sistema caracterizado por las fallas y las salidas del modelo de diagnóstico no lineal. Si el sistema es invertible la detección y separación de las fallas se obtienen por reconstrucción de los modos de las fallas.

Otra aplicación de las redes neuronales para el diagnóstico de fallas es la planteada por Zhanqun Shi [8] este trabajo comienza por hacer una comparación de las distintas técnicas de diagnóstico que existen para sistemas servo hidráulicos. Luego se desarrolla una red neuronal la cual involucra un filtro wavelet. El principal objetivo de este trabajo es usar la sensibilidad del filtro wavelet para capturar los cambios abruptos que ocurren en los sistemas hidráulicos y usar al alta eficiencia de las redes neuronales para aislar la clase de falla.

Entre los métodos de detección y diagnóstico de fallas, los métodos libres de modelo no hacen uso de modelos matemáticos de la planta [2]. Estos métodos usan redundancias físicas, sensores especiales, chequeo de límites y análisis espectral el cual es un método utilizado frecuentemente a nivel industrial.

Muchas de las variables de la planta presentan una dinámica de cambios lentos a los cuales se les asocian representaciones frecuenciales de baja frecuencia. Dichas representaciones, exhiben espectros que caracterizan el comportamiento de las variables en condiciones normales de operación; alguna desviación de este espectro es considerada como una indicación de anomalía. Ciertos tipos de fallas pueden tener siempre una forma o huella característica en el espectro, facilitando el aislamiento de la misma [2]. Así, las fallas pueden ser estudiadas realizando un análisis frecuencial de dichas señales (fallas), siendo el

Licencia Creative Commons:

Atribución - No Comercial - Compartir Igual 3.0 Venezuela
(CC BY-NC-SA 3.0 VE)

análisis frecuencial de una señal la separación de la señal en sus componentes frecuenciales, usándose para tal fin herramientas matemáticas tales como la Transformada de Fourier (TF) y la Transformada de Fourier en tiempo limitado (STFT).

Sin embargo, la TF no es adecuada para analizar fallas presentes en la instrumentación (actuadores de válvulas o transmisores) de un proceso, ya que estas presentan características no estacionarias (fenómenos oscilantes localizados en el tiempo), transitorios y/o cambios abruptos que exhiben patrones de frecuencia variables en el tiempo. Adicionalmente, se pierde información temporal relacionada a la localización en el tiempo de la falla. Surge entonces, en forma natural, la necesidad de analizar los fenómenos tanto ***localizados en tiempo como en frecuencia***, es decir, fenómenos que requieren información conjunta de ambos dominios.

La STFT realiza una representación temporal-frecuencial de la señal, sin embargo, hay un problema implícito, el cual radica en la selección del tamaño de la ventana siendo este un parámetro de diseño. Una ventana estrecha proporciona buena resolución temporal, pero mala resolución en frecuencia. En el caso opuesto, una ventana ancha proporciona buena resolución frecuencial, pero mala resolución en el tiempo. En particular la aplicación de la STFT no es apropiada para el análisis de señales provenientes de un proceso cuando la instrumentación (válvula y transmisor) está trabajando en condición de falla.

La Transformada Wavelet (TW) se desarrolló como una alternativa a la Transformada de Fourier y sus versiones mejoradas, ya que la Transformada Wavelet es capaz de proporcionar información simultánea de tiempo y frecuencia. Una aplicación particular de la TW es la desarrollada por A. M. Gaouda [9], donde se presenta una técnica de clasificación de fallas en línea. Esta técnica está basada en un análisis de multiresolución wavelet y técnicas de reconocimiento de patrones tales como distancia Euclideana, K-Nearest Neighbor y redes neuronales.

Otra aplicación de la TW es desarrollada por Jian Qiu [10], en este trabajo se describe un método novedoso para detectar y diagnosticar cambios abruptos en sensores. El uso de la

TW permite localizar con precisión las características de una señal en ambos dominios, el instante de ocurrencia de una salida anormal en un sensor puede ser identificado por la representación multiescala de la señal. Después que este instante es identificado se realiza un estudio de las diferencias presentadas en la distribución de energía de la señal sobre todas las escalas de descomposición wavelet, antes y después del instante de ocurrencia de la salida anormal, para así de esta manera clasificar la falla que se está presentando en el sensor.

Por consiguiente, la Transformada Wavelet (TW) surge como una herramienta apropiada para analizar las fallas presentadas en la instrumentación de un proceso (actuadores de válvula y transmisores) pues permite hacer una representación tiempo-frecuencia de la señal con múltiples resoluciones, es decir, tamaños de ventanas variables.

La habilidad de la TW para enfocar intervalos cortos de tiempo en componentes de alta frecuencia, e intervalos largos para componentes de baja frecuencia, mejora el análisis de señales con impulsos y oscilaciones localizadas. Adicionalmente, la TW puede comprimir o quitar el ruido de una señal sin apreciable degradación de la misma, este aspecto es importante para nuestra aplicación ya que las señales producidas por las fallas en los instrumentos contienen un cierto ruido de fondo que hace que se solapen las fallas y, por lo tanto, sea más difícil su clasificación. Por estas razones, la TW es apropiada para el estudio de señales transitorias (fallas) obteniéndose una mejor caracterización y una discriminación mas precisa de las señales.

En este trabajo se propone un método basado en la Transformada Wavelet para detectar y diagnosticar fallas que se puedan presentar en los instrumentos de un proceso químico concretamente válvulas y transmisores, dicho método se desarrolla de la siguiente manera:

- Primero, se obtienen las señales producidas por las fallas en un proceso químico. Este proceso es simulado en Matlab usando la herramienta Simulink (v. 6.1).

- Segundo, se detecta la condición de falla o de no falla a través del uso del índice de funcionamiento *IAE*, con la diferencia de que el cálculo o determinación de dicho índice se realiza en el dominio wavelet permitiendo así realizar una estimación mas robusta y por tanto menos sensible al ruido de fondo.
- Tercero, se estudia la forma como se presentan las fallas en el dominio wavelet, después de aplicada la Transformada Wavelet.
- Cuarto, para diferenciar una falla de válvula de una falla de transmisor y/o perturbación, se utiliza la información obtenida por la aplicación de la transformada para extraer las características más resaltantes de cada una de las señales y las diferencias que existen entre ellas permitiendo así definir patrones que caracterizan y distinguen cada falla para poder así clasificarlas.
- Finalmente se usan técnicas de reconocimiento de patrones, Distancia Euclideana y Distancia entre vecinos más cercanos (K-Nearest Neighbor) que permiten clasificar una falla contaminada con ruido.

Este trabajo está organizado en cinco capítulos.

Capítulo I: Presenta el estado del arte y los antecedentes necesarios para abordar el tema de Detección y Diagnóstico de Fallas. Igualmente, se presenta la justificación del porque usar la Transformada Wavelet.

Capítulo II: Presenta algunos conceptos teóricos de fallas, generalidades de las mismas así, como la clasificación general de las fallas. Igualmente se explica, de manera detallada, el modelado de fallas en los instrumentos y finalmente se realiza una revisión de los distintos enfoques que existen para la detección y el diagnóstico de las fallas especialmente el enfoque de Análisis Frecuencial o Espectral que es el utilizado en este trabajo.

Capítulo III: Describe la Transformada Wavelet (TW) en sus dos versiones: continua y discreta. Primero se estudia la Transformada Wavelet Continua (TWC) para tener una idea general de cómo trabaja la TWC y del porque es necesario discretizar dicha transformada. Seguidamente se realiza un estudio breve, pero claro, de la Transformada Discreta Wavelet (TDW), explicando en detalle como se realiza la descomposición de las señales y cómo se logra la representación temporal-frecuencial multiescala. Adicionalmente, se explica de manera breve y concisa, en que consiste un Análisis de Multiresolución. Finalmente se hace una descripción de las funciones escala y wavelet que son las dos funciones que permiten la versatilidad de la TDW.

Capítulo IV: Describe de manera detallada el método propuesto para la Detección y el Diagnóstico de fallas. Primero se explica como, a través del índice de funcionamiento *IAE*, es posible detectar la condición de falla en el dominio Wavelet. Seguidamente, se explica como se implementa la Transformada Discreta Wavelet a las señales generadas a la salida del transmisor del proceso, cuales tipos de wavelet fueron utilizadas y el número de niveles utilizados en la descomposición de la señal de falla. Igualmente se dan las bases teóricas sobre reconocimiento de patrones, específicamente Distancia Euclideana y K-Nearest Neighbor, también se dan las bases teóricas sobre extracción de características (Feature Extraction) las cuales son una de las bases fundamentales de este trabajo.

Capítulo IV: Presenta las simulaciones y resultados de la aplicación del método propuesto. Estos resultados son presentados en una serie de tablas, y en base a dichas tablas se realizan las distintas comparaciones de los dos clasificadores utilizados (Distancia Euclideana y K-Nearest Neighbor). Igualmente, para reforzar el análisis hecho sobre las tablas presenta gráficos de barras donde se puede apreciar mejor el comportamiento de cada clasificador. Finalmente se presentan las conclusiones y recomendaciones del trabajo.

CAPITULO II

MARCO TEORICO SOBRE FALLAS

En este capítulo se discuten las definiciones teóricas necesarias para establecer la base que sustenta la detección y diagnóstico de fallas. Primero se definen conceptos elementales sobre fallas y su clasificación, luego se describe el método para modelar dichas fallas tomando en cuenta las desviaciones de los parámetros que conforman el modelo que representa los instrumentos. Finalmente se hace un estudio de los diferentes métodos que existen para la detección y el diagnóstico de fallas.

2.1 Conceptos Teóricos de Fallas

Cuando un proceso industrial presenta desviaciones en sus parámetros, sus salidas generalmente no corresponden a los valores normales dentro del rango de operación, estas desviaciones podrían ser causadas por desperfectos o mal funcionamiento de los dispositivos involucrados dentro de dicho de proceso. Las salidas no deseadas son consideradas fallas, es decir, desviaciones no permitidas del comportamiento normal de la planta o de su instrumentación [1].

Las fallas se pueden clasificar de manera general en dos grupos: Fallas Aditivas y Fallas Multiplicativas [2].

Las Fallas Aditivas son entradas desconocidas (perturbaciones) que actúan sobre la planta, las cuales normalmente son cero y, cuando se presentan, causan un cambio en la salida de la planta independiente de las entradas conocidas.

Las Fallas Multiplicativas son cambios abruptos o graduales en algunos parámetros de la planta. Estas causan cambios en las salidas de la planta las cuales dependen también de la

magnitud de las entradas conocidas y están referidas al deterioro de los equipos de la planta.

De acuerdo a la clasificación anterior las fallas se pueden manifestar en instrumentos como sensores y actuadores de válvulas. Las fallas en los sensores, son discrepancias entre la variable medida y los valores actuales de la planta. Las fallas en los actuadores, son discrepancias entre la entrada del actuador y su salida actual.

Las fallas en estos dos instrumentos son usualmente consideradas como aditivas (perturbaciones ó independientes de la magnitud medida). Sin embargo, cuando la falla es completa (deterioro total del instrumento) puede ser mejor caracterizada como falla de tipo multiplicativa [2].

2.1.2 Detección y Diagnóstico de Fallas

En general, en un proceso de detección y diagnóstico de fallas se llevan a cabo las siguientes tareas:

- **Detección de la Falla**, indicación de que los parámetros de la planta se han movido de sus valores de estado estacionario.
- **Aislamiento de la Falla**, la determinación exacta de la localización de la falla, es decir, cual componente está fallando.
- **Identificación de la Falla**, la determinación de la magnitud de la falla.

Las tareas de aislamiento e identificación en conjunto se conocen como diagnóstico de fallas; mientras que la detección es una tarea independiente [1].

2.2 Modelado de Fallas en los instrumentos

Un instrumento se considera libre de falla, si la relación entre los valores reales de la variable comprendidos dentro del campo de medida, y los valores de lectura del instrumento, es lineal. En realidad, la relación entre la variable medida y los valores de lectura del instrumento es aproximadamente lineal ya que el fabricante del instrumento especifica un cierto rango de operabilidad dentro del cual el instrumento se encuentra libre de fallas. La Fig. 2.1, ilustra el rango de operabilidad especificado por el fabricante del instrumento.




Fig. 2.1. Variable real vs. Lectura del Instrumento.

El modelado de fallas en los instrumentos (válvulas, transmisores, sensores), se puede expresar en función de la ecuación determinística que relaciona la variable dependiente con la variable independiente del instrumento. Dicha ecuación se obtiene haciendo un análisis gráfico de la Fig. 2.1 [3].

$$lect(t) = \frac{lec_{\max} - lec_{\min}}{Vr_{\max} - Vr_{\min}} v(t) \quad (2.1)$$

Donde: $lect(t)$: Lectura del instrumento en el instante t .

$v(t)$: Valor de la variable medida en el instante t .

lec_{max} y lec_{min} : Lecturas máxima y mínima del instrumento respectivamente.

Vr_{max} y Vr_{min} : Valores máximo y mínimo de salida de la variable real, $v(t)$, respectivamente.

Ahora bien, el instrumento debe ser representado en forma dinámica, ya que, los procesos industriales son de naturaleza dinámica, es decir, cambian continuamente debido a las distintas perturbaciones y/o desajustes, por lo tanto, para tomar en consideración estos cambios los instrumentos se deben comportar en forma dinámica [11]. Luego la ecuación 2.1 puede escribirse como una ecuación dinámica con un comportamiento de primer orden.

$$\tau \frac{dlec(t)}{dt} + lec(t) = \frac{lec_{max} - lec_{min}}{Vr_{max} - Vr_{min}} ((v(t) - Vr_{min}) + lec_{min}) \quad (2.2)$$

Donde τ es la constante de tiempo de respuesta del bloque funcional que representa el instrumento. Conforme se vayan presentando desviaciones de la recta de calibración (considerando desviaciones aquellos valores que están fuera del rango de operabilidad especificado por el fabricante) se tendrán desviaciones de la recta valor real vs. valor medido de un instrumento específico lo cual se traduce en fallas de medida del instrumento.




Fig. 2.2. Desviaciones de la recta ocasionadas por fallas en el instrumento.

Estas fallas pueden ser fallas en el span¹, fallas en la zona muerta del span, fallas de calibración de cero y fallas en la zona muerta de cero tal como se muestra en la Fig. 2.2.

- Falla en el Span y falla en la zona muerta (ZM) del Span

La falla en el span del instrumento (recta 2 de la Fig. 2.2) se produce cuando ocurre una desviación positiva en la pendiente de la recta de calibración, dicha desviación está representada por un incremento en la variable lec_{max} . Denotando dicho incremento por, la ecuación que describe la dinámica del instrumento quedaría:

$$\tau \frac{dlec(t)}{dt} + lec(t) = \frac{(lec_{max} \pm \Delta lec_{max}) - lec_{min}}{Vr_{max} - Vr_{min}} ((v(t) - Vr_{min}) + lec_{min}) \quad (2.3)$$

La falla en la ZM del Span (recta 3 de la Fig. 2.2) se produce por una desviación negativa de la recta de calibración, el parámetro donde se involucra la falla es en Vr_{max} , esta desviación se denota por ΔVr_{max} y la ecuación que define esta falla es:

$$\tau \frac{dlec(t)}{dt} + lec(t) = \frac{lec_{max} - lec_{min}}{(Vr_{max} \pm \Delta Vr_{max}) - Vr_{min}} ((v(t) - Vr_{min}) + lec_{min}) \quad (2.4)$$

- Falla en la zona muerta (ZM) de cero y falla de calibración de cero

En estos dos tipos de fallas las lecturas están desplazadas paralelamente con respecto a la recta de calibración del instrumento. Como se observa en la Fig.2.2, el punto de partida de la recta de calibración cambia sin que varíe la inclinación o la forma de la curva.

