

**DETECCIÓN Y CLASIFICACIÓN AUTOMÁTICA DE
PERTURBACIONES QUE AFECTAN LA CALIDAD DE LA ENERGÍA
ELÉCTRICA**

VALDOMIRO VEGA GARCÍA
Ingeniero Electricista UIS



**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y DE
TELECOMUNICACIONES
BUCARAMANGA
COLOMBIA
2007**

DETECCIÓN Y CLASIFICACIÓN AUTOMÁTICA DE PERTURBACIONES QUE AFECTAN LA CALIDAD DE LA ENERGÍA ELÉCTRICA



VALDOMIRO VEGA GARCÍA

Ingeniero Electricista UIS

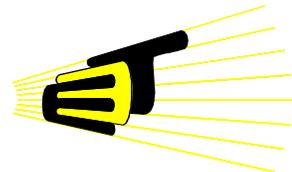
Trabajo de investigación para optar al título de Magíster en Ingeniería

Director: CÉSAR ANTONIO DUARTE GUALDRÓN

Prof. UIS, Ing. Electricista UIS, MPE UIS

Codirector: GABRIEL ORDÓÑEZ PLATA

Prof. UIS, Ing. Electricista UIS, PhD UPC



Grupo de Investigación en Sistemas de Energía Eléctrica

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
BUCARAMANGA
COLOMBIA
2007**

RESUMEN

TITULO:
DETECCIÓN Y CLASIFICACIÓN AUTOMÁTICA DE PERTURBACIONES QUE AFECTAN LA CALIDAD DE LA ENERGÍA ELÉCTRICA *

AUTOR:
VALDOMIRO VEGA GARCÍA **

PALABRAS CLAVE: monitorización, perturbaciones, descriptores, detección, identificación, clasificación, transformada wavelet, máquinas de soporte vectorial, valor rms, calidad de la energía.

DESCRIPCIÓN:

En este trabajo se estudia la Transformada Wavelet Discreta (TWD) en la detección e identificación de perturbaciones de la calidad de la energía eléctrica. La función Wavelet Biorotogonal 3.9 es utilizada para la detección, dadas sus características de respuesta en frecuencia y localización en tiempo. Se proponen tres estrategias para la obtención de patrones que permiten la identificación de perturbaciones utilizando la función Bior3.7 y el valor RMS. Se estudian perturbaciones de baja frecuencia como armónicos y flicker y de alta frecuencia como transitorios. Cuatro familias Wavelet fueron estudiadas y la Biorotogonal tuvo excelente desempeño. Los patrones son clasificados automáticamente utilizando máquinas de soporte vectorial (MSV) con la función de base radial como kernel, dado su desempeño y porque sólo requiere dos parámetros (de forma y de penalización). Las técnicas de validación cruzada y búsqueda en malla fueron utilizadas. La MSV presenta un buen desempeño al clasificar a pesar de la similitud de algunos patrones.

Inicialmente se presentan los objetivos de esta investigación. En el Capítulo 2, se presentan los conceptos matemáticos de la TWD y algunas perturbaciones de la calidad, de acuerdo con la normatividad colombiana. En el Capítulo 3, la estrategia de detección utilizando la convolución entre el filtro de descomposición pasa-altas y las perturbaciones es presentada.

En el capítulo 4, se proponen tres estrategias para obtener patrones basados en la TWD y el valor RMS. En el Capítulo 5, el clasificador MSV es presentado. Finalmente, en los capítulos 6 y 7 se presentan la herramienta computacional y las conclusiones de este trabajo, respectivamente.

* Trabajo de Investigación

** Facultad de Ciencias Físico-mecánicas, Maestría en Ingeniería Área Eléctrica
MPE. César Antonio Duarte Gualdrón

SUMMARY

TITLE:

AUTOMATIC POWER QUALITY DISTURBANCES DETECTION AND CLASSIFICATION *

AUTHOR:

VALDOMIRO VEGA GARCÍA **

KEY WORDS: monitoring, disturbances, patterns, detection, identification, classification, wavelet transform, support vector machines, RMS value, power quality.

DESCRIPTION:

In this document Discrete Wavelet Transform (DWT) is studied in detection and identification of power quality disturbances. Wavelet Function Biorthogonal 3.9 is used as a base function in detection because of its frequency response and information time localization properties. Three strategies are proposed in order to obtain patterns that allow identification of power quality disturbances. These strategies use the Wavelet Function Biorthogonal 3.7 and RMS value. Disturbances under survey are: low frequency disturbances (such as flicker and harmonics) and high frequency disturbances (such as transients and sags). Four wavelet families were studied and Biorthogonal showed excellent performance. Also, RMS value is used to characterize disturbances that show big changes in magnitude. The combination of both strategies produces excellent results. Patterns are automatically classified by support vector machines (SVM). Radial Base Function (RBF) was used as kernel, because it requires only two parameters (waveform parameter and penalization parameter). Cross validation technique and grid search were used in this work. SVM exhibited good performance as classifier despite similitude between disturbance patterns.

Initially the objectives of this research are presented. Chapter 2 presents mathematical concepts about DWT along with the properties that make it well adapted for this study. Power quality disturbances are analyzed according to current Colombian regulation. In Chapter 3, the detection strategy using convolution between high-pass decomposition filter and disturbances is presented.

Chapter 4 proposes three strategies in order to obtain patterns using the DWT and RMS value. In Chapter 5 SVM classifier is presented. Finally, Chapters 6th and 7th deal about designed graphic interface and conclusions drawn from this work, respectively.

