

DETECCIÓN E IDENTIFICACIÓN DE FALLAS EN SISTEMAS ESTOCÁSTICOS USANDO LA VARIANZA DE LA TRANSFORMADA WAVELET CONTINUA



↙ *Gustavo E. Ceballos Benavides*

Magíster en Ciencias de la Ingeniería mención Eléctrica, Universidad de Chile

↘ *Manuel A. Duarte Mermoud*

Doctor en Ingeniería Eléctrica

Se presenta un novedoso método para detectar fallas en un proceso dinámico, basado en la Transformada Wavelet Continua (TWC), sin necesidad de contar con un modelo explícito de la planta. El método desarrollado es más robusto en la detección de variaciones pequeñas en las señales producidas por alguna condición de falla, en comparación con otros métodos que utilizan la Transformada Wavelet para extracción de características de una señal.

El método de detección e identificación de fallas (DIF) presentado se aplica al modelo de una planta de molienda y flotación (sistema multivariable, MIMO), el cual presenta importantes comportamientos no lineales, obteniéndose buenos resultados. Una limitación del método propuesto es que las señales de salida del sistema deben cumplir, a lo menos, la condición de ser estacionarias en sentido amplio, de lo contrario no se puede garantizar que los vectores de características patrón o plantillas, sean representativos de cada condición de operación. El método desarrollado para llevar a cabo el proceso de detección de fallas en la planta, se basa en la generación de un vector de características patrón, usando el promedio en el desplazamiento (o tiempo) de las varianzas de las TWC de varias realizaciones de las distintas señales de salida, para cada condición de operación de la planta, para luego compararlas con las varianzas de la TWC de las señales de prueba que entrega el sistema y, de esta manera, decidir bajo qué condiciones de operación está funcionando la planta. Esta decisión, se puede realizar usando cualquier método de clasificación tales como análisis discriminante lineal de Fisher (LDA), vecinos más cercanos (k-NN) o máquinas de soporte vectorial (SVM) por nombrar algunos.

Introducción

La automatización de procesos industriales ha experimentado un desarrollo notable en las últimas décadas, permitiendo disponer actualmente de poderosos sistemas computacionales con capacidad para manipular múltiples sensores, actuadores y elementos de control digital que ejecutan sofisticados algoritmos de control, tales como control autosintonizante o adaptable, control difuso, control predictivo y control optimizante, entre otros. Como consecuencia de estos avances, la operación de los procesos automatizados se ha transformado en una tarea de gran envergadura que requiere de operadores muy bien entrenados, sistemas de apoyo que informen de manera automática anomalías que se presenten, por ejemplo fallas en sensores, actuadores, equipos o elementos de control, así como también sobre perturbaciones (externas e internas) que alteren las condiciones de operación del proceso.

El análisis de las diferentes publicaciones referentes a detección de fallas, muestra que en los últimos 30 años se ha consolidado un área de investigación fundamentada principalmente en el uso de métodos cuantitativos y cualitativos, para la Detección e Identificación de Fallas (DIF) en sistemas dinámicos. Entre éstos métodos, se encuentran ecuaciones de paridad, observadores de Luenberger, filtros de Kalman métodos de decisión estadística, estimación de parámetros, redes neuronales, etc., los cuales se aplican en las dos principales tareas asociadas a la identificación de fallas; generación de residuos y su evaluación. La mayoría de los métodos empleados para la generación de residuos se basa en la utilización de modelos matemáticos del proceso o sistema dinámico.

El aporte más significativo de esta investigación es la creación de un vector de características patrón (o plantilla), utilizando la varianza de la Transformada Wavelet Continua (TWC) de la salida

de la planta, que da cuenta del funcionamiento de la misma, basándose exclusivamente en la información temporal y espectral simultánea, de las señales de salida de la planta, prescindiendo de cualquier otra información adicional del sistema bajo estudio, demostrando que si la o las salidas de dicho proceso pueden ser consideradas como estacionarias en sentido amplio durante un intervalo de tiempo finito, entonces la varianza de su transformada wavelet depende solo del factor de escala "a" y no de su desplazamiento "b". Además, una vez construido el vector de características patrón, se deja a criterio del usuario, la técnica de identificación y clasificación de fallas que estime convenientes.

Entre las técnicas que se pueden escoger, están aquellas ampliamente aplicadas en el campo de la inteligencia artificial, como son las técnicas usadas en el reconocimiento de patrones tales como LDA (Linear Discriminant Analysis), QDA (Quadratic Discriminant Analysis), máquinas de soporte vectorial SVM (Support Vector Machines), entre otras.

También, se demuestra en Ref. [5] que el promedio del cuadrado de la transformada wavelet con respecto al desplazamiento "b", denotado como b-promedio, es un estimador insesgado de la varianza de la TWC, con lo cual, se hace relativamente sencillo la construcción del vector de características, ya que se puede prescindir del conocimiento de las probabilidades a priori de las señales de salida, las cuales son por lo general, muy difíciles de estimar y simplemente, se lleva a cabo una promediación en el dominio de las escalas de las señales de salida.

Del análisis de los métodos que utilizan el análisis wavelet para la extracción de características de las señales de una planta, se pudo observar que no existe un método sistemático para la extracción de características de un sistema general y cada forma de uso de la Transformada Wavelet (TW) se aplica de modo distinto a cada problema particular. Más aún, la mayor parte de la literatura se refiere al uso de la Transformada Wavelet Discreta (TWD) y muy pocas menciones a la TWC.

En la mayoría de los casos, se aplica un banco de filtros (filtros pasabajo y pasalto) denominado análisis multiresolutivo (MRA en inglés) haciendo uso de la TWD de las señales de una planta, ya sea tanto para reducir el número de muestras y de ese modo, conseguir una reducción de la dimensión temporal de la señal o bien, para identificar el instante de una posible anomalía del sistema. Sin embargo, esto, además de reducir la información temporal de la señal, conlleva una pérdida de información espectral importante puesto que la TWD, no considera todo el espectro ya que solo tiene en cuenta escalas que sean múltiplos de 2^j con $j \in \mathbb{Z}$ y no escalas intermedias.

En resumen, una gran cantidad de estudios se han llevado a cabo en diferentes áreas para la detección e identificación de fallas usando análisis espectral de Fourier y wavelets, sin embargo, la mayor parte de estos estudios se basan casi exclusivamente, en el análisis multiresolutivo de la TWD de las señales y se ha descartado casi por completo, el uso de la TWC. Más aún, no hay un método sistemático para aislar y clasificar diferentes tipos de fallas simultáneas. En cambio, el uso de la TWD se aplica caso a caso y se deben realizar muchas simulaciones para determinar el tipo más apropiado de wavelet a utilizar junto a su nivel de descomposición, lo cual requiere un gran esfuerzo y tiempo.

Por el contrario, el uso de la TWC, aprovechando la gran cantidad de información que esta genera de la señal, tanto a nivel espectral como temporal, se desarrolla un método sistemático para abordar el problema de DIF, por medio de la construcción de un vector de características patrón o plantilla de cada señal para diferentes condiciones de operación sin importar del tipo y orden de la planta o sistema que se esté analizando.