Cuando el desplazamiento es positivo (recta 4 de la Fig.2.2), el parámetro donde se involucra la falla es lec_{min} y corresponde a una falla de calibración de cero. La desviación es señalada por Δlec_{min} , introduciendo este parámetro en la ecuación 2.2 se obtiene

¹ Span (Alcance): Es la diferencia algebraica entre los valores superior e inferior del campo de medida del instrumento [12].

$$\tau \frac{dlec(t)}{dt} + lec(t) = \frac{lec_{\max} - (lec_{\min} \pm \Delta lec_{\min})}{Vr_{\max} - Vr_{\min}} ((v(t) - Vr_{\min}) + (lec_{\min} \pm \Delta lec_{\min})) \quad (2.5)$$

Si el desplazamiento es negativo (recta 5 de la Fig.2.2), el parámetro donde se involucra la falla es $Vr_{\min}$ y corresponde a una falla en la zona muerta de cero. La desviación es señalada por $\Delta Vr_{\min}$; introduciendo este parámetro en la ecuación 2.2 se obtiene

$$\tau \frac{dlec(t)}{dt} + lec(t) = \frac{lec_{\max} - lec_{\min}}{Vr_{\max} - (Vr_{\min} \pm \Delta Vr_{\min})} ((v(t) - (Vr_{\min} \pm \Delta Vr_{\min})) + lec_{\min}) \quad (2.6)$$

2.2.1 Modelado de fallas en un actuador de acción lineal

En este caso se va a modelar exclusivamente el actuador de la válvula, como ejemplo para definir las distintas fallas que se presentan en los instrumentos de un proceso químico (actuadores y transmisores). Las fallas en los transmisores se modelan de la misma manera.

Para modelar las fallas en el actuador de la válvula se tomó en consideración la característica lineal inherente de la válvula. En general se considera sin falla, si mantiene su relación original entre la señal de control relativa y su correspondiente flujo relativo; por lo tanto, cualquiera de las fallas anteriores se refleja en la desviación de dicha característica.[3].




Fig. 2.3. Fallas en el Actuador de la Válvula.




Fig. 2.4. Fallas en el Actuador de la Válvula vistas desde la salida del transmisor.

En las Fig. 2.3 y 2.4 se pueden observar los cuatro tipos de fallas más comunes en una válvula. El funcionamiento normal de la válvula esta representado por la recta número (1) (Fig. 2.3a). Esta característica, es la que relaciona en forma lineal la señal de control, con el flujo de salida. Esta relación no debe presentar desviaciones en el origen ni tampoco en el máximo rango de señal. Cuando estas desviaciones se presentan es porque se está ante una falla en el elemento final de control [3].

De acuerdo con la Fig.2.3, se puede expresar la ecuación que relaciona el flujo relativo $q(t)$ con la señal de control, como la ecuación de una recta.

$$q(t) = \frac{Q_{\max}}{\Delta m} m(t) \quad (2.7)$$

donde Δm , es la variación máxima de la señal de control, para un flujo máximo $q(t)$ que se denomina $Q_{\max}$.

El actuador de la válvula se debe representar con una dinámica para tomar en cuenta las características reales de la válvula [3], por lo tanto, transformando la ecuación 2.7 en una ecuación dinámica con un comportamiento de primer orden quedaría

Licencia Creative Commons:

$$\tau_v \frac{dq(t)}{dt} + q(t) = C_v m(t) \quad (2.8)$$

τ_v representa la constante de tiempo de la válvula y $C_v = \frac{Q_{\max}}{\Delta m}$

La ecuación 2.8 puede ser escrita de forma general para efectos del modelado de la siguiente manera

$$\tau_v \frac{dq(t)}{dt} + q(t) = \left(\frac{Q_{\max} - Q_{\min}}{m_{\max} - m_{\min}} \right) (m(t) - m_{\min}) + Q_{\min} \quad (2.9)$$

Donde $Q_{\max}$ y $Q_{\min}$ son los flujos máximos y mínimos permitidos para las señales de control $m_{\max}$ y $m_{\min}$ respectivamente. Variaciones sobre estos parámetros son desviaciones en la relación entre el flujo de la válvula y la señal de control las cuales representan las fallas de la válvula.

- Falla en el Span (Fig. 2.3a y 2.4a)

Esta falla se produce cuando se tiene una variación en $Q_{\max}$ es decir, que para una señal de control $m_{\max}$ tendremos un flujo $q(t)$ mayor al $Q_{\max}$ correspondiente. La ecuación 2.10 representa este tipo de falla.

$$\tau_v \frac{dq(t)}{dt} + q(t) = \left(\frac{(Q_{\max} \pm \Delta q_{\max}) + Q_{\min}}{m_{\max} - m_{\min}} \right) (m(t) - m_{\min}) + Q_{\min} \quad (2.10)$$

- Falla en la ZM del Span (Fig. 2.3b y 2.4b)

Se presenta cuando se tiene una variación en $m_{\max}$, lo cual se traduce en que para una señal de control $m_{\max}$ desviada, se tendría un flujo $q(t)$ menor al $Q_{\max}$ correspondiente.

$$\tau_v \frac{dq(t)}{dt} + q(t) = \left(\frac{Q_{\max} - Q_{\min}}{(m_{\max} \pm \Delta m_{\max}) - m_{\min}} \right) (m(t) - m_{\min}) + Q_{\min} \quad (2.11)$$

- Falla en la Calibración de Cero (Fig. 2.3c y 2.4c)

Se presenta cuando se tiene una variación en el parámetro $Q_{\min}$ lo cual se traduce en que para una señal de control $m_{\min}$, se tendría un flujo $q(t)$ mayor al $Q_{\min}$ correspondiente.

$$\tau_v \frac{dq(t)}{dt} + q(t) = \left(\frac{Q_{\max} - (Q_{\min} \pm \Delta q_{\min})}{m_{\max} - m_{\min}} \right) (m(t) - m_{\min}) + (Q_{\min} \pm \Delta q_{\min}) \quad (2.12)$$

- Falla en la ZM de Cero (Fig. 2.3d y 2.4d)

Se presenta cuando se tiene una desviación en $m_{\min}$, es decir, se estaría enviando una señal de control mínima cuando en realidad la válvula se encuentra cerrada.

$$\tau_v \frac{dq(t)}{dt} + q(t) = \left(\frac{Q_{\max} - Q_{\min}}{m_{\max} - (m_{\min} \pm \Delta m_{\min})} \right) (m(t) - (m_{\min} \pm \Delta m_{\min})) + Q_{\min} \quad (2.13)$$

2.3 Enfoques para la Detección y el Diagnóstico de Fallas

Los métodos para la detección y diagnóstico de fallas pueden ser clasificados dentro de dos grupos: los que utilizan un modelo matemático de la planta (Métodos basados en modelo) y los que no utilizan un modelo matemático (Métodos libres de modelo) [2].

Los métodos basados en modelo utilizan un modelo matemático de la planta. La descripción matemática natural de los sistemas de ingeniería es en forma de ecuaciones diferenciales, o representaciones en sus transformadas equivalentes. En muchas

aplicaciones no se dispone de tales modelos o son extremadamente complejos por lo que se recurre a aproximaciones que afectan la exactitud del modelo.

Los métodos libres de modelo no hacen uso de un modelo matemático de la planta para detectar la falla. Estos métodos utilizan redundancias físicas, sensores especiales, chequeo de límites y análisis espectral.

En el caso de redundancia física, se instalan múltiples sensores para medir la misma variable. Discrepancias entre las distintas medidas realizadas por los sensores indican una condición de falla en los sensores. Se instalan tres sensores ó más, de esta manera un esquema de votación puede ser formulado el cual aísla el sensor que está fallando. Este método implica costos adicionales en cuanto a la instrumentación instalada en la planta.

Los sensores especiales son instalados específicamente para detección y diagnóstico. Estos pueden ser sensores de límites (medidores de presión o temperatura), los cuales trabajan chequeando límites en el equipo. Otros sensores especiales pueden medir alguna cantidad física indicadora de la presencia de una falla, tal como sonido, vibración, elongación, etc.

El chequeo de límites, es ampliamente usado, las mediciones de la planta son comparadas con límites pre-establecidos. Si el umbral del límite es excedido entonces hay una situación de falla. En muchos sistemas hay dos niveles de límites, el primero sirve de alarma mientras que el segundo es un indicador de una emergencia.

El análisis de espectros de mediciones de la planta puede ser usado para la detección y aislamiento de fallas. Muchas de las variables de la planta exhiben un espectro típico de frecuencia en condiciones normales de operación; alguna desviación de este espectro es una indicación de anormalidad. Ciertos tipos de fallas pueden tener siempre una forma o huella característica en el espectro, facilitando el aislamiento de la falla.

2.3.1 Análisis Frecuencial o Espectral

El termino espectro se emplea para referirse al contenido en frecuencia de una señal. El proceso de obtención del espectro de una señal dada, se conoce como análisis frecuencial o espectral. El análisis frecuencial de una señal conlleva la separación de la señal en sus componentes frecuenciales usándose herramientas matemáticas tales como la Transformada de Fourier y la Transformada de Fourier en tiempo limitado.

La Transformada de Fourier (TF)

Una señal física se representa usualmente mediante una función de *tiempo* $s(t)$ o, alternativamente, en el dominio de la *frecuencia* por su Transformada de Fourier $S(f)$ [13]. Dichas representaciones contienen exactamente la misma información de la señal, solo que enfocadas de manera distinta pero complementaria. Si se asume que la señal es aperiódica y de energía finita, estas dos representaciones se relacionan mediante las siguientes ecuaciones:

$$S(f) = \int_{-\infty}^{\infty} s(t) \cdot e^{-j \cdot 2 \cdot \pi \cdot f \cdot t} dt \quad (2.14)$$

$$s(t) = \int_{-\infty}^{\infty} S(f) \cdot e^{j \cdot 2 \cdot \pi \cdot f \cdot t} df \quad (2.15)$$

donde t representa el tiempo y f la frecuencia.

El termino exponencial puede escribirse como:

$$e^{j \cdot 2 \cdot \pi \cdot f \cdot t} = \cos(2\pi f t) + j \cdot \text{sen}(2\pi f t) \quad (2.16)$$

Lo que hace la Transformada de Fourier es multiplicar la señal original por una expresión compleja (ecuación 2.16), luego se integra este producto. Si la integración resulta en un

valor grande, entonces la señal $s(t)$ contiene una componente espectral fuerte en la frecuencia f . Si el resultado de la integración es pequeño, significa que la señal contiene una componente de poca contribución a ese valor de frecuencia. Finalmente si el resultado es cero, entonces la señal no contiene frecuencia f en lo absoluto [13].

Se debe resaltar que la información proporcionada por la integral corresponde a todos los instantes de tiempo, desde menos infinito hasta mas infinito; en consecuencia, no importa en que instante de tiempo aparece la componente con frecuencia f , porque no afecta el resultado de la integración. En otras palabras, si la componente de frecuencia aparece en el instante t_1 o t_2 , afectara la integral de la misma manera; por lo tanto, se pierde la localización en el tiempo de las componentes armónicas de la señal.

Al procesar señales es común encontrar fenómenos con características no estacionarias (fenómenos oscilantes localizados en el tiempo (Fig. 2.5)), transitorios y/o cambios abruptos que exhiben patrones de frecuencia variables en el tiempo tal y como se mostró en la Fig. 2.4. Las señales que se originan cuando ocurre una falla en el actuador de una válvula o en un transmisor contienen las características arriba descritas como puede verse en la Fig. 2.5. Por lo tanto, un análisis con la TF no es adecuado para analizar dichas señales ya que se pierde la localización en el tiempo del fenómeno transitorio [14,15,16].

Surge entonces, en forma natural, la noción de los **fenómenos localizados en tiempo y frecuencia**, es decir; de señales que requieren información conjunta de ambos dominios.




Fig. 2.5. Falla en el actuador de la válvula y en un sensor (señales no estacionarias).

La Transformada de Fourier en tiempo limitado (STFT)

Para el análisis de señales no estacionarias se comenzó utilizando una representación de frecuencia en tiempo lineal, la cual se conoce como Transformada de Fourier en tiempo limitado (STFT) y cuya ecuación es la siguiente:

$$STFT = \int_t [s(t) \cdot w^*(t - t')] e^{-j2\pi f \cdot t} dt \quad (2.17)$$

donde $s(t)$ es la señal original, $w(t)$ es la función ventana, y el símbolo $*$ es el complejo conjugado.

La principal diferencia entre TF y STFT es que, en la TF el tamaño de la ventana (intervalo de tiempo donde se lleva a cabo la transformada) es fijo y del mismo tamaño que la señal (falla) a tratar. En la STFT la señal es dividida en pequeños segmentos; estos segmentos pueden asumirse como estacionarios escogiendo una ventana $w(t)$ donde el ancho de ésta debe ser igual al segmento en el cual la señal es estacionaria. La ventana va desplazándose a lo largo de la señal y aplicando la transformada a la porción de la señal que abarca en cada desplazamiento, presentando al final un solo espectro formado por las contribuciones

parciales de los fragmentos de señal en los que la ventana ha aplicado la transformada. Es importante resaltar que la anchura de la ventana sigue siendo fija.

La STFT calcula la similitud entre la señal $s(t)$ y la exponencial, en una ventana $w(t)$ de ancho finito. El resultado de cada desplazamiento de la ventana corresponde a diferentes TF en diferentes intervalos de tiempo (no instantes de tiempo), por consiguiente, se está obteniendo una representación tiempo-frecuencia de la señal.

Los resultados que se obtienen con esta técnica solucionan parcialmente las limitaciones (representación simultánea tiempo-frecuencia) de la TF. Sin embargo, hay un problema implícito en la STFT que es conocido como Principio de Incertidumbre de Heisenberg² el cual radica en el tamaño de la ventana.

En la STFT una ventana estrecha proporciona buena resolución temporal, pero mala en frecuencia. En el caso opuesto, una ventana ancha proporciona buena resolución frecuencial, pero mala resolución en el tiempo. Si por el contrario se hiciera la ventana infinita para mejorar la resolución en frecuencia volveríamos al caso de TF, y se perdería toda la resolución en el dominio del tiempo. Como se dijo anteriormente la ventana es de longitud finita y cubre solo una porción de la señal lo cual hace que la resolución en frecuencia sea mala, por lo tanto, no se conocen las componentes de frecuencias exactas que existen en la señal.

La implementación de la STFT para el análisis de las señales que se originan cuando se produce una falla en el actuador de una válvula o en un transmisor (Fig. 2.5) es inapropiada, ya que dichas señales contienen cambios rápidos y eventos transitorios de alta frecuencia; por lo tanto, con dicha transformada no se lograría identificar las componentes de frecuencias exactas que caracterizan a cada tipo de falla (ya sea en la válvula o en el transmisor), debido a que el tamaño de la ventana escogido es fijo a lo largo de todo el proceso de cálculo de la transformada, y por consiguiente la resolución también es fija. Una

² Estipula que no es posible conocer que componentes del espectro existen en un instante determinado, solo se puede saber los intervalos de tiempo en que existe cierta banda de frecuencia, lo cual es un problema de resolución.

vez escogido el tamaño de la ventana no puede ser modificado, trayendo como consecuencia un problema de resolución que se origina con la definición del tamaño de la ventana [15,16].

WWW.BDIGITAL.ULA.VE

Licencia Creative Commons:
Atribución - No Comercial - Compartir Igual 3.0 Venezuela
(CC BY-NC-SA 3.0 VE)

CAPITULO III

LA TRANSFORMADA WAVELET

La Transformada Wavelet surge como una herramienta poderosa para analizar señales no estacionarias, ya que permite hacer una representación simultanea tiempo-frecuencia y tiene la capacidad de realizar un análisis de Multiresolución. A diferencia de sus competidoras TF y STFT, la transformada wavelet utiliza una ventana de anchura variable, permitiendo así caracterizar comportamientos de frecuencias distintas a lo largo de la señal.

A continuación se describirán brevemente los aspectos mas importantes de la Teoría de la Transformada Wavelet en sus dos modalidades, continua y discreta.

3.1 La Transformada Wavelet Continua (TWC)

La Transformada Wavelet Continua se desarrolló como una alternativa a la STFT para superar el problema de la resolución (escogencia del tamaño de la ventana). En la TWC la señal se multiplica por una función parecida a la ventana de la STFT y se calcula la transformada de modo independiente en distintos segmentos temporales de la señal [17]. Sin embargo, el ancho de la ventana no es fijo, va cambiando a medida que se realiza la transformada para cada componente del espectro, es decir, se analiza la señal a diferentes frecuencias con resoluciones diferentes y no cada componente espectral a una resolución constante, como es el caso de la STFT. Este es el aspecto mas resaltante de la Transformada Wavelet Continua.

La expresión que representa la TWC es:

$$CWT_x^\psi(\tau, s) = \Psi_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (3.1)$$

donde $\psi(t)$ es la función transformante conocida como wavelet “madre”, y el resto de las funciones generadas $\psi_{s,\tau}(t)$ se conocen simplemente como wavelets, las cuales son versiones dilatadas y/o trasladadas en el tiempo de la función madre. El parámetro τ se denomina *factor de traslación*, y s *factor de escala*. Para cada par de valores de s y τ , la TWC puede interpretarse como una medida de la similitud de la señal en estudio $x(t)$ con la wavelet ubicada en la posición τ y en la escala s .

El termino traslación “ τ ” representa la ubicación de la ventana a lo largo de toda la señal (ver Fig. 3.1). Dicho termino corresponde a la información de tiempo en el dominio de la transformada, sin embargo, no se tiene un parámetro de frecuencia, como se tiene en STFT. En cambio se tiene el parámetro de escala “ s ” el cual representa la frecuencia. Las frecuencias bajas (valores altos de s) corresponden a una información global de la señal, y las frecuencias altas (valores bajos de s) corresponden a una información detallada de la señal.




Fig. 3.1. Representación tiempo-frecuencia de la señal.

Ahora bien, el calculo de la TWC implica la solución de una integral, lo cual, resulta computacionalmente complejo realizar, por lo tanto; es necesario discretizar la transformada [13] [14]. Mallat [18], desarrolló un algoritmo que permite discretizar la

transformada wavelet. Surge entonces lo que se conoce como Transformada Discreta Wavelet la cual se verá en detalle en el siguiente punto.

3.2 La Transformada Discreta Wavelet (TDW)

La información que proporciona la TWC es redundante, esta redundancia (información innecesaria) requiere una cantidad importante de tiempo para su cálculo. La Transformada Discreta Wavelet mantiene solo la información suficiente para el análisis y síntesis de la señal original, con una reducción significativa de tiempo para su cálculo, por lo tanto, puede decirse que, la TDW es considerablemente más simple de ejecutar que la TWC [13].

Una señal, en L^2 , espacio de todas las funciones integrables al cuadrado (es decir si $\varphi \in L^2 \rightarrow \int_s \varphi^2 < \infty$) puede ser escrita como una serie en expansión en términos de las funciones de escala $\varphi_k(t)$ y wavelet $\psi_{j,k}(t)$ [14].

$$f(t) = \sum_k c(k) \varphi_k(t) + \sum_k \sum_j d(j,k) \psi_{j,k}(t) \quad (3.2)$$

$$c(k) = \sum_m h(m-2k) c_{j+1}(m) \quad \text{Coeficientes de aproximación} \quad (3.3)$$

$$d(k) = \sum_m g(m-2k) c_{j+1}(m) \quad \text{Coeficientes de detalles} \quad (3.4)$$

Donde φ_k y $\psi_{j,k}$ son familias de funciones generadas de funciones básicas de escalamiento $\varphi(t)$ y wavelet $\psi(t)$, es decir $\varphi_k = \varphi(t-k)$ y $\psi_{j,k} = 2^{j/2} \psi(2^j t - k)$. Cuando el índice k cambia de posición, la wavelet se mueve sobre el eje del tiempo permitiendo la localización en tiempo del evento. Cuando el índice j cambia, la forma de la wavelet cambia en escala, es decir, se expande o comprime en tiempo (ver Fig. 3.1). Esto permite una representación de los detalles de la señal.

La ecuación 3.3 (primer termino de 3.2), es una función que representa una baja resolución o una aproximación de la función $f(t)$ para cada incremento de j , el segundo termino expresado por la ecuación 3.4 representa una resolución mas fina de $f(t)$.

La TDW analiza la señal $f(t)$ a diferentes bandas de frecuencia con diferentes resoluciones, descomponiendo la señal en dos partes, una que representa la información de aproximación (baja frecuencia) y otra parte que representa la información de detalles de la señal $f(t)$ (alta frecuencia). La TDW utiliza dos funciones para realizar dicha descomposición, la función escala $\phi(t)$ y la función wavelet $\psi(t)$, las cuales están asociadas con filtros paso bajo y paso alto respectivamente, como se verá mas adelante.

3.2.1 Análisis de Multiresolución

Antes de iniciar el estudio en detalle de las funciones wavelet y escala es necesario enunciar algunos requerimientos de expansión de conjuntos (Fig. 3.2) [14,19]. Sea

$$.... \subset V_{-2} \subset V_{-1} \subset V_{-0} \subset V_1 \subset V_2 \subset \subset L^2 \quad (3.5)$$

donde
$$V_{-\infty} = \{0\} \quad y \quad V_{\infty} = L^2 \quad (3.6)$$

El espacio que contiene señales de alta resolución contendrá también señales de baja resolución. Escrito de otra manera seria:

$$baja \text{ resolución} \leftarrow V_j \subset V_{j+1} \rightarrow alta \text{ resolución} \quad \forall j \in Z \quad (3.7)$$




Fig. 3.2. Espacio Vectorial expandido con la función escala. Multiresolución.

Si se analiza la ecuación 3.5 y se observa la Fig. 3.2, se tiene que, V_{-1} está contenido en V_0 , V_0 está contenido en V_1 y así sucesivamente, de forma tal que V_∞ está contenido por el conjunto L^2 ; en consecuencia satisface la condición natural de escalamiento, la cual manifiesta que si $\varphi_k(t)$ está en V_0 , también está en V_1 representada o expandida por $\varphi_k(2t)$. Esto significa que $\varphi_k(t)$ puede ser expresada como una suma de términos o funciones derivadas de $\varphi_k(2t)$. La ecuación 3.8 expresa lo anteriormente descrito

$$\varphi(t) \in V_j \leftrightarrow \varphi(2t) \in V_{j+1} \quad (3.8)$$

la ecuación 3.8 asegura que elementos en el espacio V_j son simplemente versiones escaladas de los elementos en el próximo espacio V_{j+1} .

3.2.2 La Función Escala

La función escala se define como:

$$\varphi_k(t) = \varphi(t - k); \quad k \in \mathbb{Z}; \quad \varphi \in L^2 \quad (3.9)$$

donde $\mathbb{Z}$ representa el conjunto de los números enteros.

El subespacio de L^2 expandido por esas funciones $\varphi_k(t)$ es definido como:

$$V_0 = \overline{\text{span}_k \{\varphi_k(t)\}} \quad \text{span}_k: \text{expresa expansión completa} \quad (3.10)$$

Donde V_0 es el espacio de todas las funciones $f(t)$ que pueden ser expresadas como una combinación lineal de las funciones $\varphi_k(t)$. En otras palabras para todo k desde $-\infty$ hasta $+\infty$ $f(t)$ puede ser escrita como:

$$f(t) = \sum a_k \varphi_k(t) \quad \forall \quad f(t) \in V_0 \quad (3.11)$$

Luego, una familia de funciones de dos dimensiones puede ser generada de la función escala básica $\varphi_k(t)$ por escalamiento y traslación, es decir

$$\varphi_{j,k}(t) = 2^{j/2} \cdot \varphi(2^j t - k); \quad (3.12)$$

Cuya expansión sobre k es

$$V_j = \overline{\text{span}_k \{\varphi_k(2^j t)\}} = \overline{\text{span}_k \{\varphi_{j,k}(t)\}} \quad (3.13)$$

para todos los $k \in \mathbb{Z}$. Esto significa que si $f(t) \in V_j$ entonces la ecuación 3.11 puede ser expresada como:

$$f(t) = \sum a_k \varphi(2^j t + k) \quad (3.14)$$

Para $j > 0$, la expansión es grande ya que $\varphi_{j,k}(t)$ es estrechada (comprimida) y trasladada en saltos pequeños; por lo tanto, estas funciones de escala pueden representar información de detalles de $f(t)$. Para $j < 0$, $\varphi_{j,k}(t)$ es estirada y trasladada en saltos grandes. Entonces estas funciones de escala pueden representar solamente información burda, y el espacio expandido en ella es pequeño. Otra manera de pensar acerca de los efectos de un cambio en escala es en términos de resolución [14].

3.2.3 La Función Wavelet

Los detalles de una señal $f(t)$ pueden ser mejor descritos, no por el uso de $\varphi_{j,k}(t)$ y el incremento de j para incrementar el tamaño del subespacio expandido por la función escala. Sin embargo, se pueden definir un grupo de funciones $\varphi_{j,k}(t)$ ligeramente diferentes que expanden las diferencias entre el espacio expandido por varias funciones escala. Esas funciones ligeramente diferentes son las funciones wavelet [14].

Si la función escala y la función wavelet son ortogonales proporcionan varias ventajas. Las funciones bases ortogonales permiten un calculo sencillo de los coeficientes de expansión, además tienen presente el teorema de Parseval³ [14], el cual permite la división de la energía de la señal en el dominio de la Transformada Wavelet.

El complemento ortogonal de V_j en V_{j+1} está definido como W_j , esto significa que todos los miembros de V_j son ortogonales a todos los miembros de W_j ; por lo tanto:

$$\langle \varphi_{j,k}(t), \psi_{j,l}(t) \rangle = \int \varphi_{j,k}(t), \psi_{j,l}(t) dt = 0 \quad j, k, l \in \mathbb{Z} \quad (3.15)$$




Fig. 3.3. Función Escala y espacio vectorial. Función Wavelet.

³ Teorema de Parseval: Si las funciones de escala y wavelet forman una base ortonormal entonces la energía de $f(t)$ es igual a la energía en cada uno de sus componentes y coeficientes wavelets. Esta es una de las razones por las cuales la ortonormalidad es importante [14]

La relación entre varios subespacios puede ser mejor descrita siguiendo las siguientes expresiones. Se puede empezar con un V_j , para $j=0$ y decir que

$$V_0 \subset V_1 \subset V_2 \subset \dots \subset L^2 \quad (3.16)$$

Ahora se puede definir el subespacio wavelet expandido W_0 tal que:

$$V_1 = V_0 \oplus W_0 \quad (3.17)$$

donde $\oplus$ denota la unión de los conjuntos V_j , W_j .

el cual se extiende a

$$V_2 = V_0 \oplus W_0 \oplus W_1 \quad \text{o} \quad V_2 = W_1 \oplus V_1 \quad (3.18)$$

y de manera general se puede escribir como

$$L^2 = V_0 \oplus W_0 \oplus W_1 \oplus W_2 \dots \quad (3.19)$$

donde V_0 es el espacio inicial expandido por la función escala $\phi(t-k)$. La Fig. 3.3 muestra el anidamiento de las funciones escala del espacio V_j para diferentes escalas j y, muestra como el espacio wavelet está particionado excepto para el elemento cero.

Entonces, como se dijo al principio en la ecuación 3.2, cualquier función $f(t) \in L^2(R)$ puede ser escrita como una serie en términos de la función escala $\phi_k(t)$ y la función wavelet $\psi_{j,k}(t)$.

Teniendo claro los conceptos de la función wavelet y la función escala se verá a continuación como trabaja la TDW.

La descomposición de la señal a diferentes frecuencias, se obtiene simplemente filtrando la señal de manera sucesiva (filtrado paso bajo y paso alto) en el dominio del tiempo. La señal original $x(n)$ se pasa primero por un filtro paso alto con respuesta impulso $g(n)$ y un filtro paso bajo con respuesta impulso $h(n)$. Luego de el filtrado, la mitad de las muestras pueden ser eliminadas de acuerdo con la regla de Nyquist⁴, porque la señal ahora tiene la mitad de la frecuencia de la señal de entrada; por lo tanto, la señal puede ser submuestreada por un factor de 2, es decir se desechan una de cada dos muestras a la salida del filtro. Esto constituye un nivel de descomposición que se puede expresar por las ecuaciones 3.15 y 3.16.

$$y_{PA}(k) = \sum_n x(n).g(n-2k) \quad (3.20)$$

$$y_{PB}(k) = \sum_n x(n).h(n-2k) \quad (3.21)$$

donde $y_{PA}(k)$ y $y_{PB}(k)$ son la salida de los filtros paso alto y paso bajo respectivamente. El factor $2k$ representa el proceso de submuestreo por un factor de 2.

En cada nivel (ver Fig.3.4), el filtrado y el submuestreo darán como resultado la mitad de las muestras (la mitad de resolución en tiempo) y la mitad de la banda de frecuencia extendida (se dobla la resolución de frecuencia).

⁴ Regla de Nyquist: Si la frecuencia mas alta contenida en una señal $x(n)$ es f_{max} y la señal se muestrea a una frecuencia $f_s > 2f_{max}$, entonces la señal $x(n)$ puede recuperarse totalmente a partir de sus muestras.




Fig. 3.4. Representación gráfica de la Transformada Wavelet Discreta.

La Fig. 3.4 ilustra el procedimiento de filtrado, donde $x(n)$ es la señal original a ser analizada, $h(n)$ y $g(n)$ son los filtros paso bajo y paso alto, respectivamente. El ancho de banda de la señal a cada nivel está determinado como " f " y el símbolo del círculo con la flecha y el 2, indica la operación de submuestreo por un factor de dos.

La señal $x(n)$ pasa por un par de filtros, y se descompone en dos señales, $ca1$ versión suave o de aproximación de $x(n)$ (su frecuencia se extiende desde 0 a $\pi/2$), y $cd1$, versión detallada de $x(n)$ que contiene la información relevante o detalles de la señal en este *Nivel1* de descomposición (la frecuencia se extiende desde $\pi/2$ hasta π). De igual manera, la señal $ca1$ se pasa por el mismo par de filtros y se descomponen en $ca2$ y $cd2$, donde $cd2$ contiene la información relevante del *Nivel2* (la frecuencia se extiende desde $\pi/4$ hasta $\pi/2$). La señal $x(n)$ tiene ahora la mitad de resolución en tiempo, pero tiene dos veces la resolución en frecuencia del *Nivel1*. El proceso se repite sucesivamente hasta obtener la descomposición completa en las subbandas correspondientes. En este ejemplo específico (Fig. 3.4) hay 3

niveles de descomposición, cada nivel con la mitad del número de muestras del nivel anterior.

La TDW de $x(n)$ se obtiene encadenando todos los coeficientes que empiezan en el ultimo nivel de descomposición, es decir:

$$x(n) = [ca3:cd3:cd2:cd1] \quad (3.22)$$

por lo tanto la TDW tiene el mismo número de coeficientes que la señal de entrada $x(n)$.

WWW.BDIGITAL.ULA.VE

CAPITULO IV

DESCRIPCION DEL METODO DE DETECCION Y DIAGNÓSTICO

En este capitulo se desarrolla el método propuesto para la detección y el diagnóstico de fallas a través del uso de la señal de salida del transmisor. El objetivo principal es desarrollar un método que permita detectar cambios en el proceso e identificar la causa que ocasiona el cambio. El método consta de dos fases, la detección de la condición de falla y, el diagnóstico de la misma. Adicionalmente, en esta ultima fase, el método permite determinar el porcentaje estimado de desviación del parámetro en el cual se está registrando la condición de falla.

4.1 Detección de la condición de falla

Sin perdida de generalidad, se puede asumir que la salida del transmisor de la planta, $y(t)$, ilustrada en la Fig. 4.1 viene dada por.

$$y(t) = x(t) + \eta(t) + (\mathbf{1}_i)^T \cdot \mathbf{F}(t, p) \quad (4.1)$$




Fig. 4.1. Diagrama general de un lazo de control por retroalimentación.

donde $y(t)$ es la señal de salida del transmisor, $x(t)$ es la señal de referencia o set point, $\eta(t)$ representa ruido de fondo el cual se asumirá como ruido blanco Gaussiano con media cero y varianza σ^2 .