2. Conceptos Generales sobre la Transformada Wavelet

A continuación, veremos algunas de las propiedades de la TWC y la elección del tipo de función wavelet analizante.

2. 1.1. La Transformada Wavelet Continua

Se define la transformada wavelet continua [3] (TWC o bien, CWT del inglés: Continuous Wavelet Transform) de una señal del tiempo $y(t)$ como:

$$C_y(a, b) = \langle y, \psi_{a,b} \rangle = \frac{1}{|a|^{1/2}} \int_{-\infty}^{+\infty} y(t) \psi^* \left(\frac{t-b}{a} \right) dt$$

$$\text{con } a \in \mathbb{R}^+ - \{0\} \text{ y } b \in \mathbb{R}, \quad (2.1)$$

en que $\psi^* \left(\frac{t-b}{a} \right)$ es el complejo conjugado de la función $\psi \left(\frac{t-b}{a} \right)$ donde $\psi(\cdot)$ corresponde a la función wavelet analizante o simplemente wavelet. En nuestro estudio, la wavelet a utilizar será una función real. El factor "a" se denomina comúnmente como factor de escala y "b" es el factor de desplazamiento. $\psi_{a,b}(t) = \frac{1}{|a|^{1/2}} \psi \left(\frac{t-b}{a} \right)$ corresponde a la wavelet analizante o wavelet madre normalizada y $C_y(a,b)$ en Eq. (2.1) son los coeficientes de la TWC de $y(t)$.

Observando la integral (2.1), se puede decir que dado un "a" fijo, la TWC corresponde a la correlación cruzada entre $y(t)$ y $\psi_a(t)$. Se sabe además, que si un proceso estocástico es estacionario, la correlación entre dos señales reales $x(t)$ y $y(t)$, denotada por $R_{x,y}(\tau) = \int_{-\infty}^{+\infty} x(t)y(t+\tau)dt$, es equivalente a la convolución estándar entre $x(t)$ y la inversión temporal de $y(t)$, es decir; $R_{x,y} = x(t) * y(-t)$, en que $x(t) * y(-t)$, define la convolución entre $x(t)$ e $y(-t)$. Por lo tanto, la TWC de una señal $y(t)$, se puede interpretar como un filtrado lineal pasabanda de dicha señal, es decir

$$C_y(a, b) = \int_{-\infty}^{+\infty} y(t) \frac{1}{\sqrt{a}} \psi \left(\frac{t-b}{a} \right) dt = y * \bar{\psi}_a(t),$$

en que $\bar{\psi}_a(t) = \frac{1}{\sqrt{a}} \psi \left(\frac{-t}{a} \right)$ es la wavelet analizante.

La Transformada de Fourier (TF) de la función $\bar{\psi}_a(\omega)$, tiene la siguiente expresión:

$$\bar{\psi}_a(\omega) = \sqrt{a} \cdot \psi(a\omega) \quad , \quad (2.2)$$

$$\begin{aligned} \bar{\psi}_a(\omega) &= F\{\bar{\psi}_a(t)\} = F\left\{\frac{1}{\sqrt{a}} \psi \left(\frac{-t}{a} \right)\right\} = \frac{a}{\sqrt{a}} \psi(a\omega) : \\ &= \sqrt{a} \cdot \psi(a\omega) \end{aligned}$$

En este estudio, usaremos como wavelet analizante, la Wavelet Haar (conocida comúnmente como "db1") [7, 14] puesto que es más sencilla de tratar matemáticamente, indicando que no existe un método definido para la elección de la función wavelet. Además, la Wavelet Haar tiene propiedades comunes a la mayoría de las wavelets como soporte finito y ser ortogonal.

En el caso de las wavelets ortogonales, como la Wavelet Haar, estas poseen dos funciones que las caracterizan completamente, a saber, las wavelets madres y wavelets padres [3]. Las wavelets madres tienen integral nula sobre todo el espacio y las wavelet padres tienen integral igual a 1 en todo el espacio. Además, ambas wavelets tienen integral cuadrática igual a 1, es decir:

wavelet padre o función de escala: $\phi(t)$

$$\int_{-\infty}^{+\infty} \phi(t) dt = 1 \quad \text{y} \quad \int_{-\infty}^{+\infty} \phi(t)^2 dt = 1 \quad (2.3)$$

wavelet madre o simplemente wavelet: $\psi(t)$

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad \text{y} \quad \int_{-\infty}^{+\infty} \psi(t)^2 dt = 1 \quad (2.4)$$

El conjunto de funciones constituido por traslaciones y escalamiento s de las funciones mencionadas forman una base en el espacio de las funciones de cuadrado integrable denotado por L^2 . En el caso de las wavelets no-ortogonales, como la Wavelet Morlet, estas poseen solo una función que las caracteriza, a saber, la wavelet madre o simplemente wavelet.

Una crítica que generalmente se hace al análisis wavelet es la elección arbitraria de la función wavelet : $\psi(t)$. Debería notarse que la misma elección arbitraria se realiza cuando se elige una de las transformadas más tradicionales tales como la transformada de Fourier, Bessel, Legendre, etc. No obstante, existen diversos factores que deben ser considerados para elegir una función wavelet adecuada, dependiendo del problema que se desea enfrentar.

Un factor a considerar es saber si la wavelet debe ser compleja o real. Una función wavelet compleja retornará información acerca de la amplitud y fase respectivamente, y por tanto está mejor adaptada para capturar algún comportamiento oscilatorio y retardo de la señal $x(t)$, pero no existen algoritmos rápidos para su cálculo, por tanto no es del todo adecuada para análisis y diagnóstico de fallas en tiempo real. Más aún, su reconstrucción no está garantizada. Por otro lado, una función wavelet real, retorna sólo una componente (real) y por tanto puede ser usada para aislar peaks o discontinuidades [4], lo cual es adecuado para los fines de determinar algún comportamiento anómalo o de falla en un sistema, y además, su cálculo es más rápido que el de una wavelet compleja.

Finalmente, la función wavelet que se usará en este estudio la Wavelet Haar o Dabuchies 1 (ver Figura 2) [5] definida como

$$\psi(t) = \begin{cases} 1 & \text{si } 0 < t < 1/2 \\ -1 & \text{si } 1/2 < t < 1 \end{cases} \quad (2.5)$$

Para llevar a cabo el cálculo de la transformada wavelet continua, Matlab dispone de la función "CWT" la cual será nuestra principal herramienta de análisis. En la Figura 1 se muestra la función wavelet Haar, que será usada en el análisis.