Es importante resaltar que el uso de ruido blanco, como contaminación de la señal proveniente del transmisor, se aleja en principio de un caso real cuando se monitorea la señal $y(t)$ localmente donde el controlador ejerce su acción. Dado que, la retroalimentación introduce correlación a las componentes ruidosas. Sin embargo, el ruido solo se considera para efectos de probar ó mostrar la capacidad del método para detectar y diagnosticar desajustes (posibles fallas) que se estén presentando. Igualmente dicha adición es hecha con el fin de considerar todos los posibles porcentajes de desajustes que puedan presentarse en los parámetros de la instrumentación del proceso y no con el fin de probar si la estrategia de control es tolerante o no al ruido que se está agregando a la señal. El objetivo general de este trabajo es la propuesta de un método para la detección y el diagnóstico de fallas y no el estudio de una estrategia de control para procesos estocásticos.

Mas aun, el modelo de la señal $y(t)$ en la ecuación (4.1) puede ser visto como si el monitoreo de la señal a la salida del transmisor es realizado a distancia, mientras que el control se realiza localmente. Así, $\eta(t)$ emula el ruido introducido por el canal de comunicación, entre el proceso y el centro de supervisión para la detección y el diagnóstico de la falla. Modelos mas complejos, para el canal de comunicación y su influencia en el método de detección y el diagnóstico de fallas es objeto de estudio en investigaciones posteriores.

El termino “ $(\mathbf{1}_i)^T \cdot \mathbf{F}(t, p)$ ” en la ecuación (4.1) representa uno de los posibles desajustes (fallas o perturbaciones) que se pueden presentar en la planta, donde $(\mathbf{1}_i)^T$ es un vector n-dimensional cuyas componentes son ceros excepto posiblemente la i-enésima componente la cual representa la condición de desajuste. Es decir

$$(\mathbf{1}_i)^T = [0 \quad 0 \quad 1 \quad \dots \quad 0] \quad (4.2)$$

donde T es la traspuesta del vector $\mathbf{1}_i$, “1” es el elemento i-enésimo que representa la condición de desajuste y “0” representa la condición de no desajuste.

El termino $\mathbf{F}(t,p)$ constituye el patrón de la falla, el cual es una función temporal desconocida, el parámetro p representa el porcentaje de desajuste que se está presentando en la planta, $\mathbf{F}(t,p)$ puede ser escrita como:

$$\mathbf{F}(t, p) = \begin{bmatrix} F_1(t, p) \\ F_2(t, p) \\ F_3(t, p) \\ \vdots \\ F_n(t, p) \end{bmatrix} \quad (4.3)$$

Así, $\mathbf{F}(t,p)$ puede ser vista como una función vectorial, formada por funciones escalares, las cuales representan los distintos patrones de fallas o perturbaciones que se presentan en el proceso.

En el Capítulo II se mencionó que se pueden presentar cuatro tipos de fallas en el actuador de la válvula, cuatro tipos de fallas en el transmisor y también se consideró la presencia de posibles perturbaciones, ya que estas, pueden llegar a confundirse con fallas en la instrumentación del proceso. Sin embargo, es importante resaltar que en este trabajo se considera que ocurre un solo desajuste a la vez, por lo tanto, el producto entre $(\mathbf{1}_i)^T$ y $\mathbf{F}(t,p)$ dará como resultado una función escalar, la cual representa el desajuste que se está presentando en el proceso, ya sea falla o perturbación. Expresando lo anterior, $(\mathbf{1}_i)^T \cdot \mathbf{F}(t, p)$ es igual, por ejemplo a,

$$\mathbf{F} = \begin{bmatrix} 0 & 0 & 1 & \dots & 0 \end{bmatrix} \cdot \begin{bmatrix} F_1(t, p) \\ F_2(t, p) \\ F_3(t, p) \\ \vdots \\ F_n(t, p) \end{bmatrix} = F_3(t, p) \quad (4.4)$$

es decir, se está presentando el desajuste $F_3(t, p)$, el cual tiene un porcentaje de desajuste igual a p .

Ahora bien, estos desajustes se manifiestan como cambios en la señal $y(t)$ y por consiguiente como cambios en el proceso de medición del transmisor [10]. Cuando dichos cambios se presentan generan un cambio en la señal de salida del error $e(t)$ (ver Fig. 4.1), el cual se define como:

$$e(t) = y(t) - x(t) \quad (4.5)$$

y tiene un valor de aproximadamente cero cuando la variable controlada $y(t)$ coincide con el valor de referencia $x(t)$, es decir, cuando el proceso se encuentra en condiciones normales de operación (en estado estacionario) y no existe condición de falla. Sin embargo, si existe un desajuste (falla o perturbación) la variable controlada $y(t)$ se aleja de el valor de referencia y el error quedaría como sigue

$$e(t) = \eta(t) + \mathbf{F}(t, p) \quad (4.6)$$

por lo tanto, realizando un monitoreo de la señal del error se detectan los cambios en la señal $y(t)$ y, por ende, se pueden detectar posibles desajustes, los cuales podrían estar siendo provocados por una posible falla o una perturbación.

De acuerdo con lo establecido en el párrafo anterior detectar un cambio en $y(t)$ se reduce a un problema de regulación de las variables del proceso.

De manera general en los procesos el controlador es lo suficientemente robusto para permitir que, bajo la influencia de perturbaciones o fallas incipientes (fallas en el actuador de la válvula o en el transmisor), esté presente un estado transitorio y luego regrese a su estado estacionario; por consiguiente, se quiere un indicador que con el monitoreo de ciertas señales ($y(t)$ y $x(t)$) y luego de un procesamiento, genere una medida a través de la cual se pueda determinar la presencia de desajustes en el proceso bajo estudio [5].

4.1.1 Índice de Funcionamiento

El índice de funcionamiento, permite medir el desempeño del controlador mediante el monitoreo de las señales $y(t)$ y $x(t)$. El índice de funcionamiento es una medida de la eficiencia del controlador en la tarea de mantener la variable de control en el umbral de referencia deseado.

Con el fin de determinar la presencia o no de fallas, se puede plantear que la respuesta de un proceso en lazo cerrado es un error o desviación mínima de la variable controlada, $y(t)$, respecto al valor de referencia. Debido a que el error está en función del tiempo que dura la respuesta, la suma del error en cada instante se debe minimizar; dicha suma es, por definición, la integral del error en tiempo. La integral del error no se puede minimizar de manera directa, ya que un error negativo muy grande cancelaría un error positivo y por tanto la integral del error se haría cero o mínima cuando en realidad debería tomar un valor elevado. Para evitar los valores negativos en la función de desempeño, se recomienda el uso, como índice de funcionamiento, a la integral del valor absoluto del error, mejor conocido como *IAE* (integral absolute error), el cual se escribe como [11]:

$$IAE = \int_{t_0}^t |e(t)| dt \quad (4.7)$$

donde $e(t)$ es la diferencia entre la variable controlada y el valor de referencia. La integral se extiende desde el momento en que ocurre la perturbación, t_0 , hasta un tiempo posterior necesario para que el proceso regrese nuevamente a su estado estacionario [11].

Cuando el proceso está en condiciones normales de operación, debería tener un valor de IAE aproximadamente cero, ya que la variable controlada coincide con el valor de referencia. Sin embargo, este valor de IAE para condiciones de estado estacionario es difícil de determinar debido al ruido de fondo que contiene la señal $y(t)$. Efectivamente este es un valor pequeño pero cambia conforme varía el ruido $\eta(t)$. Con el fin de dar una mayor robustez al proceso de detección de la falla, en este trabajo se va a realizar la estimación del IAE en el dominio wavelet, es decir, se va a aprovechar la capacidad que tiene la transformada discreta wavelet (TDW) para suprimir el ruido de las señales y así poder tener un IAE fijo para el caso en que el proceso se encuentre en estado estacionario evitando así, las variaciones del IAE debido al ruido de fondo.

Para determinar el IAE en el dominio wavelet es necesario expresar la señal $e(t)$ como una serie en expansión en términos de las funciones de escala $\varphi_k(t)$ y wavelet $\psi_{j,k}(t)$, tal como se explico en el Capitulo III.

$$e(t) = \sum_k c(k)\varphi_k(t) + \sum_k \sum_j d(j,k)\psi_{j,k}(t) \quad (4.8)$$

donde $\sum_k c(k)\varphi_k(t)$ representa una aproximación de la señal $e(t)$ a baja resolución; por lo tanto los coeficientes $c(k)$ contienen la información de baja frecuencia de la señal. El segundo termino $\sum_k \sum_j d(j,k)\psi_{j,k}(t)$ representa los detalles de la señal y son una representación mas fina de $e(t)$. Los coeficientes $d(j,k)$ contienen la información de alta frecuencia de la señal y por tanto las componentes ruidosas y de detalles de la señal.

El IAE expresado ahora en términos wavelet quedaría:

$$IAE = \int_{t_0}^t |e(t)| dt = \int_{t_0}^t \left| \sum_k c(k) \varphi_k(t) + \sum_k \sum_j d(j,k) \psi_{j,k}(t) \right| dt \quad (4.9)$$

luego, como el ruido tiene la característica de contener altas frecuencias, entonces este se encuentra representado por los coeficientes de detalles. Así, despreciando dichos coeficientes y tomando sólo los coeficientes de aproximación, los cuales no contienen ruido de fondo, se puede estimar el valor de IAE sin las complicaciones que trae las fluctuaciones provocadas por el ruido. Además, los coeficientes de aproximación tal como su nombre lo indica, nos permite realizar una representación aproximada de la señal $e(t)$, representando dicha señal con un número reducido de datos.

Así el IAE quedaría como

$$IAE = \int_{t_0}^t \left| \sum_k c(k) \varphi_k(t) \right| dt \quad (4.10)$$

El IAE en condiciones normales de operación, estimado en el dominio wavelet, presenta un valor muy cercano a cero debido a que la variable controlada se encuentra en el umbral de referencia, y, hasta un valor máximo de $IAE = IAE_{umbral}$ (en la frontera) se dice que el proceso se encuentra en operación normal. Si el índice IAE supera dicho valor, la variable controlada se está alejando del umbral de referencia, lo cual indica que algo no deseado está ocurriendo en el proceso, por lo tanto el sistema presenta un desajuste originado por alguna perturbación o falla. En la Fig. 4.2, se presenta un esquema de lo expuesto anteriormente. Si el proceso parte de un estado x_0 y llega a un estado x_1 y presenta un $IAE > IAE_{umbral}$ se dice que el sistema ha sido afectado por la presencia de algún desajuste. La escogencia del valor umbral puede realizarse empíricamente [5].




Fig. 4.2. Esquematización del cambio de estado x_0 al estado x_1 .

4.2 Descripción del método propuesto para el Diagnóstico de la Falla

Definido el método que permite detectar la existencia o no de la condición de falla se procede a realizar el diagnóstico de la falla, llevando a cabo las siguientes tareas:

- Aplicación de la Transformada Discreta Wavelet (TDW) sobre la señal $y(t)$.
- Extracción de los parámetros que caracterizan la falla (Feature Extraction).
- Reconocimiento y Clasificación.
- Determinación del valor de porcentaje de desajuste.

La Fig. 4.3 ilustra este procedimiento.




Fig. 4.3. Tareas implicadas en el Diagnóstico de la Falla.

Es importante resaltar que el proceso de diagnóstico de la señal $y(t)$ se lleva a cabo solo si se presenta una condición de desajuste, es decir, el valor de IAE es mayor que el IAE_{umbral} , de lo contrario el proceso de diagnóstico no se realiza.

4.2.1 Aplicación de la Transformada Discreta Wavelet

El primer paso es realizar la descomposición de la señal falla $y(t)$ a través del uso de la Transformada Discreta Wavelet (TDW). Para poder implementar la TDW es necesario definir el tipo de wavelet, el tamaño de la wavelet (tamaño de definición) y el número de niveles de descomposición que serán necesarios para realizar dicha implementación. Existen diferentes tipos de wavelets que pueden ser utilizadas para descomponer la señal distorsionada $y(t)$. No existe ninguna regla o método para establecer cual wavelet es mejor para una aplicación en particular, por esa razón la escogencia de la wavelet se realiza en forma empírica.

En este trabajo en particular, se utilizaron dos tipos de wavelet, las cuales son: Daubechies (db4, db8, db20) y biortogonales (bior3.5, bior6.8). El significado de los coeficientes que acompañan a los nombres de las wavelet están referidos al orden de la wavelet, mas concretamente al número de coeficientes para la descomposición y reconstrucción de la señal, por ejemplo db4, contiene 8 coeficientes para la descomposición de la señal y 8 para su reconstrucción. El mismo caso se presenta para db8 solo que esta tendrá, 16 coeficientes para descomposición y 16 para reconstrucción y así para el resto de dbN. En cuanto a las biortogonales los números que acompañan al nombre de la wavelet también están referidos al orden de la wavelet, el primer numero se conoce como N_r y es la longitud del filtro de reconstrucción, el segundo numero es N_d y representa la longitud del filtro de descomposición. Para bior3.5, N_r tiene una longitud de 4, y N_d tiene una longitud de 11, para bior6.8 seria $N_r=11$ y $N_d=17$ [14].

Para determinar cual de estos dos tipos de wavelet era la mas adecuada se realizaron varias simulaciones que son mostradas en el Capitulo V.

En cuanto a la determinación del número de niveles hasta el cual se debe descomponer una señal existen varios criterios, el primero está basado en el concepto de entropía: en el se calcula la entropía de cada nivel y se compara con la del nivel anterior, si ésta resulta mayor, ya no es necesario seguir descomponiendo la señal y por lo tanto se determina el nivel de descomposición [20].

Un segundo criterio el cual es empleado en este trabajo, se basa en descomponer la señal hasta un nivel en el cual se obtenga la información necesaria para el caso particular que se esté realizando, la descomposición se puede realizar indefinidamente hasta que se obtenga una sola muestra de la señal, sin embargo, en la practica se escoge un número de niveles adecuado a la naturaleza de la señal. En nuestro caso particular se realizaron varias descomposiciones hasta diferentes niveles y se determinó que una descomposición de 6 niveles es adecuada para nuestra aplicación en particular.




Fig. 4.4. TDW realizada sobre una falla en el actuador de la válvula.

Una vez seleccionada la wavelet y determinado el número de niveles de descomposición, se aplica la TDW a la señal $y(t)$ obteniéndose un conjunto de coeficientes de aproximación y de detalles tal como lo ilustra la Fig. 4.4. En esta figura se puede observar la descomposición en 6 niveles de una falla del 10% en el span del actuador de la válvula.

La Fig. 4.4 muestra la señal $y(t)$ en el dominio del tiempo contaminada por ruido de fondo. Igualmente, muestra como en los dos primeros niveles de descomposición (niveles 1 y 2) la señal contiene la información de altas frecuencias y una gran cantidad de ruido contenido en estos coeficientes. Sin embargo, también se puede observar como la cantidad de ruido se atenúa conforme disminuye la frecuencia de la señal, específicamente a partir de los coeficientes $cd3$ hasta los $cd6$ y $ca6$, donde prácticamente la señal no contiene ruido. Las características que posiblemente pueden representar las distintas fallas o perturbaciones, se pueden extraer a partir de aquéllos coeficientes en los cuales la señal no esté contaminada en un alto porcentaje por ruido de fondo, esta condición se comienza a ver a partir de los coeficientes $cd3$ hasta $cd6$ y $ca6$. Nótese además que el número de coeficientes por banda disminuye.

4.2.2 Extracción de características (Feature Extraction)

La extracción de características consiste en extraer de la señal distorsionada (falla o perturbación), características relevantes que permitan diferenciar una señal distorsionada de otra clase de señal distorsionada, por ejemplo una falla producida en el actuador de la válvula y una falla en el transmisor.

El primer paso es realizar la TDW sobre la señal distorsionada, y obtener los coeficientes de detalles y coeficientes de aproximación los cuales son una representación de la señal a diferentes bandas de frecuencia (Fig. 4.4). Los coeficientes de aproximación representan la baja frecuencia de la señal y los coeficientes de detalles representan las altas frecuencias. Como se dijo anteriormente se realiza una descomposición wavelet de 6 niveles, esta

descomposición permite representar la señal original (posible falla) por medio del siguiente vector.

$$Wy = [ca6 : cd6 : cd5 : cd4 : cd3 : cd2 : cd1] \quad (4.11)$$

donde Wy representa la posible señal de falla en el dominio wavelet, $ca6$ los coeficientes de aproximación y $cd1$ hasta $cd6$ representan los coeficientes de detalles. La mas alta frecuencia de la señal está contenida en el coeficiente $cd1$ y va disminuyendo hasta llegar los coeficiente de menor frecuencia que son $ca6$ y $cd6$. Donde $ca6$ y $cd6$ son los vectores que contienen los $\left\lfloor \frac{n_{i-1} - 1}{2} \right\rfloor + i$ coeficientes de aproximación y detalles respectivamente, donde $\lfloor \chi \rfloor$ denota una aproximación por exceso de χ , n_{i-1} es la longitud de la señal en el nivel i de descomposición, en este caso particular seria la longitud de $ca5$, finalmente i es el nivel de descomposición actual, es decir 6.