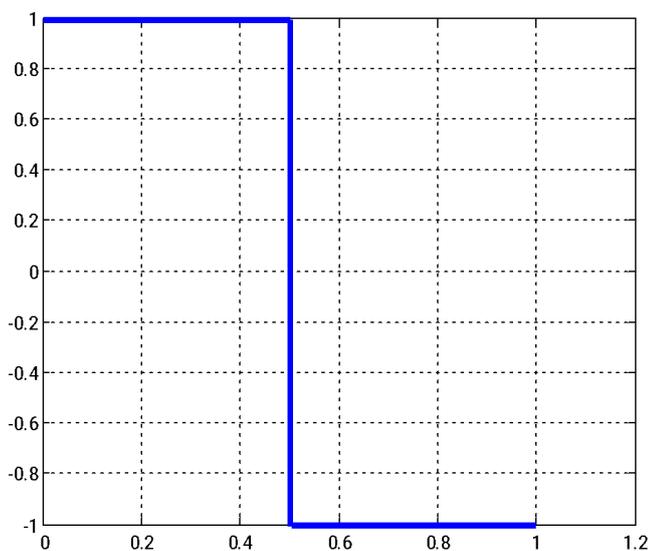


Figura 1

Función Wavelet Haar

2.2. Técnicas de Extracción de Características

El objetivo principal de las técnicas de extracción de características es reducir la dimensión de los datos para simplificar el análisis. Estas técnicas se basan usualmente en transformar los datos del espacio original a uno nuevo (espacio transformado) de menor dimensión. En el caso de transformaciones lineales, se utiliza una matriz de transformación W tal que:

$$y = W \cdot x \quad (2.6)$$

donde x es el vector original de características de dimensión n , W es la matriz de transformación de $p \times n$ e y representa el nuevo vector de características transformado de dimensión $p < n$. Hay diversas técnicas de reducción de la dimensión del vector

de características como por ejemplo PCA (Principal Components Analysis) o DWT (Discrete Wavelet Transform), por nombrar solo algunas.

Sin embargo, una pregunta fundamental debiera ser; ¿qué características son las adecuadas a escoger de una señal, para formar el vector de características? Esta pregunta debiera ser hecha antes de pensar en las técnicas de reducción de la dimensión del vector de características. La verdad es que existen múltiples respuestas, sin embargo, en este trabajo consideraremos una característica muy particular que presenta la DWT de una señal del tiempo, al menos para la Wavelet Haar, que es la varianza de los coeficientes de la transformada wavelet continua, que tiene una particularidad importante para generar el vector de características y es que su varianza solo depende del factor de escala a y no de su desplazamiento b , si se considera que la señal a procesar es estacionaria en sentido amplio.

2.3. Técnicas de Clasificación de Patrones

El concepto de clasificación de patrones o reconocimiento de patrones, cubre una amplia gama de problemas de las más diversas disciplinas científicas, en particular, en el área de la ingeniería y sus aplicaciones. Actualmente, las técnicas de clasificación de patrones muestran un fuerte desarrollo motivado por los nuevos avances en robótica e inteligencia artificial. En particular, una de las aplicaciones más relevantes de la clasificación de patrones corresponde a las áreas de visión artificial [26], reconocimiento de caracteres [27], diagnóstico médico computarizado [28] y reconocimiento del habla [29].

Desde el punto de vista matemático, un patrón es un vector n -dimensional cuyas características de un fenómeno son almacenadas en sus componentes. Generalmente, este vector es obtenido con los datos entregados por un sensor. Así entonces, el diseño de un sistema de clasificación de patrones consiste por lo general de tres etapas, a saber: la Adquisición de datos, el Preprocesamiento y representación adecuada de los datos y la Clasificación de los datos.

La primera etapa se lleva a cabo mediante un sensor o conjunto de sensores, mientras que el objetivo principal de la segunda etapa es eliminar el ruido y permitir que los datos sean adecuados para realizar, por último la tercera etapa, donde se debe escoger un método apropiado para clasificar los datos y asociarlos a una clase bien definida dentro de un grupo de distintas clases.

Existen muchos métodos de clasificación en la literatura científica, como son por ejemplo; Análisis Lineal Discriminante de Fisher (LDA) [30], Redes Neuronales (NN) [31, 32], vecinos más cercano (K-NNs) [33], Funciones de Base Radial como son las Máquinas de Soporte Vectorial (SVM) [34] por nombrar algunas, los cuales han sido ampliamente usados en problemas prácticos.

3. Metodología de Análisis en la Detección e Identificación de Fallas

El enfoque que utilizaremos en este estudio se basa principalmente en extraer características de una señal del tiempo $y(t)$ (salida de un sistema dinámico, por ejemplo) a través de su transformada wavelet. Puesto que, aunque tradicionalmente la transformada de Fourier ha sido utilizada para análisis en frecuencia, la transformada wavelet da un marco más flexible en el cual es posible realizar un análisis tanto en el dominio del tiempo como de la escala (equivalente a la frecuencia en la transformada de Fourier). Para ello usaremos la función Wavelet Haar.

El método consiste entonces, en extraer características basadas en la transformada wavelet continua, puesto que en la literatura técnica el uso de la transformada wavelet para extraer características se basa casi exclusivamente en la transformada wavelet discreta de la señal [16, 17, 18, 19, 20, 22, 24, 25], combinada con análisis multiresolutivo [3], para disminuir la dimensión del vector de características o consideran la energía de la señal y suma de los coeficientes wavelet [16]. En el caso de la transformada wavelet continua, la extracción de características, se basa casi exclusivamente en comparar las diferencias de ángulos de desfases

de las wavelets para las diversas señales lo cual es útil si es que la señal a analizar presentara un retardo en caso que se produjese una falla.

Para este tipo de fallas, las cuales se presentan por lo general en sistemas de transmisión a grandes distancias de energía eléctrica, se debe utilizar además, una wavelet compleja para capturar dicho retardo por medio del desfase producido en la TWC lo cual es un análisis muy dependiente del problema específico, es decir, detección de fallas en sistemas de transmisión de señales a grandes distancias. Además, el tiempo de procesamiento crece dado que se debe computar tanto la magnitud como el ángulo de la TWC por ser la wavelet una función compleja [23].

En el caso de la wavelet discreta, se sugiere realizar la extracción de características considerando los puntos discretos de la transformación expresados en el dominio del tiempo, los cuales pueden ser muchos dependiendo del largo temporal de la señal bajo estudio, lo cual implica disponer de un vector de características de dimensión demasiado elevada.

En este estudio, se sugiere otro enfoque, el cual consiste en extraer las características de un mapa bi-dimensional en el espacio tiempo-escala, con lo cual se considera toda la información posible de la señal, para luego disminuir la dimensionalidad de la matriz de coeficientes considerando el hecho que la varianza de la transformada wavelet continua es independiente del desplazamiento b (o tiempo), y solo depende de la escala a , si se considera que el proceso bajo estudio es un proceso estocástico en sentido amplio.

Así, las fallas de un proceso continuo son representadas como desviaciones con respecto al vector de características considerado normal. Luego, la información del estado actual del proceso en cuestión es información suficiente para representar fallas actuales o presentes. Por lo tanto, es posible en principio, representar fallas en un determinado instante de tiempo, observando la distribución o gráfica de los coeficientes en función solo de la escala (a) de la transformada wavelet en ese mismo instante.

Luego, lo esencial, es definir una distribución representativa de cada estado de operación (normal o falla). En este caso, se utilizará como vector de características de cada estado de operación ya sea normal o falla, al vector de los coeficientes de la varianza de la transformada wavelet continua, la cual se demuestra en Ref. [5] que es independiente del desplazamiento (o tiempo b) para cada escala a .

Sin embargo, si el número de escalas es relativamente elevado para mantener la mayor cantidad de información posible de la señal, también se puede tener problemas a la hora de usar un clasificador lineal como es el caso del LDA de Fisher, ya que la matriz de covarianza de las muestras puede ser singular o cercana a singular, dado el problema de colinealidad o casi-colinealidad que se presenta cuando el vector de características tiene muchas dimensiones. Por tanto, la matriz de covarianza de los datos originales no admite inversa, que es lo que se necesita al usar estas técnicas de clasificación. Para evitar este inconveniente, se redujo la dimensión del vector de características original a solo 3 componentes usando la técnica de Análisis de Componentes Principales (Principal Components Analysis o PCA por sus siglas en inglés).

3.1. Criterios de Detección e Identificación de Fallas

A continuación, se indican los criterios que serán considerados en este estudio para la detección e identificación de fallas en un sistema dinámico y de tiempo continuo.

- Las fallas de un proceso continuo serán representadas como desviaciones con respecto al estado normal.
- Se propone, representar tanto las fallas en un instante determinado, como el estado normal de un proceso, por medio de un vector de características caracterizado por los coeficientes de la varianza de la transformada wavelet continua de las señales de salida de dicha planta.

- Cada condición de operación sobre un intervalo de tiempo, es caracterizada por el promedio sobre el desplazamiento de la varianza de la transformada wavelet. Esto es posible de hacer, ya que en Ref. [5, 6] se demuestra que la varianza de la transformada wavelet de la salida de un proceso estocástico estacionario no es función del desplazamiento b . Por lo tanto, se generarán vectores de características tanto para condiciones de operación Normal y Falla (falla de sensor y falla debido a variación paramétrica, por ejemplo), recolectando datos relevantes de operación de la planta.

En la referencia [25] se muestra en detalle la metodología propuesta para la identificación de fallas, la cual básicamente consta de la creación del Vector de Características para la Identificación de Fallas basado en el Valor Medio de la Varianza de la Transformada Wavelet.

Además, otro tema relevante para caracterizar las señales (Normal y Falla) es la determinación de la escala máxima (a_{max}) a utilizar en el proceso de creación de los vectores característicos, de tal manera de no tener un retardo demasiado grande en el proceso de detección de una falla, ya que el retardo en la detección provocado por una perturbación o falla tipo escalón usando una escala a , es precisamente a . Más aún, al usar una ventana temporal de análisis de L unidades de tiempo, el efecto de un cambio (o falla) en la salida $y(t)$, desaparecerá de la TWC, transcurrido L unidades de tiempo después del instante en que se inicia la falla. Entonces, si se usa una escala máxima a_{max} , el retardo en la detección será de a lo menos a_{max} unidades de tiempo más el tiempo invertido en el cómputo de la TWC. Luego, escoger la escala máxima es un compromiso entre el retardo aceptado para la detección de una falla y la cantidad de información espectral que se desea obtener de la señal para su caracterización.

Es decir, mientras mayor sea a_{max} , mayor será la información espectral que se tendrá de la señal bajo estudio, pero mayor será el retardo en la detección. Es deseable entonces, conocer lo mejor posible, el rango espectral (a_{max}) de los diferentes tipos de señales (Normal y Falla) para decidir el valor mínimo de a_{max} a escoger sin perder información relevante que caracteriza a cada tipo de señal.

Por otro lado, escoger escalas a_{max} grandes, eleva sustancialmente el tiempo de cómputo de la TWC, lo cual es perjudicial para una rápida detección de una falla. Entonces, la escala máxima a usar a_{max} se podría escoger en forma heurística, considerando el retardo máximo permitido en la detección de una falla y luego probar si esa escala máxima, es suficiente para llevar a cabo una buena clasificación del tipo de operación de un sistema o planta.

Esta decisión se puede realizar, observando el error cometido en la matriz de confusión y ver si esta presenta un buen porcentaje de clasificación correcta, en caso afirmativo, la escala máxima considerada es aceptada como tal, de lo contrario, se escoge una escala máxima de mayor valor.

En la Figura 2 se muestra en forma esquemática el sistema de identificación y clasificación de fallas, donde $Z(a_z)$ es el Vector de Características.

4. Detección e Identificación de Fallas usando el Vector de Características aplicado a un modelo de Planta de Molienda y Flotación de Mineral

Se construyó un simulador del modelo de una planta que denominaremos Ad-Hoc [12] en ambiente SIMULINK de MATLAB, cuya Versión 1.0 del simulador está desarrollada en tiempo continuo el cual se describe en detalle en [12] Este simulador, se construyó principalmente para probar distintos métodos de identificación y detección de fallas, además de servir para explorar estrategias de control automático e identificación. En particular, aplicaremos el método de las plantillas o vector de características patrón anteriormente descrito a esta planta no lineal de múltiples entradas y salidas.

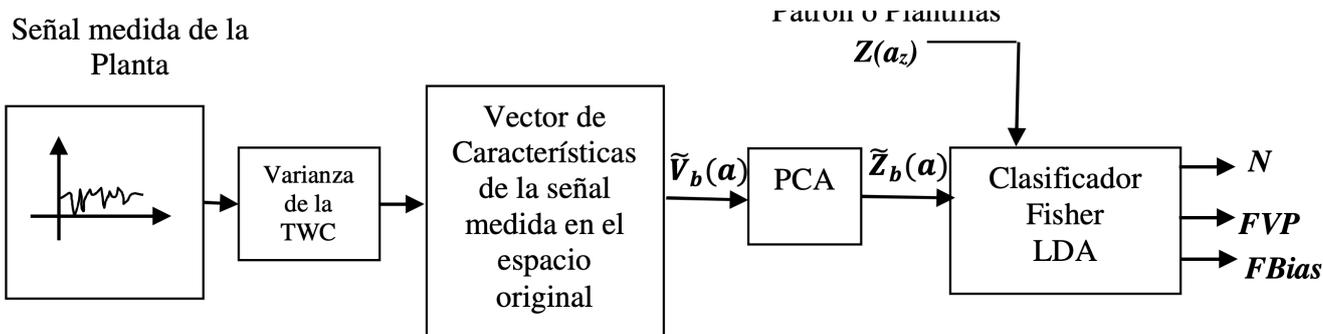


Figura 2

Sistema de identificación y clasificación de fallas en línea para una planta.

4.1. Descripción de la Planta de Molienda y Flotación Ad-Hoc

Esta planta Ad-Hoc [12] consiste en una abstracción de las características más importantes de una planta de molienda y flotación, la cual se compone de un primer bloque denominado **molino**, un segundo bloque denominado **clasificador** y un tercer y último bloque denominado **flotación**. Básicamente, se trata de un conjunto de partículas que tienen diversos atributos (por ejemplo; tamaño del mineral, tasas de traspaso entre tamaños, tasas de selección, etc.) y las reglas que gobiernan tanto los traspasos entre masas como la selección de ellas. No es difícil, entonces, para una persona con formación en modelación de sistemas dinámicos comprender rápidamente los fundamentos de la molienda y la flotación, desde este punto de vista y como consecuencia, la modelación dinámica de los procesos correspondientes. Así, es posible interpretar el comportamiento de las variables del modelo y las relaciones que existen entre ellas, más claramente que en el caso de una planta totalmente abstracta como sería un modelo puramente matemático. Es así como aparecen en forma natural ciertas restricciones impuestas a los sistemas desarrollados para estas plantas, como consecuencia de que no se dispone de todas las mediciones que se desearían tener.