Los coeficientes de la descomposición wavelet están conformados por una cantidad de muestras que dependen del nivel de descomposición en que estén ubicados dichos coeficientes.

Para el caso de la falla de la Fig. 4.4, cada coeficiente está conformado de acuerdo como la señala la Tabla 4.1.

Tabla 4.1. Número de muestras de los coeficientes que conforman la señal Wy .

Coeficientes	Número de muestras
$ca6$	13
$cd6$	13
$cd5$	20
$cd4$	34
$cd3$	62
$cd2$	118
$cd1$	229

la descomposición de la falla de la Fig. 4.4 se puede ilustrar también de la manera como lo muestra la Fig. 4.5. Puede observarse que Wy parte con un número de muestras igual a 451;

como resultado de la operación de submuestreo (dowsampling) implícito en el cálculo de la TDW, este número de muestras va disminuyendo a medida que la señal va pasando por cada nivel de descomposición, tal como lo muestran la Tabla 4.1 y la Fig. 4.5.




Fig. 4.5. Representación en forma de árbol de la TDW.

De este vector “ Wy ” se escogen aquellos coeficientes que aporten un porcentaje de energía significativo del total de la energía de la señal y se desprecian aquellos donde se encuentre concentrada la mayor cantidad de ruido. El ruido tiene la característica de contener altas frecuencias; por lo tanto, se encuentra almacenado en mayor grado en los coeficientes de más alta frecuencia. Si se observa la Fig. 4.4, estos coeficientes son $cd1$ y $cd2$, ya que puede notarse que hay una gran cantidad de ruido en dichos coeficientes, y el mismo va decreciendo conforme disminuye la frecuencia, específicamente desde $cd3$ hasta $cd6$. También, el aporte en cuanto a energía de estos coeficientes de alta frecuencia, es muy cercano a cero; por lo tanto, en vez de aportar alguna información relevante para el reconocimiento de la señal, aportan es una gran cantidad de datos ruidosos que dificultan la operación de diagnóstico de la falla y pudieran conducir a una clasificación errada del tipo

de falla. Adicionalmente se requiere de un mayor tiempo de calculo por la gran cantidad de datos.

Es importante resaltar que el vector característico puede estar conformado por otros elementos o características diferentes a los coeficientes de la TDW, es decir, se puede usar por ejemplo la cantidad de energía almacenada en una banda especifica de la TDW, o se puede usar el tiempo de duración de una falla o perturbación, el cual es proporcional al área bajo la curva de dicha falla o perturbación, en fin se puede usar cualquier característica que permita diferenciar una falla de otra falla.

Una vez seleccionados los coeficientes y/o características que van a conformar el vector característico (Feature vector) se tendría una expresión para dicho vector como sigue:

$$Vf = [ca_j : cd_j : : cd_{j+1} : , E_{j+1} , , A_j] \quad (4.12)$$

Con la utilización de este vector Vf se logra reducir el tamaño de datos necesarios para la operación de diagnóstico de la falla y a su vez se está utilizando la información de la señal que realmente es necesaria para la diferenciación entre las distintas fallas que se puedan estar presentando.

4.2.2.1 Generación de Patrones

Es necesario generar patrones para cada una de los tipos de fallas que se puedan presentar en la instrumentación, ya sea fallas en el actuador de la válvula, en el transmisor o alguna perturbación en las variables de entrada del proceso. Estos patrones son los que van a permitir reconocer la falla que se esté presentando, dichos patrones de fallas son almacenados en una base de datos. La Fig. 4.6 presenta un ejemplo de patrones para ciertas fallas en el actuador de la válvula y en el transmisor.

Como se observa en la Fig. 4.6a y 4.6b, cada clase de falla se forma por la generación de patrones de fallas de diferentes porcentajes, es decir, se puede presentar una falla en el span del actuador de la válvula (Fig. 4.6a) la cual posee un $\Delta q_{\max}$, que es el valor de desajuste, y este a su vez puede tomar los valores de 7.5%, 10%, 12.5%, 15% y 17.5% de su valor en operación normal ($Q_{\max}$). En la Fig. 4.6 cada porcentaje de desajuste está representado por un tipo de línea específica tal como lo indica la leyenda de la mencionada figura.




Fig. 4.6. Ejemplos de patrones de fallas.

Luego que han sido generados los distintos patrones para cada clase de falla, se calcula el promedio de estos, y se obtiene el centroide o valor promedio de la falla, el cual, representa la clase para la falla en el span del actuador de la válvula (Fig. 4.6a). De igual manera se hace para el resto de las fallas (Fig. 4.6b) que se presentan ya sea en el transmisor o las perturbaciones de las variables de entrada del proceso. Este procedimiento de generación de patrones se esquematiza en la Fig. 4.7, donde se ilustran algunas de las clases (centroide de la falla) para cada falla, y como estas, están circundadas por fallas patrones de diferentes porcentajes, conformando el espacio de clases de fallas generadas en un proceso.




Fig. 4.7. Espacio de clases de fallas generadas en un proceso.

Una vez generadas las distintas clases de fallas se procede a aplicarles el mismo procedimiento que se aplicó a la falla W_y (desajuste presentado en el proceso expresado en función de los coeficientes de la TDW), para de esta manera conformar el vector característico pero de las fallas que están almacenadas en la base de datos de patrones de fallas. El vector característico para cada una de las clases de fallas queda de la siguiente manera:

$$Vfc = [ca_j : cd_j : : cd_{j+1} : , E_{j+1} , , A_j] \quad (4.13)$$

Cuando ya se han conformado los vectores característicos de la falla desconocida y de cada una de las clases, se procede a reconocer y clasificar el patrón de falla desconocido y etiquetarlo como una de las clases de fallas ya almacenadas en la base de datos. Basándose en el vector característico asociado a cada una de las clases de fallas y comparándolo con el vector característico de la falla desconocida se puede conocer cual es el origen del desajuste que presenta el proceso y por lo tanto se realiza el diagnóstico de la falla.

4.2.3 Reconocimiento y Clasificación

El reconocimiento y clasificación de la falla se puede tratar con técnicas asociadas al reconocimiento de patrones. Los patrones asociados a una clase (falla de válvula por

ejemplo) son relativamente similares entre sí, mientras son relativamente disímiles a los de otra clase (falla de transmisor). Por lo tanto a este punto surge la pregunta, ¿de qué forma se puede medir la similitud entre patrones?. Una medida de este tipo se expresa de manera numérica para indicar el grado de asociación entre dos patrones en una clase, o entre un patrón y una clase, o entre dos clases de patrones.

Se puede definir el grado de similitud, como la distancia entre un patrón de entrada desconocido Vf y un grupo de patrones conocidos Vfc_i como

$$C = \arg \min_i (d(Vf, Vfc_i)) \quad (4.14)$$

donde d es una medida de la distancia entre Vf y el patrón conocido Vfc_i . Así, el patrón desconocido será asignado a la clase con la cual se obtenga la distancia más pequeña d . El número de distancias será igual, al número de patrones conocidos que se tengan.

En la literatura pueden encontrarse distintas expresiones para medir el grado de similitud pero las mas empleadas son medidas de distancias, y entre estas unas de las mas utilizadas son la distancia Euclideana y la distancia entre vecinos mas cercanos mejor conocida como K-Nearest Neighbor [21, 22].

4.2.3.1 Distancia Euclideana

Un patrón desconocido Vf (falla cualquiera) puede considerarse que pertenece a una cierta clase de falla, si y solo si, la distancia entre Vf y un prototipo Vf_v (falla en el actuador de la válvula) es menor que la distancia entre Vf y otro prototipo, por ejemplo Vf_T (falla de transmisor). La distancia Euclideana se calcula como sigue [9]:

$$d_E = \sqrt{[(Vf_v - Vf)(Vf_v - Vf)^T]} = \left(\sum (Vf_v - Vf)^2 \right)^{1/2} \quad (4.15)$$

En este trabajo se calcula la distancia Euclídeana entre el vector característico de la falla desconocida y cada uno de los vectores característicos de los centroides de las clases de fallas que se encuentran en la base de datos. Se obtienen tantas distancias Euclídeanas como clases de fallas se tengan.

Para ilustrar el procedimiento obsérvese la Fig.4.7, se calcula la distancia Euclídeana entre la falla desconocida (usando el vector característico Vf) y cada una de las clases de fallas (usando el vector característico Vfc del centroide de la clase). La clase de falla con la cual Vf presente la menor distancia Euclídeana, es un indicativo de la similitud de la falla desconocida con dicha clase; por lo tanto, se determina el tipo de falla o clase de falla que se está presentando.

4.2.3.2 K-Nearest Neighbor

El concepto adoptado para la distancia Euclídeana puede ser extendido al caso de la mínima distancia con respecto a un grupo de vectores característicos.

Sea $R_1, R_2, \dots, R_j$ los j grupos de vectores característicos asociados con las clases $S_1, S_2, \dots, S_j$, respectivamente, es decir, el grupo R_1 pertenece a la clase S_1 , R_2 pertenece a la clase S_2 y así sucesivamente. También denótense como $R_j^{(k)}$ a cada vector característicos perteneciente a cada uno de los grupos R_j , es decir, $R_j^{(k)} \in R_j$ con $k = 1, \dots, u_j$, donde u_j es el número de vectores característicos en el grupo R_j . Se define la distancia entre un patrón de entrada desconocido Vf y R_j como

$$d(Vf, R_j) = \min_{k=1, \dots, u_j} (Vf - R_j^{(k)}) \quad (4.16)$$

donde la distancia entre Vf y R_j , es la distancia más pequeña entre Vf y cada vector en R_j . El clasificador asignará el patrón desconocido a la clase a la cual pertenezca este grupo de vectores R_j [22]. El calculo de la distancia d se realiza a través de la ecuación 4.15.

Para este caso en particular se calcula la distancia Euclideana entre el patrón desconocido Vf (falla desconocida) y cada uno de los patrones R_j (Fig. 4.6) pertenecientes a las distintas clases S_j (ClaseV, ClaseT, ClaseP) que se encuentran en la base de datos, obteniéndose así tantas distancias Euclidianas como patrones de fallas se tengan. Luego se clasifica la falla en función de la menor distancia. Para ilustrar el método obsérvese la Fig. 4.8.




Fig. 4.8. Espacio de patrones de fallas generadas en un proceso.

Obsérvese en la Fig. 4.8, que existen tres clases de fallas (S_1, S_2, S_3) en el espacio de fallas, la ClaseV que representa un tipo de falla en el actuador de la válvula (falla en el span), la ClaseT que representa un tipo de falla en el transmisor (falla en la ZM del span) y la ClaseP que representa una perturbación en una de las variables de entrada del proceso. Todas estas clases están conformadas por diferentes porcentajes (cada porcentaje es un $R_j^{(k)}$) de la misma clase de falla.

El método consiste en calcular la distancia entre el vector característico (Vf) del patrón desconocido y cada uno de los vectores característicos de los patrones conocidos ($R_j^{(k)}$) que conforman la ClaseV, la ClaseT y la ClaseP. El patrón con el cual la falla desconocida presente la menor distancia Euclideana, es un indicativo de la similitud de la falla desconocida con dicho patrón y por ende con la clase a la cual pertenece este ultimo; por lo tanto se determina el tipo de falla que se está presentando en el proceso.

Licencia Creative Commons:

Atribución - No Comercial - Compartir Igual 3.0 Venezuela
(CC BY-NC-SA 3.0 VE)

4.2.4 Determinación del valor de porcentaje de desajuste.

La determinación del valor de porcentaje de la falla desconocida $y(t)$ se realiza de dos formas, una que está referida al clasificador de distancia Euclideana y otra referida al clasificador K-Nearest Neighbor.

Para el caso del clasificador de distancia Euclideana se aprovecha la información que se tiene sobre la distribución de la energía de la señal en cada banda de frecuencia de la TDW. De estos coeficientes se escoge el coeficiente de aproximación $ca6$ porque es el que mantiene una distribución de energía proporcional al porcentaje de falla, para cada uno de los porcentajes de falla que se presentan, es decir, la energía para cada porcentaje de falla se comporta de manera creciente o decreciente, pero, no ambos comportamientos a la vez (Fig. 4.9).

Lo que se hace es formar dos vectores, los cuales están estructurados de la siguiente manera:

$$X = [7.5\% \ 10\% \ 12.5\% \ 15\% \ 17.5\%] \quad (4.17)$$

El vector X representa los distintos porcentajes de desajustes o de falla que se pueden presentar en una clase de falla específica.

$$E_{ca} = [E_{ca7.5} \ E_{ca10} \ E_{ca12.5} \ E_{ca15} \ E_{ca17.5}] \quad (4.18)$$

El vector E_{ca} está conformado por la energía de los coeficientes de aproximación para cada porcentaje de desajuste, es decir $E_{ca7.5}$, representa la energía almacenada en el coeficiente de aproximación para una falla específica del 7.5%. De igual manera para el resto de los elementos del vector E_{ca} .

Luego que se han formado estos dos vectores se calcula la energía (Efd) de el coeficiente de aproximación de la falla desconocida, y con este valor se procede a realizar una interpolación y a determinar el porcentaje de desajuste. La Fig. 4.9 ilustra el procedimiento.




Fig. 4.9. Curva utilizada para interpolar y determinar el porcentaje de la Falla.

Con el valor de energía de los coeficientes de aproximación de la falla desconocida “ Efd ” se traza una horizontal hasta cortar la curva (Fig. 4.9), luego a partir de este punto de corte se traza una vertical hasta cortar el eje horizontal y se consigue el porcentaje estimado de la falla. Las ventajas y desventajas de este método se presentan en el Capítulo IV.

Para el caso del clasificador del vecino más cercano, se aprovecha la información que se tiene sobre la distancia Euclídeana de la falla desconocida con cada uno de los patrones que conforman el espacio de fallas. Cuando se ha determinado la menor distancia Euclídeana de la falla desconocida con un patrón cualquiera y, por ende con la clase a la cual pertenece, se procede a ordenar las distancias Euclídeanas obtenidas para esta clase, en orden ascendente. Con estas distancias se forma un vector D :

$$D = [d_{(1)}, d_{(2)}, d_{(3)}, \dots, d_{(n)}] \quad (4.19)$$

La distancia $d_{(1)}$ es la menor de todas las distancias del vector D , $d_{(2)}$ es la que le sigue en cuanto a su valor, y así sucesivamente. En este caso también se hace uso del vector X , el cual se ordena de acuerdo como quedan ordenadas las distancias Euclidianas en el vector D , es decir, el porcentaje 7.5 queda ubicado en la misma posición en la cual quedo ubicada la distancia Euclideana para un porcentaje del 7.5%, y así de igual manera para el resto de porcentajes.

Luego se procede a estimar el porcentaje de falla " P_{fe} " utilizando para ello un promedio entre los porcentajes mas cercanos a la falla desconocida. En este trabajo se estima el porcentaje de falla utilizando la media y la media ponderada de las distancias. Para ilustrar como se calcula la media del porcentaje de las distancias veamos el siguiente ejemplo:

Supongamos que se presenta una falla desconocida $y(t)$. Seguidamente se aplica el procedimiento explicado en los puntos 4.2.1 y 4.2.2. Después que se ha aplicado este procedimiento se pueden obtener los vectores X y D los cuales son el vector de porcentajes y el vector de distancias Euclidianas respectivamente.