Finalmente, debemos decir que el modelo de la "Planta Ad-Hoc" es de la clase de modelos de ecuaciones de estado y de estado/salida, no lineales y variantes en el tiempo, sometida a perturbaciones estocásticas.

4.2. Diagrama en Bloques de la Planta Ad-Hoc

El diagrama en bloques de la Figura 3, muestra en forma compacta, las entradas (lado izquierdo del diagrama), salidas (lado derecho) y perturbaciones (parte superior e inferior) de la Planta de Molienda y Flotación Ad-Hoc.

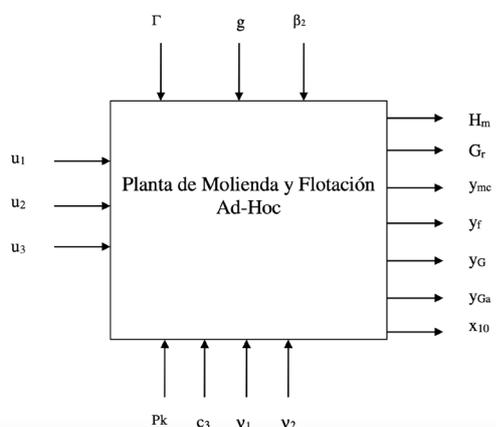


Figura 3

Esquema de Bloques de la Planta de Molienda y Flotación Ad-Hoc.

4.3. Definición de Condiciones de Operación de la Planta de Molienda y Flotación Ad-Hoc

En la Tabla 1, se muestran, cuatro condiciones en las que se considera que la planta está operando en falla, más la condición de operación normal. A saber, se considera condición de funcionamiento de falla, si cualquiera de los parámetros g, φ, β_2 o bien c_3 , cambia de un valor considerado normal a uno de falla, donde g : es la granulometría de alimentación a molienda, φ es la Moliendabilidad del mineral, β_2 : es la tasa de descarga de mineral de tamaño 2 en el molino y c_3 es la tasa de rechazo de tamaño 3 en el clasificador.

Tabla 1: Parámetros de la planta Ad-Hoc para diversas condiciones de operación

Condición	Parámetros			
	g	Γ	β_2	c_3
Normal	[0.40.40.10]	N (1,0.1)	0,2	0,1
Falla	[0.80.40.10]	N (0.8,0.1)	>0.3	>0.15

De la Tabla 1, se ve por ejemplo, que la granulometría de alimentación a molienda "g" cambia de fina (condición de funcionamiento normal: $g=[0,4 \ 0,4 \ 0,1 \ 0]$) a muy gruesa (condición de funcionamiento de falla: $g=[0,8 \ 0,4 \ 0,1 \ 0]$).

4.4. Señales Capturadas bajo diversas Condiciones de Operación de la Planta de Molienda y Flotación Ad-Hoc y sus respectivas Plantillas con Control Regulatorio (PI) de la Masa de Mineral Retenida en el Molino H_m

En las Figuras 4.1 a 4.5, se muestra una porción de las señales de la planta Ad-Hoc medidas durante 440 segundos. Las fallas se producen a partir de los 220 segundos y las figuras muestran la evolución desde el segundo 340 al 440 (últimos 100 segundos de la falla) de tal manera que se muestra sólo la porción de régimen permanente y no las oscilaciones producto del transiente inicial para diferentes condiciones de operación previamente definidas en la Tabla 1. Además, la planta se encuentra bajo condiciones de control regulatorio PI de la masa de mineral retenida en el molino H_m .

También, en las Figuras 4.1(b) y (c) a 4.5(a) y (c), se muestran respectivamente las plantillas en el espacio original (32 escalas) confeccionadas con solo 150 muestras (Figuras 4.1(b) a 4.5(b)) y las plantillas reducidas (solo 3 escalas) en el espacio transformado de las PCA (Figuras 4.1(c) a 4.5(c)).

Nuevamente, la elección de las escalas y escala máxima a_{max} queda a criterio del usuario, teniendo en consideración el retardo en la detección de una falla y el error de clasificación que se desee aceptar. En este caso, se escogieron 32 escalas con escala máxima $a_{max}=32$ ya que fue suficiente para los efectos de detectar e identificar el tipo de falla presente en esta planta no lineal.

Señal Analizada (y_{Gmed}): Ley de concentrado de Cu

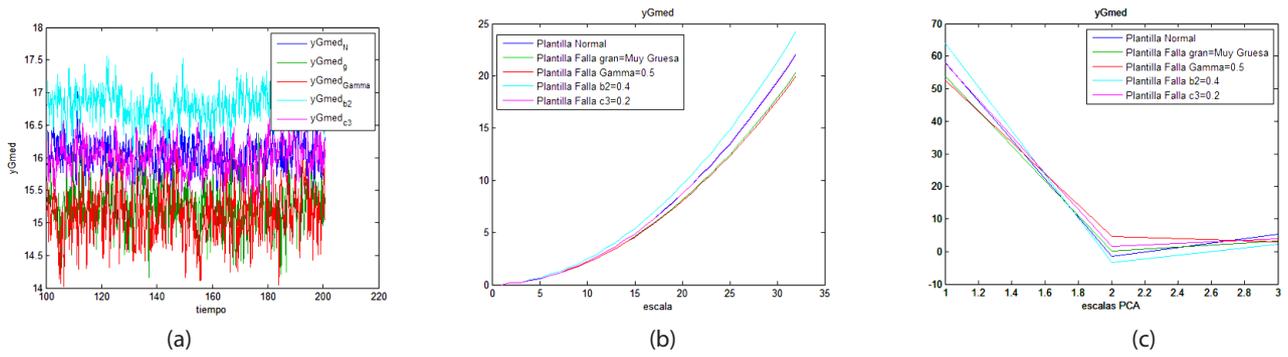


Figura 4.1

(a) Señal y_{Gmed} para diversas condiciones de operación, (b) Plantillas en el espacio original; (N) condición normal, (g) falla por aumento en la granulometría de entrada, (φ) falla debido a una disminución de φ , (β_2) falla por aumento de β_2 , (c3) falla por aumento de c_3 y (c) Plantillas en el espacio transformado de las PCA.

Señal Analizada (G_{med}): Granulometría de alimentación a flotación

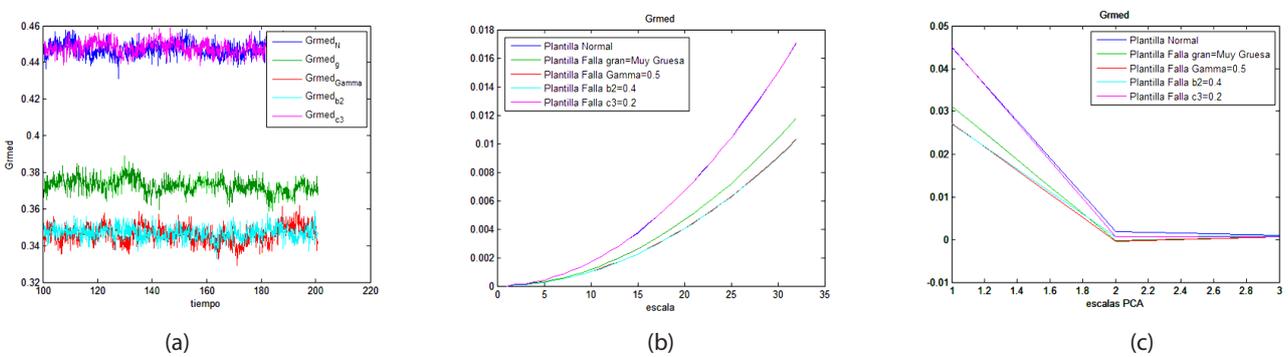


Figura 4.2

(a) Señal G_{med} para diversas condiciones de operación, (b) Plantillas en el espacio original; (N) condición normal, (g) falla por aumento en la granulometría de entrada, (Γ) falla debido a una disminución de Γ , (β_2) falla por aumento de β_2 , (c3) falla por aumento de c_3 y (c) Plantillas en el espacio transformado de las PCA.

Señal Analizada (y_{mcmcd}): Flujo de mineral de salida del clasificador

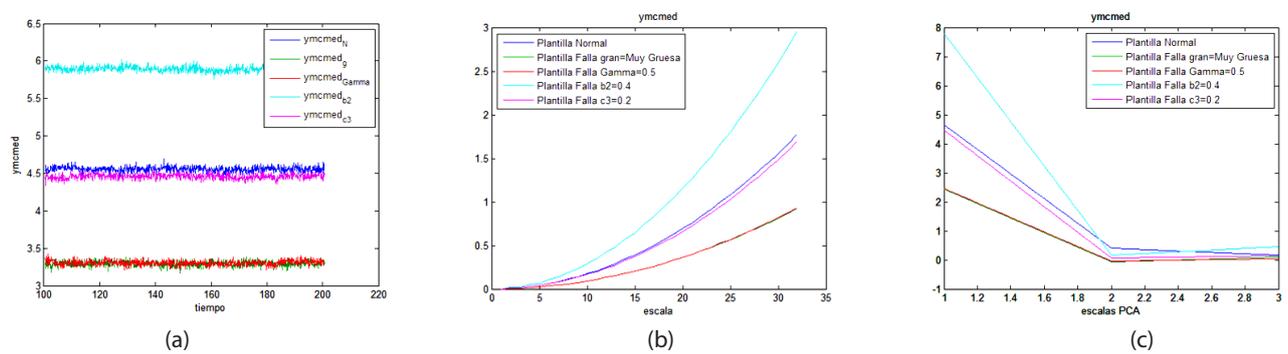


Figura 4.3

(a) Señal y_{mcmcd} para diversas condiciones de operación, (b) Plantillas en el espacio original; (N) condición normal, (g) falla por aumento en la granulometría de entrada, (Γ) falla debido a una disminución de Γ , (β_2) falla por aumento de β_2 , (c3) falla por aumento de c_3 y (c) Plantillas en el espacio transformado de las PCA.

Señal Analizada (y_{fmed}): Flujo de mineral de entrada a flotación

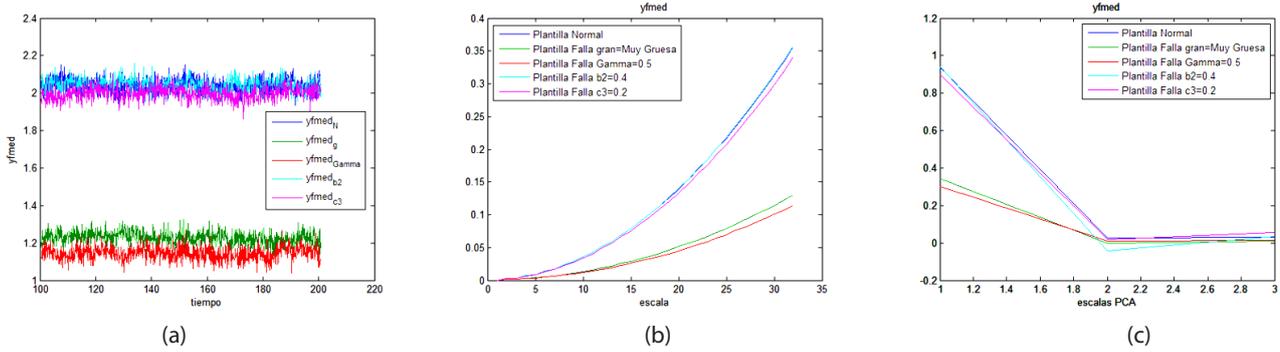


Figura 4.4

(a) Señal y_{fmed} para diversas condiciones de operación, (b) Plantillas en el espacio original; (N) condición normal, (g) falla por aumento en la granulometría de entrada, (Γ) falla debido a una disminución de Γ , (β_2) falla por aumento de β_2 , (c3) falla por aumento de c_3 y (c) Plantillas en el espacio transformado de las PCA.

Señal Analizada (u_{1med}): Flujo de alimentación de sólidos a molienda

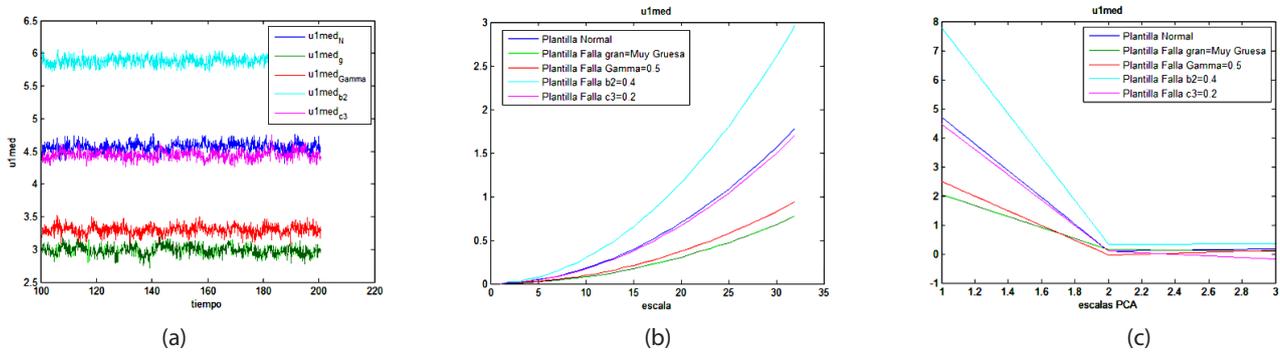


Figura 4.5

(a) Señal u_{1med} para diversas condiciones de operación, (b) Plantillas en el espacio original; (N) condición normal, (g) falla por aumento en la granulometría de entrada, (Γ) falla debido a una disminución de Γ , (β_2) falla por aumento de β_2 , (c3) falla por aumento de c_3 y (c) Plantillas en el espacio transformado de las PCA.