- Primero, se ordena el vector D de distancias Euclidianas D de menor a mayor. Supongamos que dicho vector queda ordenado de la siguiente manera:

$$D = [d_{(1)}, d_{(2)}, d_{(3)}, \dots, d_{(n)}] \quad (4.20)$$

donde:

- $d_{(1)}$: Es la distancia Euclideana entre el patrón desconocido $y(t)$ y un patrón conocido de 12.5% de desajuste.
- $d_{(2)}$: Es la distancia Euclideana entre el patrón desconocido $y(t)$ y un patrón conocido de 7.5% de desajuste.
- $d_{(3)}$: Es la distancia Euclideana entre el patrón desconocido $y(t)$ y un patrón conocido de 10% de desajuste.

- $d_{(4)}$: Es la distancia Euclideana entre el patrón desconocido $y(t)$ y un patrón conocido de 15% de desajuste.

- $d_{(5)}$: Es la distancia Euclideana entre el patrón desconocido $y(t)$ y un patrón conocido de 17.5% de desajuste.

lo cual quiere decir, que la menor de las distancias es $d_{(1)}$ y la que le sigue en cuanto a su valor es $d_{(2)}$ y así sucesivamente para el resto de las distancias.

- Segundo, se ordena el vector X de acuerdo con el orden en que quedo ordenado el vector D , es decir.

$$X = [12.5\%, 7.5\%, 10\%, 15\%, 17.5\%] \quad (4.21)$$

- Tercero, se escoge un valor de K , dicho parámetro determina el número de distancias con el cual se va a calcular la media del porcentaje.

- Cuarto, se realiza la operación de la ecuación 4.22.

$$Pfe = \{X_{(1)} + X_{(2)} + \dots + X_{(K)}\} / K \quad (4.22)$$

la cual da una estimación del porcentaje de desajuste que se está presentando en el span del actuador de la válvula para este ejemplo en particular.

En cuanto a la media ponderada, se calcula de igual manera que el caso anterior, solo que ahora se tiene un vector adicional de ponderaciones W , el cual está conformado por los pesos que van a ponderar cada uno de los porcentajes del vector 4.17. Se obtienen tantos pesos como elementos en cada clase.

Una manera natural de escoger los pesos o ponderaciones es tomar el inverso de las distancias Euclidianas, así de esta manera aquellas distancias mas pequeñas, que son las

Licencia Creative Commons:

que están mas cerca de la falla desconocida serán ponderadas con un peso mayor que aquellas que estén mas alejadas.

El vector de pesos se expresa entonces como:

$$W = [1/d_{(1)}, 1/d_{(2)}, \dots, 1/d_{(n)}] \quad (4.23)$$

donde n es el número de distancias que conforman el vector (4.19), cada " $1/d_{(n)}$ " corresponde al peso de la distancia $d_{(n)}$. Cabe resaltar que el vector de pesos se ordena de igual manera como se hace con el vector X . Finalmente la media ponderada que determina el porcentaje de falla se expresa como:

$$Pfe = \frac{\{X_{(1)} * W_{(1)} + X_{(2)} * W_{(2)} + \dots + X_{(K)} * W_{(K)}\}}{\{W_{(1)} + W_{(2)} + \dots + W_{(K)}\}} \quad (4.24)$$

la cual da una estimación del porcentaje de desajuste que se esté presentando en el span del actuador de la válvula para este ejemplo en particular.

CAPITULO V

RESULTADOS

En este capítulo se presenta la aplicación del método de detección y diagnóstico de fallas utilizando la Transformada Wavelet al modelo de un proceso industrial. La detección y el diagnóstico de la falla se hace con el uso de la señal de salida del transmisor. El modelo sobre el cual se realiza el estudio es un tanque de precalentamiento cuyas especificaciones serán dadas brevemente a continuación, mayores detalles del proceso simulado pueden ser encontrados en [23].

5.1 Especificaciones para la Simulación

-Las fallas se modelan adicionando términos a los parámetros de los instrumentos del proceso, específicamente actuador de la válvula y transmisor.

- Se consideran perturbaciones desde 7.5 hasta 17.5 del valor normal en el flujo de entrada Q_1 .

- Se asume que se produce una sola falla a la vez, ya sea en el actuador de la válvula o en el transmisor.

5.2 Descripción del proceso industrial

El método propuesto es aplicado a un proceso lineal, para fallas en el transmisor y en el actuador de la válvula. El proceso consiste en un tanque que recibe un flujo caliente, $Q_1(t)$, y otro flujo frío, $Q_2(t)$ los cuales son mezclados para obtener una temperatura $T_3(t)$ deseada a la salida. La variable manipulada es el flujo de agua fría Q_2 , para mantener la temperatura

Licencia Creative Commons:

Atribución - No Comercial - Compartir Igual 3.0 Venezuela
(CC BY-NC-SA 3.0 VE)

de salida T_3 en el nivel establecido. La temperatura de salida es medida a 125 ft del tanque aguas abajo. La Fig.5.1 muestra el proceso sobre el cual se realizaron las simulaciones. Se asume que:

- El volumen del líquido en el tanque es constante.
- El contenido está bien mezclado.
- El tanque y la tubería están bien aislados.

La información del proceso y los valores en estado estacionario están descritos en la Tabla 5.1.




Fig. 5.1. Tanque de Mezclado.

Tabla. 5.1. Información del proceso y valores en estado estacionario.

Variable	Valor	Variable	Valor
Q_1	250 lb/min	V	15 ft ³
Q_2	191.17 lb/min	TO	0.5
C_{p1}	0.8 BTU/lb-°F	V_p	0.478
C_{p2}	1.0 BTU/lb-°F	C_{v1}	12 gpm/psi ^{1/2}
$C_{p3} C_{v3}$	0.9 BTU/lb-°F	ΔP_v	16psi
Referencia	150°F	τ_T	0.5min
T_1	250°F	τ_{vp}	0.4min
T_2	50°F	A	0.2006 ft ²
T_3	150°F	L	125 ft

Ecuaciones que describen el proceso:

- Balance de energía alrededor del tanque de mezclado

$$Q_1(t)Cp_1(t)T_1(t) + Q_2(t)Cp_2(t)T_2(t) - (Q_1(t) + Q_2(t))Cp_3(t)T_3(t) = V\rho C_{v_3} \frac{dT_3(t)}{dt} \quad (5.1)$$

El transmisor y la válvula se simulan como sistemas de primer orden. Estas ecuaciones fueron explicadas en detalle en el Capítulo I sección 1.2.1:

- Transmisor de temperatura

$$\frac{dT_O(t)}{dt} = \frac{1}{\tau_T} \left[\frac{T_A(t) - 100}{100} - T_O(t) \right] \quad (5.2)$$

- Ecuación de la válvula

$$Q_2 = \frac{500}{60} C_{vL} V_P(t) \sqrt{G_f \Delta P_V} \quad (5.3)$$

- Actuador de la válvula

$$\frac{dV_P(t)}{dt} = \frac{1}{\tau_{V_P}} [m(t) - V_P(t)] \quad (5.4)$$

- Estrategia de control

Se utilizó un controlador proporcional-integral (PI), cuya sintonización se realizó por el método de Dahlin.

A través de las ecuaciones del proceso y sus valores en estado estacionario se simuló dicho proceso con el paquete MATLAB-Simulink. Las simulaciones permiten obtener la señal

del error usada para detectar la falla y la señal de salida del transmisor que es la señal que va a ser analizada a través de la Transformada Discreta Wavelet para diagnosticar las posibles fallas o perturbaciones.

5.3 Simulación de las Fallas

Las fallas son simuladas como desviaciones tipo escalón, las cuales se adicionan a los parámetros de los instrumentos, de manera tal que simulen posibles fallas en la instrumentación utilizada en el proceso (válvula y transmisor), de igual manera se hace con las perturbaciones. Dichas desviaciones se introducen en los parámetros del instrumento, específicamente en los señalados en las ecuaciones 2.9 a la 2.13 para el caso del actuador de la válvula (descritas en detalle en el Capítulo II). En cuanto al transmisor la desviaciones se introducen de manera similar al actuador de la válvula.

Los valores de las desviaciones bajo los cuales van a ser simuladas las posibles fallas se muestran en las Tablas 5.2.

Tabla. 5.2a Desviaciones presentadas en el actuador de la válvula.

Tipo de Falla	Parámetro desviado	Porcentajes de Desviación
Span	Q_{max}	$\Delta Q_{max}=7.5, 10, 12.5, 15, 17.5$
ZM del Span	m_{max}	$\Delta m_{max}=7.5, 10, 12.5, 15, 17.5$
Calibración de Cero	Q_{min}	$\Delta Q_{min}=7.5, 10, 12.5, 15, 17.5$
ZM de Cero	m_{min}	$\Delta Q_{min}=7.5, 10, 12.5, 15, 17.5$

Tabla. 5.2b Desviaciones presentadas en el transmisor.

Tipo de Falla	Parámetro desviado	Porcentajes de Desviación
Span	TO_{max}	$\Delta TO_{max}=7.5, 10, 12.5, 15, 17.5$
ZM del Span	T_{3max}	$\Delta T_{3max}=7.5, 10, 12.5, 15, 17.5$
Calibración de Cero	TO_{min}	$\Delta TO_{min}=7.5, 10, 12.5, 15, 17.5$
ZM de Cero	T_{3min}	$\Delta T_{3min}=7.5, 10, 12.5, 15, 17.5$

Para cada una de estas fallas de las Tablas 5.2 se obtuvieron los vectores característicos generándose así la base de datos correspondiente para ser usada en la clasificación de las fallas.

5.4 Resultados de las Simulaciones

Dos métodos de clasificación para diagnosticar las fallas son propuestos; la distancia Euclideana y la distancia entre el vecino mas cercano (K-Nearest Neighbor). Los dos métodos son comparados usando una matriz de clasificación y calculando la exactitud de cada clasificador para diagnosticar las fallas.

5.4.1 Clasificador por Distancia Euclideana

Una serie de fallas y perturbaciones fueron generadas en el actuador de la válvula, en el transmisor y en el flujo de entrada Q_1 (perturbación). Se generó un grupo de 5000 señales el cual es dividido en cinco grupos de 1000 señales. Cada grupo de 1000 representa un tipo de falla. Se trabaja con diferentes niveles de ruido, es decir, el termino $\eta(t)$ de la ecuación 3.1 que representa el ruido de fondo de la señal de falla tendrá tres valores diferentes de varianza, mas específicamente, $\sigma^2=0.025$, 0.05 y 0.1 y la media de dicho ruido es cero.

Usando el método propuesto de extracción de características, para obtener las características mas resaltantes que permitan diferenciar una señal de falla de otra clase de falla, se construye el vector característico para cada tipo de falla. Cada señal de falla contiene 489 muestras y al extraer las características mas resaltantes se pretende reducir el número de muestras en un grado considerable, para de esta manera reducir el tiempo de calculo para diagnosticar la falla.

Estando el proceso en condiciones normales de operación en las cuales la temperatura de salida T_3 es de 150 °F, se tiene un valor de índice de funcionamiento IAE_{CNO} . Este valor de IAE se calculó en el dominio wavelet utilizando el coeficiente de aproximación **ca6**. Al generarse los diferentes tipos de fallas que se van a estudiar y clasificar, el índice de funcionamiento cambia y alcanza los valores que se muestran en las Tablas 5.3.

Tabla. 5.3a. Índices de funcionamiento en condiciones normales de operación.

σ^2	IAE_{CNO}
0.025	1.6609
0.05	3.9694
0.1	6.6212

Tabla. 5.3b. Índices de funcionamiento para las condiciones de fallas presentadas.

Falla	IAE_{CF}		
	$\sigma^2=0.025$	$\sigma^2=0.05$	$\sigma^2=0.1$
F13v	12.3060	13.3542	14.2465
F39v	10.9861	12.9252	13.6190
F28t	11.8836	13.8692	9.7163
F416t	12.6562	8.5884	8.7390
Pert17.5	7.7577	15.4432	9.3184

Donde:

IAE_{CNO} es el valor de IAE en condiciones normales de operación.

IAE_{CF} es el valor de IAE en condición de falla.

F13v es una falla del 13% en el span del actuador de la válvula.

F39v es una falla del 9% en la calibración de cero del actuador de la válvula.

F28t es una falla del 8% en la ZM del span, del transmisor de temperatura.

F416t es una falla del 16% en la ZM de cero del transmisor de temperatura.

Pert17.5 es una perturbación del 17.5% en el flujo Q_1 .

Es importante recordar que ocurre una sola falla a la vez, no todas al mismo tiempo. Sin embargo, se realiza el estudio de cinco fallas diferentes para probar el desempeño de los clasificadores.

Como el valor de IAE para cada una de las condiciones de falla es significativamente más grande que el valor de IAE en condiciones normales de operación, se puede afirmar que existe la presencia de desajustes en el proceso que podrían estar siendo ocasionados por posibles fallas o perturbaciones. En los siguientes pasos se va a tratar de diagnosticar que

Licencia Creative Commons:

Atribución - No Comercial - Compartir Igual 3.0 Venezuela
(CC BY-NC-SA 3.0 VE)

clase de falla o perturbación es la que se está presentando, y también se va a estimar el porcentaje de desajuste que ocasionan.

En las Fig. 5.2 se muestran los patrones de fallas generados por cada una de las fallas señaladas en las Tablas 5.3b. Es indudable que las cinco fallas de la Fig. 5.2 (fallas sin ruido) son bastantes similares entre si y que eventualmente podría ser complicado diferenciar una de otra.




Fig. 5.2. Fallas sin ruido.

Igualmente; en las Fig. 5.3 se muestran las mismas fallas pero con ruido de fondo; en este caso es aun más difícil diferenciar una de otra. En la Fig. 5.3a están graficadas las cuatro fallas y la perturbación; de hecho no se aprecia claramente donde comienza o termina una u otra falla, el resto de las figuras (desde la b hasta la f) muestra cada una de las fallas pero de forma separada tal como lo especifica la leyenda. Estas cinco fallas son las que se van a tratar de diagnosticar.




Fig. 5.3. Fallas con ruido de fondo. Las fallas de las Fig. 5.3b, c, d, e, fueron descritas en la sección 4.4.1

Luego de que se generan las fallas se realiza la descomposición de cada una de las fallas a través de la transformada discreta wavelet (TDW). Ahora bien, para poder realizar la TDW es necesario seleccionar una wavelet específica con la cual se van a analizar las fallas, en este caso en particular se comenzó por el uso de la wavelet Daubechies, concretamente la db4. También, era necesario determinar el número de niveles de descomposición, el cual, se estima realizando varias descomposiciones hasta diferentes niveles y se determinó que una descomposición de 6 niveles era adecuada para nuestra aplicación en particular.

Después que se aplicó la TDW a cada una de las fallas, era necesario establecer cual sería el vector característico que se utilizaría para la clasificación de las distintas fallas. Para realizar esta tarea se conformaron diferentes *vectores característicos* y se realizaron pruebas de clasificación de fallas para determinar cual de estos vectores era el que proporcionaba mejores resultados. En estas primeras simulaciones se conformaron 7 *vectores característicos*.

En la Tabla 5.4 se muestran estos vectores y se explica en detalle cuales son los elementos que conforman cada vector.

Tabla 5.4. Descripción de los vectores característicos.

Vector Característico	Características usadas en el <i>vector característico</i>
1. $V_f = [ca6\ cd2\ cd3\ cd4\ cd5\ cd6]$	Vector conformado por el coeficiente de aproximación <i>ca6</i> , y los coeficientes de detalles <i>cd2</i> hasta <i>cd6</i> .
2. $V_f = [ca6\ cd3\ cd4\ cd5\ cd6]$	Coeficiente <i>ca6</i> , y los coeficientes <i>cd3</i> hasta <i>cd6</i> .
3. $V_f = [ca6\ cd4\ cd5\ cd6]$	Coeficiente <i>ca6</i> , y los coeficientes <i>cd4</i> hasta <i>cd6</i> .
4. $V_f = [ca6\ cd5\ cd6]$	Coeficiente <i>ca6</i> , <i>cd5</i> y <i>cd6</i> .
5. $V_f = [ca6\ cd6]$	Coeficiente <i>ca6</i> y <i>cd6</i> .
6. $V_f = [ca6\ cd3\ cd4\ cd5\ cd6\ A]$	Igual que el vector 2 pero agregando <i>A</i> , donde <i>A</i> es una medida proporcional al tiempo de duración de la falla.
7. $V_f = [ca6\ cd3\ cd4\ cd5\ cd6\ Ecd5\ Eca6]$	Igual que el vector 2 pero agregando la energía almacenada en los coeficientes <i>cd5</i> y <i>ca6</i> .