Ahora bien, con las plantillas ya determinadas en la fase de simulación anterior, es posible comenzar a generar fallas, a partir de una condición de funcionamiento normal, para determinar cuál de las señales anteriormente medidas y caracterizadas a través de sus plantillas, es la más adecuada para identificar el tipo de falla presente en la planta. Para ello, es de gran utilidad, estudiar las **matrices de confusión** producidas en la clasificación, para varias realizaciones de un mismo tipo de falla y así averiguar la señal óptima que se debe medir para capturar dicho comportamiento anómalo o de falla.

Demás está decir, lo complejo que es determinar en este ejemplo, cada condición de operación ya que de las figuras, se ve que algunas plantillas, son muy similares a otras, dada la pequeña variación en los parámetros que se utilizó, para producir una falla de la planta. Es evidente que al considerar variaciones más significativas en los parámetros, el proceso de clasificación de fallas mejoraría sustancialmente, ya que las plantillas estarían más separadas unas de otras.

4.4.1. Matrices de confusión confeccionadas para 150 señales de prueba obtenidas de la planta Ad-Hoc considerando las diversas condiciones de operación (Normal y Fallas)

A continuación, en las Tablas 2 a 7 se muestran las matrices de confusión para las 5 señales consideradas en la identificación de fallas, incluida la condición de operación normal. El largo de las señales consideradas para la confección de las plantillas y las señales de prueba fue de 92.6 segundos, equivalentes a 926 muestras, considerando un periodo de muestreo de $T_s=0.1$ segundos. Para la confección de las matrices de confusión, se analizaron 50 señales de prueba por cada condición de operación. Es decir, el total de señales de prueba que fue comparada con las respectivas plantillas o vectores de características reducidos fue de 250, ya que se usaron 50 señales de prueba para identificar y clasificar las condiciones de operación de la planta usando la señal y_{gmed} , 50 señales más para el caso de usar la señal y_{rmed} , 50 más para el caso de usar la señal y_{fmed} y finalmente, 50 señales más para el caso de usar la señal u_{1med} .

Estas plantillas fueron construidas considerando diferencias mínimas de operación de la planta pero que a su vez, poder identificar al menos alguna señal, que fuera capaz de detectar una posible anomalía o falla de operación. Esto es útil para identificar qué señal o señales son las más adecuadas para capturar los diversos cambios de comportamiento desde una condición normal a otra de falla.

Para mayor sencillez del análisis, es útil definir la siguiente hipótesis, a saber:

Hipótesis: Sólo una falla sucede a la vez, mientras dure el tiempo de la ventana de análisis L usada para el cálculo de la varianza de la TWC.

Tabla 2: Parámetros considerados para la identificación y clasificación de fallas de la planta de molienda y flotación Ad-Hoc

Nombre	Símbolo	Condición Normal	Condición de Falla
Granulometría de alimentación a molienda	g	g=[0,4 0,4 0,1 0]	g=[0,8 0,4 0,1 0]
Moliendabilidad	Γ	1	0,8
Tasa de descarga del molino	β_2	0,2	0,3
Rechazo tamaño 3 en clasificador	c3	0,1	0,15

En la Tabla 2 (similar a la Tabla 1 pero en que se indica el símbolo y valor de cada parámetro), se muestran las condiciones de operación normal y falla con los valores correspondientes de los parámetros.

A continuación, se muestran las matrices de confusión para las diversas condiciones de operación usando distintas señales del proceso. I de análisis y_{mcmcd}

Tabla 3: Matriz de confusión para Plantillas de la señal de análisis y_{Gmed}

	N	g	Γ	β_2	c3
N	100	0	0	0	0
g	0	96	4	0	0
Γ	0	16	84	0	0

Tabla 4: Matriz de confusión para Plantillas de la señal de análisis G_{med}

	N	g	Γ	β_2	c3
N	100	0	0	0	0
g	0	100	0	0	0
Γ	0	0	100	0	0
β_2	0	0	0	100	0
c3	0	0	0	0	100

Tabla 5: Matriz de confusión para Plantillas de la señal de análisis y_{mcmcd}

	N	g	Γ	β_2	c3
N	100	0	0	0	0
g	0	100	0	0	0
Γ	0	0	100	0	0
β_2	0	0	0	100	0
c3	0	0	0	0	100

Tabla 6: Matriz de confusión para Plantillas de la señal de análisis y_{fmed}

	N	g	Γ	β_2	c3
N	100	0	0	0	0
g	0	100	0	0	0
Γ	0	0	100	0	0
β_2	0	0	0	100	0
c3	0	0	0	0	100

Tabla 7: Matriz de confusión para Plantillas de la señal de análisis u_{1med}

	N	g	Γ	β_2	c3
N	100	0	0	0	0
g	0	100	0	0	0
Γ	0	0	100	0	0
β_2	0	0	0	100	0
c3	0	0	0	0	100

De la observación de las Tablas 3 a 7, se puede concluir lo siguiente:

En general, todas las señales presentaron un buen desempeño en la clasificación de las fallas ocurridas en la planta, exceptuando la señal y_{Gmed} , que presentó algunas confusiones menores, en todo caso, entre la condición de falla debido al cambio en la granulometría g y la moliendabilidad β del mineral (ver Tabla 3).

- Es evidente el buen desempeño en la clasificación que se obtuvo al analizar varias señales de la planta, por lo que no fue necesario concatenar vectores de características o plantillas para mejorar el desempeño en la clasificación.
- Finalmente, se concluye bastaría con considerar cualquiera de las señales G_{med} , y_{mcmcd} , y_{fmed} ó u_{1med} para detectar los 4 tipos de fallas considerados en la Planta de Molienda Ad-Hoc.

Es interesante mencionar que el diseño del vector de características patrón o plantilla desarrollado en este trabajo para detección y clasificación de fallas, fue aplicado con éxito en la detección de cambios en la moliendabilidad β de una planta simulada de Molino SAG, el cual generó la publicación [9] en la revista *International Journal of Mineral Processing*, con resultados muy aceptables, a pesar que se dejó de lado, un análisis exhaustivo de la elección de la escala máxima a utilizar (a_{max}) como fue el caso del análisis realizado al sistema de primer orden visto en es estudio. Sin embargo, como se mencionó en capítulos anteriores, esta elección de a_{max} queda a criterio del usuario.

5. Conclusiones

En este trabajo se demuestra que es posible aplicar la Transformada Wavelet Continua con éxito y simpleza en la creación de un vector de características patrón (o plantilla), para su posterior uso en la detección y diagnóstico de fallas de diversos tipos de plantas, tanto lineales como no lineales.

Es interesante observar que para aplicar esta metodología, no se necesita un modelo (o modelos múltiples explícitos) de la planta para llevar a cabo, por ejemplo, un análisis de los residuos y con ello determinar si estamos o no en presencia de una falla. Simplemente se analiza la señal medida desde la planta para el instante presente o actual.

El método funciona en línea para una ventana de tiempo determinada por el diseñador. Si la ventana temporal de análisis es muy pequeña se pierde precisión en la identificación de una falla, ya que se presentan más falsos positivos o mayor cantidad de traslapes en las curvas de distancia, por tanto no se puede estar seguro si la planta bajo análisis, está o no, operando en condi-

ción de falla, es decir existe un compromiso entre el ancho de la ventana temporal de análisis y la capacidad del método de DIF presentado en este trabajo para detectar fallas.

El vector de características patrón (o plantilla) diseñado en este trabajo, ha demostrado ser un medio adecuado para detectar fallas o condiciones de operación de un sistema estocástico lineal y no lineal tanto SISO como MIMO. Si bien es cierto se ha impuesto la condición que las señales sean estacionarias en sentido amplio, en general, casi todos los sistemas reales cumplen con dicha condición, por lo tanto, no es una restricción tan fuerte.

También como trabajo futuro, también sería interesante probar diversas técnicas de clasificación de patrones, como la vista en este trabajo de investigación (LDA Fisher y k-NN) y otras adicionales tales como SVM, QDA, etc aplicadas a diversas plantas, usando el vector de características creado en este trabajo versus los vectores de características comúnmente usados en la literatura, para así tener una base de comparación de los desempeños obtenidos en la clasificación de fallas como en el reconocimiento de patrones.

Finalmente, la gran potencia que posee la construcción del vector de características propuesto para el proceso de clasificación de fallas, se debe al hecho que en el proceso de construcción del vector de características se considera tanto la información espectral de la señal (análisis en el dominio de la escala o su equivalente a la transformada de Fourier) como la información temporal. Este hecho es relevante ya que los métodos que en general utilizan la transformada wavelet para clasificación, hacen uso de la versión discreta y no continua de ésta y la construcción de los vectores de características se basan principalmente en la información temporal de las señales y reducen su dimensión usando diferentes escalas (descomposición), pero en ese proceso se pierde información valiosa, cosa que no sucede al combinar ambas informaciones (espectral y temporal) en forma simultánea como es el caso del vector de características patrón (o plantilla) diseñado en este trabajo.

Referencias Bibliográficas

[1] S. Mallat, "A Wavelet Tour of Signal Processing Identification", Academic Press, San Diego, CA, USA (1999).

[2] C. Torrence and G.P. Compo; "Bulletin of the American Meteorological Society", Program in Atmospheric and Oceanic Sciences, University of Colorado, Boulder, Colorado.

[3] Gonzalez, G.D., G. Ceballos, R. Paut, D. Miranda, P. La Rosa, "Fault detection and identification through variance of wavelet transform of system outputs". In Recent advances in Intelligent systems and signal processing, Ed. N.E. Mastorakis, C. Manikopoulos, G.E. Antoniou, V.M. Mladenov, I.F. Gonos, WSEAS Press, 2003, pp. 47-53

[4] Gonzalez, G.D., Paut, R., Cipriano, A., Miranda, D., and Ceballos, G., "Fault Detection and Isolation Using Concatenated Wavelet Transform Variances and Discriminant Analysis", IEEE Transactions on Signal Processing, May 2006.

[5] Misiti, M., Y. Misiti, G. Oppenheim and J-M. Poggi. Wavelet Toolbox for Use with MATLAB. The Mathworks, Inc., Natick, MA, U.S.A, (1996)

[6] G. González y David Miranda P.; "Manual del Usuario Simulador de la Planta Ad-Hoc versión 1.0", Depto. Ingeniería Eléctrica, U. de Chile, 2003.

[7] Daubechies, I., Ten lectures on wavelets, (CBMS-NSF regional conference series in applied mathematics), 61, 2002.

[8] K. Kasinathan, Power System fault detection and classification by wavelet transforms and adaptive resonance theory neural networks, University of Kentucky Master's Theses, , 2007.

[9] C. Pang and M. Kezunovic. Wavelet-Based Method for Transmission Line Fault Detection and Classification during Power Swing, Texas A& M University, 2008.

[10] J. Gao, Y. Ji, J. Bals, R. Kennel. Fault Detection of Power Electronic Circuit using Wavelet Analysis in Modelica. Technische Universität München Arcistr. Munich, Germany, 2012.

[11] M. Patel, R.N. Patel. Fault Detection and Classification on a Transmission Line using Wavelet Multi Resolution Analysis and Neural Network. Dept. of Elect. Engg. S.S.C.E.T, Durg, India, 2012.

[12] J.I. Adetorosaheedayode, Power System Fault Detection Using Wavelet Transform and Probability Neural Network. American Journal of Engineering Research (AJER) e-ISSN: 2320-0847 p-ISSN : 2320-0936 Volume-5, Issue-4, pp-192-196. 2016.

[13] M. Michalik, W. Rebizant, M. Lukowicz. Wavelet Transform Approach to High Impedance Fault Detection in MV Networks. Institute of Electrical Power Engineering Wroclaw University of Technology, Poland.

[14] K.P. Ray, B.K Panigrahi, P.K. Rout. Detection of Faults in Power System Using Wavelet Transform and Independent Component Analysis. Bhubaneswar, India. Dept. of ECE, The University of Texas at Dallas, Technical Report, USA. 2016.

[15] P. Sharma, D. Saini, A. Saxena, Fault Detection and Classification in Transmission Line Using Wavelet Transform and ANN. Department of Electrical Engineering, Swami Keshvanand Institute of Technology Management & Gramothan, Jaipur, India. 2016.

[16] E.R. Davies, Machine Vision: Theory, Algorithms, Practicalities, 3rd ed. San Mateo, CA: Morgan Kaufmann, 2004.

[17] L.C. Jain and B. Lazzerini, Eds., Knowledge-Based Intelligent Techniques in Character Recognition, Boca Raton, FL: CRC, 1999.

[18] A. Dhawan, Medical Image Analysis. Hoboken, NJ: Wiley, 2003.

[19] W. Chou and B. H. Juang, Eds., Pattern Recognition in Speech and Language Processing, Boca Raton, FL: CRC2003.

[20] M. Kiefte, Discriminant Analysis Toolbox. Edmonton, AB, Canada: Univ. Alberta, 2000.

[21] C. Bishop, Neural Networks for Pattern Recognition. New York: Oxford Univ. Press, 2002.

[22] B. D. Ripley, Pattern Recognition and Neural Networks. Cambridge, U.K.: Cambridge Univ. Press, 1996.

[23] A. Webb, Statistical Pattern Recognition. Hoboken, NJ: Wiley, 2002.

[24] V. Vapnik, Statistical Learning Theory. Hoboken, NJ: Wiley, 1998

[25] G.E. Ceballos Benavides, Detección e Identificación de Fallas e Sistemas Lineales y No Lineales Estocásticos por Medio del Diseño de un Vector de Características basado en la Varianza de la Transformada Wavelet Continua". Tesis Magister en Ciencias de la Ingeniería, Mención Eléctrica, Universidad de Chile, Abril 2018.