Para determinar cual de estos 7 *vectores característicos* es el mas apropiado para clasificar las fallas, se procedió a calcular la exactitud o porcentaje de exactitud de clasificación obtenido para cada uno de los diferentes vectores. El porcentaje de exactitud del clasificador se calculó de acuerdo con la siguiente ecuación [9]:

$$exactitud = \frac{N_{correctas}}{N_{Total}} * 100 \quad (5.5)$$

donde $N_{correctas}$ es el número de clasificaciones correctas y N_{Total} es el número total de realizaciones del experimento incluyendo las clasificaciones erróneas. Mas adelante se muestra cómo se calculó este porcentaje de exactitud.

La Tabla 5.5 muestra los resultados obtenidos para cada uno de los patrones de fallas que se generaron, los cuales están señalados en la Tabla 5.3b. Como se observa en la Tabla 5.5 para cada vector característico se estimó, el porcentaje de datos utilizado por cada uno de

estos vectores característicos en base al total de muestras que tiene la señal que son 489, este porcentaje se estima de acuerdo con la siguiente ecuación:

$$\%data\ utilizado = \frac{longitud\ de\ Vf}{489} * 100 \quad (5.6)$$

Se estimó también el tiempo que dura la simulación, pero este se expreso en una unidad de tiempo, es decir, se toma aquella simulación que dura el menor tiempo y a ésta se le asigna el valor de la unidad, el resto de los tiempos de las simulaciones se estiman dividiendo estos entre la unidad ya fijada. Igualmente puede observarse que se tiene un porcentaje de exactitud de clasificación para cada nivel de ruido. Dicho nivel de ruido afecta la exactitud del clasificador ya que como se ve este hace disminuir la exactitud del clasificador.

Tabla 5.5. Vectores característicos utilizados para la clasificación de las fallas. Wavelet usada db4.

Vector Feature	%datos utilizado	ts(p.u)	Exactitud		
			$\sigma^2=0.025$	$\sigma^2=0.05$	$\sigma^2=0.1$
1. $Vf=[ca6\ cd2\ cd3\ cd4\ cd5\ cd6]$	53.17	2.67	95.18	91.04	86.8
2. $Vf=[ca6\ cd3\ cd4\ cd5\ cd6]$	29.04	1.22	95.74	92.28	86.82
3. $Vf=[ca6\ cd4\ cd5\ cd6]$	16.36	1.22	95.2	90.74	84.82
4. $Vf=[ca6\ cd5\ cd6]$	9.41	1.11	94.52	90.6	86.04
5. $Vf=[\ ca6\ cd6]$	5.32	1	92.72	89.78	84.38
6. $Vf=[ca6\ cd3\ cd4\ cd5\ cd6\ A]$	29.24	3.33	96.28	92.36	86.56
7. $Vf=[\ ca6\ cd3\ cd4\ cd5\ cd6\ Ecd5\ Eca6]$	29.45	1.22	64.4	47.2	35.6

Realizando una análisis de la Tabla 5.5 se puede decir que:

- El vector característico que genera los porcentajes mas altos de clasificación es el vector identificado con el número 6, el cual utiliza un 29.24% del total de muestras de la señal, pero, también se nota que es el que necesita mas tiempo para la simulación, específicamente 3.33 unidades de tiempo. La razón por la cual este vector es el que

tarda más tiempo en la simulación es debido a que el calculo del tiempo de duración de la falla agrega un tiempo de calculo adicional de mas o menos un 333%.

- El vector que le sigue en cuanto a porcentaje de exactitud de clasificación es el vector 2, este tiene porcentajes menores de exactitud, pero el tiempo necesario para la simulación se reduce a 1.22 unidades de tiempo.
- Igualmente el vector 5 realiza la simulación en un tiempo menor al vector 2 pero los porcentajes de exactitud en la clasificación también disminuyen.
- El vector 7 tarda poco tiempo en la simulación. Sin embargo, los porcentajes de exactitud son los mas bajos de todas las simulaciones realizadas.
- En cuanto a los vectores 3 y 4, tanto el tiempo de simulación como los porcentajes de exactitud son buenos o aceptables, pero desmejoran la exactitud comparados con el vector 2.

Por lo tanto, el vector característico seleccionado para clasificar las fallas es el vector identificado con el número 2, debido a que es el que presenta un buen equilibrio en cuanto a tiempo de simulación y porcentaje de exactitud para clasificar las fallas.

El vector 2 está conformado por un número total de elementos los cuales están distribuidos de la siguiente manera:

- **ca6**: 13 elementos
- **cd6**: 13 elementos
- **cd5**: 20 elementos
- **cd4**: 34 elementos
- **cd3**: 62 elementos

El número total de elementos del vector característico es 142, por lo tanto, se está utilizando un 29.04% del total de muestras de la señal ya que las señales de falla generadas contienen cada una un número total de elementos de 489.

Seguidamente que se determinó el mejor vector característico se procedió a estimar cual era la wavelet mas adecuada para clasificar las distintas fallas. Lo que se hizo fue realizar varias simulaciones con las fallas de la Tabla 5.3 pero con diferentes tipos de wavelets. Los resultados de estas simulaciones se muestran en la Tabla 5.6.

Tabla 5.6. Selección de la wavelet mas apropiada para el diagnóstico de las fallas.

$$V_f = [ca6 \text{ } cd3 \text{ } cd4 \text{ } cd5 \text{ } cd6]$$

Wavelet Usada	ts(p.u)	Exactitud		
		$\sigma^2=0.025$	$\sigma^2=0.05$	$\sigma^2=0.1$
db4	1	95.74	92.28	86.82
db8	2.18	96.28	91.66	86.72
db20	2.73	95.96	91.48	85.4
bior3.5	2.36	93	87.86	81.82
bior6.8	1.82	95.54	91.44	87

Como se observa en la Tabla 5.6, para cada tipo de wavelet se estimó el tiempo que dura la simulación y también se calculó el porcentaje de exactitud para clasificar las fallas que se obtiene con cada una de estas wavelet. Estos resultados señalan que la wavelet con la cual se obtienen los porcentajes más altos de exactitud es la db8. Sin embargo, se requiere de un tiempo de simulación de 2.18 unidades de tiempo, esto es debido a que la db8 contiene 16 coeficientes para descomposición y 16 para reconstrucción, lo que implica un mayor tiempo de cálculo, por lo tanto se escoge la wavelet que le sigue en cuanto a porcentaje de exactitud y también aquella que presenta el menor tiempo de simulación la cual es db4.

Finalmente, se determinó que el vector característico mas adecuado para realizar el diagnóstico de las fallas era el vector numero 2 de la Tabla 5.5 y la wavelet más adecuada era la db4.

El comportamiento del clasificador por distancia Euclideana utilizando las especificaciones anteriormente descritas es mostrado en las Tablas 5.7.

Como se mencionó en el Capítulo III, se calcula la distancia Euclideana entre el vector característico seleccionado (de la falla desconocida) de la Tabla 5.5 y cada una de las clases de fallas que se encuentran en la base de datos. Para cada una de las fallas “desconocidas” (Tabla 5.3b) y cada una de las clases de fallas que se encuentran en la base de datos se conformo un vector característico que tiene las características del vector característico seleccionado.

Se obtienen tantas distancias Euclideanas como clases de fallas se tengan, en este caso de acuerdo con la Tabla 5.7 se tienen cinco clases de fallas. La clase de falla con la cual el vector característico de la falla desconocida presente la menor distancia Euclideana, es un indicativo de la similitud entre la falla desconocida con dicha clase; por lo tanto, se determina el tipo de falla o clase de falla que se está presentando.

Tabla 5.7. Matriz de clasificación usando distancia Euclideana.

5.7.a. $\sigma^2 = 0.025$.

Clases de Fallas	F13v	F39v	F28t	F416t	Pert175n	Exactitud
cla1v (falla en el Span del actuador de la válvula)	877	3	0	0	87	
cla3v (falla calibración de cero del actuador de la válvula)	0	997	0	0	0	
Cla2t (falla ZM del Span del transmisor)	0	0	1000	0	0	
Cla4t (falla ZM de cero del transmisor)	0	0	0	1000	0	
pert1(perturbación en el flujo W_1)	123	0	0	0	913	95.74

5.7.b. $\sigma^2 = 0.05$.

Clases de Fallas	F13v	F39v	F28t	F416t	Pert175n	Exactitud
cla1v (falla en el Span del actuador de la válvula)	789	37	0	0	134	
cla3v (falla calibración de cero del actuador de la válvula)	4	960	0	0	0	
Cla2t (falla ZM del Span del transmisor)	0	0	999	0	0	
Cla4t (falla ZM de cero del transmisor)	0	0	1	1000	0	
pert1(perturbación en el flujo W_1)	207	3	0	0	866	92.28

5.7.c. $\sigma^2 = 0.1$.

Clases de Fallas	F13v	F39v	F28t	F416t	Pert175n	Exactitud
cla1v (falla en el Span del actuador de la válvula)	699	68	0	0	214	
cla3v (falla calibración de cero del actuador de la válvula)	22	898	0	0	2	
Cla2t (falla ZM del Span del transmisor)	0	0	961	1	0	
Cla4t (falla ZM de cero del transmisor)	0	0	39	999	0	
pert1(perturbación en el flujo W_1)	279	34	0	0	784	86.82

Licencia Creative Commons:

Atribución - No Comercial - Compartir Igual 3.0 Venezuela
(CC BY-NC-SA 3.0 VE)

Cada una de las fallas de la Tabla 5.7 se hace pasar por el clasificador 1000 veces para cada nivel de ruido; es decir, que se estaría pasando 3000 mil veces debido a que hay tres niveles de ruido. Cada vez que la señal pasa por el clasificador se calcula la distancia Euclideana del vector característico de la falla desconocida con cada una de las clases de falla y se cuenta cuantas veces se clasifica correctamente e incorrectamente. Este procedimiento se aplica a cada una de las fallas que se quieren diagnosticar.

En la matriz de clasificación (Tablas 5.7) el número de clasificaciones correctas se encuentran a lo largo de la diagonal principal y las clasificaciones incorrectas están distribuidas en el resto de los elementos de la matriz. Así, por ejemplo, para un nivel de ruido de 0.05, de las 1000 veces que se hace pasar la falla generada en la válvula con un 13% de desajuste, 78.9% de las veces se clasifico correctamente, 20.7% de las veces se clasifico incorrectamente ya que se confundió con una perturbación, finalmente 4% se confundió como falla tipo cla3v (falla calibración de cero del actuador de la válvula).

Para el caso de un nivel de ruido de 0.025 el porcentaje de exactitud se calculó de acuerdo con la ecuación 5.5 como sigue:

$$exactitud = \frac{877 + 997 + 1000 + 1000 + 913}{5000} * 100 = \frac{4787}{5000} * 100 = 95.74\% .$$

$$exactitud = 95.74\% .$$

de igual manera se realizo para los otros niveles de ruido.

Las Tablas 5.7 muestran que el porcentaje de exactitud del clasificador disminuye conforme aumenta el nivel del ruido, ahora bien esta disminución se debe a que aumenta el número de clasificaciones incorrectas para el caso de F13v y Pert175n, esta falla y perturbación son las que presentan mas similitud de acuerdo con la Fig. 5.2 y los resultados de las Tablas 5.7 corroboran esta similitud, ya que las clasificaciones incorrectas de F13v

son clasificadas como Pert175n, y las clasificaciones incorrectas de Pert175n son ubicadas en F13v.

Una vez identificadas las fallas se procedió a estimar el porcentaje de desajuste que producen cada una de estas fallas y perturbaciones sobre los instrumentos del proceso. El valor de porcentaje de la falla desconocida se estimó utilizando los métodos descrito en el Capítulo III sección 4.3.4. Igualmente, para estimar la robustez del clasificador estimando el porcentaje de desajuste, se procedió a realizar simulaciones de fallas desde 7.5% hasta 17.5% de desajuste, incrementando el porcentaje cada 0.5% obteniéndose un total de 21 fallas por clase. Luego se calculó el error promedio para cada clase de falla y perturbación. Estos resultados se muestran en la Tabla 5.8.

Tabla 5.8. Porcentaje de desajuste estimado utilizando la Fig 3.9.

Patrón de Falla	%error, $\sigma^2 = 0.025$	%error, $\sigma^2 = 0.05$	%error, $\sigma^2 = 0.1$
cla1v	37.3	40.2	58.8
cla3v	25.6	26.9	28.3
cla2t	24.2	25.5	22.2
cla4t	53	48.4	66.7
cla1p	37.5	43.57	42.80

cla1v: fallas en el span del actuador de la válvula.

cla3v: fallas en la calibración de cero del actuador de la válvula.

cla2t: fallas en la ZM del span del transmisor de temperatura.

cla4t: fallas en la ZM de cero del transmisor de temperatura.

cla1p: perturbaciones en el flujo Q_1 .

La Tabla 5.8 muestra el error promedio de estimación del porcentaje de desajuste presentado tanto para fallas como para perturbaciones, se observa que el error promedio aumenta conforme aumenta el nivel de ruido, también se observa que el menor error se produce para el caso de cla2t la cual corresponde a fallas en el transmisor del tipo falla en la zona muerta del span, este resultado es prácticamente independientemente del nivel de ruido.

En general los errores producidos por este método son bastante considerables incluso para el caso de cla2t que es el que tiene los errores más pequeños, por lo tanto, la estimación del porcentaje de desajuste utilizando este método no es buena.

5.4.2 Clasificador por K-Nearest Neighbor

Para el caso del clasificador K-Nearest Neighbor se utilizaron las mismas fallas de la Tabla 5.3, de igual manera se estimaron los valores de *IAE* para detectar los posibles desajustes en el proceso. Los valores de *IAE* coinciden con los de la Tabla 5.3 ya que el calculo de estos no depende del clasificador que se esté utilizando, y como se menciono anteriormente se están usando las mismas fallas.

De igual manera que en el clasificador por distancia Euclideana, luego que se generaron las fallas se realizó la descomposición de cada una de las fallas a través de la transformada discreta wavelet (TDW). El estudio de la determinación de la wavelet mas adecuada, el número de niveles de descomposición y la elección del vector característico no se realizo de nuevo ya que estos no dependen del clasificador, por lo tanto, estos tres parámetros son los mismos que para el caso del clasificador por distancia Euclideana.

Los resultados obtenidos para el clasificador por K-Nearest Neighbor se muestran en las Tablas 5.9, igual que para el caso de Distancia Euclideana se realizo una matriz de clasificación donde, el número de clasificaciones correctas se encuentran a lo largo de la diagonal principal y las clasificaciones incorrectas están distribuidas por el resto de elementos de la matriz.

Tabla 5.9. Matriz de clasificación usando K-Nearest Neighbor.

5.9.a. $\sigma^2 = 0.025$.

Patrones de Fallas	F13v	F39v	F28t	F416t	Pert1175	Exactitud
cla1v (falla en el Span del actuador de la válvula)	882	0	0	0	89	
cla3v (falla calibración de cero del actuador de la válvula)	1	1000	0	0	0	
cla2t (falla ZM del Span del transmisor)	0	0	999	0	0	
cla4t (falla ZM de cero del transmisor)	0	0	1	1000	0	
pert1 (perturbación en el flujo Q_1)	117	0	0	0	911	95.84

Licencia Creative Commons:

Atribución - No Comercial - Compartir Igual 3.0 Venezuela
(CC BY-NC-SA 3.0 VE)

5.9.b. $\sigma^2 = 0.05$.

Patrones de Fallas	F13v	F39v	F28t	F416t	Pert1175	exactitud
cla1v (falla en el Span del actuador de la válvula)	791	20	0	0	126	
cla3v (falla calibración de cero del actuador de la válvula)	7	978	0	0	1	
cla2t (falla ZM del Span del transmisor)	0	0	983	0	0	
cla4t (falla ZM de cero del transmisor)	0	0	17	1000	0	
pert1(perturbación en el flujo Q_1)	202	2	0	0	873	92.5

5.9.c. $\sigma^2 = 0.1$.

Patrones de Fallas	F13v	F39v	F28t	F416t	Pert1175	exactitud
cla1v (falla en el Span del actuador de la válvula)	681	57	0	0	239	
cla3v (falla calibración de cero del actuador de la válvula)	43	933	0	0	14	
cla2t (falla ZM del Span del transmisor)	0	0	949	1	0	
cla4t (falla ZM de cero del transmisor)	0	0	51	999	0	
pert1(perturbación en el flujo Q_1)	276	10	0	0	747	86.18

Los resultados de las Tablas 5.9, muestran una similitud con los resultados de las Tablas 5.7 en cuanto a que aumenta el número de clasificaciones incorrectas para el caso de F13v y Pert175, como se dijo en párrafos anteriores esta falla y perturbación son las que presentan mas similitud de acuerdo con la Fig. 5.3 y los resultados de las Tablas 5.7 y 5.9 confirman esta similitud. Igualmente en este clasificador (K-Nearest Neighbor) la exactitud del mismo se ve afectada negativamente por el nivel de ruido que se este presentando, sobre todo en aquellas fallas y/o perturbaciones que presenten mayor similitud específicamente F13v y Pert175.

Una vez identificadas las fallas se procedió a estimar el porcentaje de desajuste que producen cada una de estas fallas y perturbaciones sobre los instrumentos del proceso. Dicha estimación se realizó utilizando el método descrito en el Capítulo III sección 3.3.4. Estos resultados se muestran en las Tablas 5.10 y 5.11.

Tabla 5.10. Porcentaje de desajuste estimado con la media de las distancias.

5.10a. $k=3$.

Patrón de Falla	%error, $\sigma^2 = 0.025$	%error, $\sigma^2 = 0.05$	%error, $\sigma^2 = 0.1$
cla1v	11.7	12.3	11.6
cla3v	8.8	9.3	10.7
cla2t	9.60	11.6	11.6
cla4t	8.1	10	9.2
cla1p	9.53	9.1	7.83

Licencia Creative Commons:

Atribución - No Comercial - Compartir Igual 3.0 Venezuela
(CC BY-NC-SA 3.0 VE)

5.10b. $k=2$.

Patrón de Falla	%error, $\sigma^2 = 0.025$	%error, $\sigma^2 = 0.05$	%error, $\sigma^2 = 0.1$
cla1v	6.4	8.3	12.9
cla3v	6	6	9.5
cla2t	7.4	8.5	9.1
cla4t	5.6	6.1	7.0
cla1p	6.65	7.12	8.34

La Tabla 5.10 muestra el error promedio de estimación del porcentaje de desajuste presentado, en este caso, calculado con la media de las distancias Euclidianas usando dos valores de k . Se observa que el porcentaje de error es afectado nuevamente por el nivel de ruido. Sin embargo, es afectado en menor grado que para el caso del clasificador por distancia Euclidea. También se puede observar que el menor error se comete para el caso de cla4t ya sea para $k=2$ o $k=3$. El valor de k es un parámetro que influye sobre la estimación del error ya que como lo muestra la Tabla 5.10 cuando k es igual a dos el error de estimación disminuye para casi todos los casos, esto es debido a que cuando k crece el valor calculado por la estimación se aleja del valor verdadero, ya que esa tercera distancia está muy alejada del valor mas cercano al valor verdadero de desajuste.

Tabla 5.11. Porcentaje de desajuste estimado con la media ponderada de las distancias.

5.11a. $k=3$.

Patrón de Falla	%error, $\sigma^2=0.025$	%error, $\sigma^2=0.05$	%error, $\sigma^2=0.1$
cla1v	8.8	13	10.7
cla3v	8.3	8.7	9.3
cla2t	11	9.9	8.3
cla4t	9.6	8.2	9.8
cla1p	7.85	6.03	8.5

5.11b. $k=2$.

Patrón de Falla	%error, $\sigma^2=0.025$	%error, $\sigma^2=0.05$	%error, $\sigma^2=0.1$
cla1v	8.1	9.2	12.4
cla3v	5.9	7.2	8.1
cla2t	6.9	8.7	9.3
cla4t	5.8	6.1	7.1
cla1p	8.31	9.28	9.9

La Tabla 5.11 muestra los resultados concernientes a la estimación del porcentaje de desajuste estimado a través del uso de la media ponderada, igualmente para valores de k de 3 y 2. Para el caso de $k=3$, el menor error se comete para Pert1, pero en este caso también el

error es afectado por el nivel de ruido presente en la señal, conforme aumenta el nivel de ruido aumenta el error en la estimación del porcentaje de desajuste.

Para el caso de $k=2$, el menor error se comete para cla4t, igualmente el error es afectado por el nivel de ruido presente en la señal.

Finalmente observando las Tablas 5.10 y 5.11 se puede decir que los menores errores se cometen cuando se estima el error utilizando la media de las distancias y para un valor de $k=2$.

5.5 Comparación entre el clasificador por Distancia Euclideana y K-Nearest Neighbor

Para realizar la comparación entre estos dos clasificadores se compararon los porcentajes de exactitud de cada una de las matrices de clasificación y se realizaron varios gráficos de barras para observar el comportamiento de cada uno de los clasificadores.

Tabla 5.12 Comparación entre el clasificador por Distancia Euclideana K-Nearest Neighbor.

Clasificador	%exactitud		
	$\sigma^2=0.025$	$\sigma^2=0.05$	$\sigma^2=0.1$
Distancia Euclideana	95.74	92.28	86.82
K-Nearest Neighbor	95.84	92.5	86.18
Diferencia	0.1	0.22	0.64

De acuerdo con los resultados de la Tabla 5.12 los dos clasificadores presentan prácticamente la misma exactitud para clasificar las fallas, las diferencias que existen entre el porcentaje de exactitud generado por un método u otro son muy pequeñas y por lo tanto no se puede establecer cual es mejor que otro, excepto para el caso de un nivel de ruido de 0.1 donde existe la diferencia mas grande. Igualmente, estos resultados son presentados en los siguientes gráficos de barras.




Fig. 5.4. Comparación de las Tablas 5.6a y 5.8a.

En esta figura se observa que el clasificador por K-Nearest Neighbor es más eficiente a la hora de clasificar la falla f39v ya que de las 1000 veces que la falla pasa por el clasificador, este la clasifica 1000 veces correctamente, igualmente para el caso de f13v la cual es clasificada correctamente en un 88.2% comparado con un 87.7% del clasificador por distancia Euclideana. El resto de las fallas las clasifica prácticamente con el mismo porcentaje de exactitud (detállense las Tablas 5.6a y 5.8a).




Fig. 5.5. Comparación de las Tablas 5.6b y 5.8b.

En cuanto a la Fig. 5.5 correspondiente a un nivel de ruido de 0.05, la diferencia más resaltante se observa en la clasificación de la falla f39v, donde el clasificador por K-Nearest Neighbor la clasifica correctamente en un 97.8%, comparado con un 96% para el

clasificador por distancia Euclideana. Contrariamente, ocurre con la falla f28t donde el clasificador por distancia Euclideana la clasifica correctamente en un 99.9% comparado con 98.3% del otro clasificador. Para el resto de las fallas el porcentaje de clasificaciones es muy similar.




Fig. 5.6. Comparación de las Tablas 5.6c y 5.8c.

Para el caso del nivel mas alto de ruido (Fig. 5.6) el clasificador que presenta las mayores cantidades de clasificaciones correctas es el clasificador por distancia Euclideana excepto para el caso de la falla f39v donde se comporta mejor el clasificador K-Nearest Neighbor.

Finalmente en párrafos anteriores se dijo que la estimación del porcentaje de desajuste (estimado por medio del clasificador por K-Nearest Neighbor) se realiza de una manera mas eficiente utilizando la media de las distancias y para un valor de $k=2$. Para comparar este ultimo método con el método por distancia Euclideana se realizaron una serie de gráficos de barras y se llego a la conclusión de que el clasificador por K-Nearest Neighbor comete errores mucho menores que los cometidos por el clasificador por distancia Euclideana; el error más pequeño cometido por este ultimo es de 22.2 % que es el caso de cla2t (f28t) para una varianza de ruido de 0.1 (Fig. 5.9), mientras que para el clasificador por K-Nearest Neighbor el menor error es de 5.8% que es el caso cla4t (f416t) para una varianza de ruido de 0.025. (Fig. 5.7). Detállense las Tablas 5.8 y 5.10b e igualmente las Fig.5.7 a 5.9.




Fig. 5.7. Comparación de las Tablas 5.8 y 5.10b.




Fig. 5.8. Comparación de las Tablas 5.8 y 5.10b.




Fig. 5.9. Comparación de las Tablas 5.8 y 5.10b.

CONCLUSIONES

El análisis en el dominio del tiempo no es adecuado para el estudio de los diferentes tipos de fallas que se presentan en la instrumentación del proceso estudiado en esta tesis, ya que las mismas presentan características no estacionarias (fenómenos oscilantes localizados en el tiempo), que exhiben patrones de frecuencias variables en el tiempo. Por consiguiente; el análisis de este tipo de señales (fallas) con la Transformada Discreta Wavelet (TDW) representa una alternativa para solucionar los problemas anteriormente mencionados pues permite hacer una representación tiempo-frecuencia de la señal con múltiples resoluciones.

La detección de la condición de falla se realizó a través de una técnica ya conocida, como es el índice de funcionamiento *IAE*, solo que dicha estimación se realiza en el dominio wavelet. Esto con el fin de explotar la capacidad de la Transformada Discreta Wavelet (TDW) para suprimir el ruido de las señales, y así, poder obtener un *IAE* fijo para el caso en que el proceso se encuentre en estado estacionario evitando así, las variaciones del *IAE* debido al ruido de fondo.

Los dos clasificadores implementados (Distancia Euclideana y K-Nearest Neighbor) en este trabajo permiten el diagnóstico y clasificación de la falla que se está presentando como una de las distintas clases de fallas que se encuentran almacenadas en la base de datos, bien sea falla en el actuador de la válvula, falla de transmisor o perturbación. Ambos clasificadores presentan porcentajes de exactitud aceptables y las diferencias entre estos dos clasificadores son muy pequeñas.

El método propuesto tiene la ventaja de estimar el porcentaje de desajuste que se está presentado (ya sea falla o perturbación) con ambos clasificadores. Sin embargo; la estimación de dicho porcentaje es realizada de una forma más eficiente por el clasificador K-Nearest Neighbor, pues, éste presenta errores menores que el clasificador por Distancia Euclideana.

El ruido de fondo que contienen las fallas y/o perturbaciones afecta negativamente el desempeño de los clasificadores (Distancia Euclideana y K-Nearest Neighbor), ya que el porcentaje de exactitud de los mismos disminuye conforme aumenta el nivel del ruido.

Finalmente, el método propuesto para la detección y diagnóstico de fallas, presenta la ventaja de no requerir un modelo matemático de la dinámica del proceso, ya que se basa en el análisis en el dominio Wavelet de una señal que está disponible en el proceso (señal de salida del transmisor), lo cual trae como consecuencia que el método sea aplicable a otros tipos de procesos diferentes al estudiado en este trabajo.

WWW.BDIGITAL.ULA.VE

REFERENCIAS BIBLIOGRAFICAS

- [1] Sánchez, Betsy. **Detección y Diagnóstico de Fallas utilizando Estructuras de Transición**. Proyecto de Grado para optar al título de Magíster Scientiae Postgrado en Automatización e Instrumentación. Universidad de los Andes. Mérida. Enero 2002.
- [2] Janos J. Gertler. **Fault Detection and Diagnosis in Engineering Systems**. New York: Marcel Dekker 1998.
- [3] Tarantino, R. **Detección de Fallas en Sistemas Dinámicos lineales variantes en el tiempo**. Tesis para la obtención del grado de Doctor en Ciencias Aplicadas. Universidad de los Andes. Mérida. Noviembre 1999.
- [4] Addison Rios-Bolívar, Germain Garcia. **Control por Compensación de la Saturación y Filtros de Detección de Fallas**. IV Congreso de Automatización y Control (CAC'2003) Noviembre 2003, Mérida-Venezuela.
- [5] Garcés Rosas, Sayra M. **Propuesta de un Sistema Automático para Detección y Diagnóstico de Fallas**. Proyecto de Grado para optar al título de Magíster Scientiae Postgrado en Automatización e Instrumentación. Universidad de los Andes. Mérida. Diciembre 1999.
- [6] Yifeng Zhou, Juergen Hahn, M. Sam Mannan. **Fault detection and classification in chemical processes based on neural networks with feature extraction**. ISA Transactions 42 (2003) 651-664.
- [7] Addison Rios-Bolívar, Rivas E Francklin I, Moussalli K Gloria M. **Un Método Basado en Redes Neuronales para el Diagnóstico y Reconstrucción de Fallas**. IV Congreso de Automatización y Control (CAC'2003) Noviembre 2003, Mérida-Venezuela.
- [8] Zhanqun Shi, Andrew Ball, Fengshou Gu, Bo Liang. **Fault Diagnosis of Hydraulic Control System Based on Wavelet Analysis and NN**. DYMAG'99, Manchester, UK, 1999.
- [9] A. M. Gaouda, S. H. Kanoum, M. M. A. Salama, and A. Y. Chikhani. **Pattern "Recognition Applications for Power System Disturbance Classification**. IEEE Transactions on Power Delivery, VOL. 17, NO. 3, JULY 2002.
- [10] Jian Qiu Zhang and Yong Yan. **A Wavelet-Based Approach to Abrupt Fault Detection and Diagnosis of Sensors**. IEEE Transactions on Instrumentation and Measurement, VOL. 50, NO. 5, OCTOBER 2001.
- [11] C.A. Smith, A.B. Corripio. **Control Automático de Procesos Teoría y Practica**. Editorial Limusa, México D.F, 2002.

- [12] Calderón Jesús. **Características y Especificaciones Generales de los Instrumentos de Mediciones**. Facultad de Ingeniería. Mérida-Venezuela. ULA.
- [13] Eduardo Pedro Serrano. **Introducción a la transformada wavelet y sus aplicaciones al procesamiento de señales de Emisión Acústica**.
<http://www.cnea.gov.ar/cac/endye/glea/trabajos/serrano.pdf>
- [14] C. Sidney Burrus, **Introduction to Wavelets and Wavelet Transforms**. Prentice Hall, Upper Saddle River, New Jersey 07458.
- [15] V. Jayashankar, R. Vanaja Ranjan. **Time Frequency Analysis of Transient Signals**.
bruce.engr.ucf.edu/~prp/paper4.pdf
- [16] Jorge L, Fahmida N. Chowdhury, Aravena. **Fault Detection of Fligh Critical Systems**.www.ece.lsu.edu/mcu/publications/year1report_files/P08-DASC2001FaultDetect.pdf
- [17] Ángel Fernando German Bueno. **La Transformada Wavelet una herramienta de análisis de señales y calidad de onda**. Mundo Electrónico Febrero 2002/328.
- [18] S. G. Mallat. **A theory for multiresolution signal decomposition: The wavelet representation**. IEEE Transactions on Pattern Recognition and Machine Intelligence. vol. 11. pp. 674-693, July 1989.
- [19] Luzardo R. Ender O. **Caracterización de Aisladores Eléctricos de Cerámica ante Descargas Parciales usando la Transformada Wavelet**. Proyecto de Grado para optar al título de Ingeniero Electricista. Mérida. Enero 2003.
- [20] Michel Misiti, Yves Misita. **Wavelet Toolbox. For Use with MATLAB**. COPYRIGHT 1996 - 1997 by The MathWorks, Inc. All Rights Reserved.
- [21] Nadler Morton and Eric P. Smith. **Pattern Recognition Engineering**. Printed in the United States of America, 1993.
- [22] K. S. Fu. **Applications of Pattern Recognition**. Boca de Ratón, Florida, 1982.
- [23] Oscar Camacho, Carlos A. Smith, **Sliding mode control: an approach to regulate nonlinear chemical processes**, ISA Transactions 39 (2000) 205-218.
- [24] D. Cuesta Frau, D.Novák, J.C. Pérez Cortés, **Reducción del ruido en señales electrocardiográficas mediante la transformada Wavelet**.
- [25] Taiwen Jiang, Bingzhen Chen. **Application of steady-state detection method based on wavelet transform**. Computers and Chemical Engineering 27 (2003) 569-578.m