* Research work

** Physics and Mechanics Engineering College, Engineering Master - Electrical Area MPE. César Antonio Duarte Gualdrón

CONTENIDO

Pág.

INTRODUCCIÓN.....	1
1. PLANTEAMIENTO DEL TRABAJO DE INVESTIGACIÓN.....	4
1.1. DEFINICIÓN Y ACOTACIÓN DEL PROBLEMA.....	4
1.2. OBJETIVOS DE LA INVESTIGACIÓN	5
1.2.1. <i>Objetivo General</i>	5
1.2.2. <i>Objetivos Específicos</i>	5
1.3. RESULTADOS ESPERADOS	5
2. PERTURBACIONES DE LA CALIDAD DE LA ENERGÍA Y TÉCNICAS DE PROCESAMIENTO.....	7
2.1. CALIDAD DE LA ENERGÍA ELÉCTRICA	7
2.1.1. <i>Transitorio Electromagnético</i>	7
2.1.1.1. Transitorio Oscilatorio	8
2.1.1.2. Transitorios Tipo Impulso.....	8
2.1.2. <i>Variaciones de Corta Duración</i>	9
2.1.2.1. Hueco de Tensión (<i>Sag o Dip</i>).....	9
2.1.2.2. Elevación de Tensión (<i>Swell</i>).....	9
2.1.2.3. Interrupción de Corta Duración	10
2.1.3. <i>Variaciones de Larga Duración</i>	10
2.1.4. <i>Desbalance de Tensión</i>	10
2.1.5. <i>Distorsión de la Forma De Onda</i>	10
2.1.5.1. Armónico	10
2.1.5.2. Muesca de Tensión (<i>Notch</i>).....	11
2.1.6. <i>Fluctuación de Tensión (Flicker)</i>	12
2.2. TRANSFORMADA WAVELET DISCRETA.....	13
2.3. CONSIDERACIONES FINALES.....	18
3. ESTRATEGIA DE DETECCIÓN DE PERTURBACIONES.....	19
3.1. ESTADO DEL ARTE EN LA DETECCIÓN DE PERTURBACIONES.....	19
3.2. TÉCNICA DE DETECCIÓN BASADA EN LA TRANSFORMADA WAVELET	21
3.3. SELECCIÓN DE LA WAVELET	24
3.3.1. <i>Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones wavelet Biortogonales</i>	27
3.3.2. <i>Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones wavelet Coiflet</i>	29
3.3.3. <i>Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones wavelet Daubechies</i>	30
3.3.4. <i>Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones wavelet Symlet</i>	32
3.4. CÁLCULO DEL UMBRAL.....	34
3.5. CONSIDERACIONES FINALES.....	42
4. ESTRATEGIA DE IDENTIFICACIÓN: OBTENCIÓN DE DESCRIPTORES.....	45
4.1. ANÁLISIS EN FRECUENCIA DE LA TRANSFORMADA WAVELET DISCRETA.....	47
4.1.1. <i>Familia wavelet Bior</i>	50

4.1.2.	<i>Familia de funciones wavelet Coif</i>	53
4.1.3.	<i>Familia de funciones wavelet Db</i>	55
4.1.4.	<i>Familia de filtros wavelet Sym</i>	57
4.2.	TRANSFORMADA WAVELET DISCRETA Y VALOR RMS PARA IDENTIFICAR PERTURBACIONES	60
4.2.1.	<i>Diferencias de energía de coeficientes Wavelet - Patrón 1</i>	64
4.2.2.	<i>Energía de la perturbación a partir de coeficientes Wavelet y valor eficaz – patrón 266</i>	69
4.2.3.	<i>Cálculo de la energía de la señal diferencia y valor eficaz</i>	69
4.3.	CONSIDERACIONES FINALES.....	70
5.	ESTRATEGIA DE CLASIFICACIÓN: MÁQUINAS DE SOPORTE VECTORIAL	72
5.1.	ESTADO DEL ARTE EN LA CLASIFICACIÓN DE PERTURBACIONES DE LA CALIDAD DE LA ENERGÍA	72
5.2.	METODOLOGÍA DEL PROCESO DE CLASIFICACIÓN	75
5.3.	MÁQUINAS DE SOPORTE VECTORIAL.....	76
5.3.1.	<i>Parámetro de penalización – tolerancia al ruido en una MSV</i>	81
5.3.2.	<i>MSVs NO LINEALES</i>	83
5.3.3.	<i>Multclasificación utilizando SVM</i>	84
5.3.3.1.	Máquinas multclasificadoras	84
5.3.3.2.	Máquinas biclasificadoras generalizadas.....	84
5.3.4.	<i>Métodos de descomposición estándares</i>	85
5.3.4.1.	Uno contra el resto:.....	85
5.3.4.2.	Uno contra uno:.....	86
5.3.4.3.	Arquitectura de descomposición ECOC:	86
5.3.5.	<i>Métodos de reconstrucción</i>	87
5.3.6.	<i>Validación Cruzada en la MSV</i>	89
5.4.	RESULTADOS DE SIMULACIÓN UTILIZANDO MSV.....	93
5.5.	CONSIDERACIONES FINALES.....	99
6.	IMPLEMENTACIÓN DE LA ESTRATEGIA DE DETECCIÓN, IDENTIFICACIÓN Y CLASIFICACIÓN DE PERTURBACIONES.....	100
7.	RESULTADOS, CONCLUSIONES Y TRABAJOS FUTUROS	103
7.1.	RESULTADOS.....	103
7.2.	CONCLUSIONES.....	106
7.3.	TRABAJOS FUTUROS.....	108
8.	REFERENCIAS BIBLIOGRÁFICAS.....	109
9.	BIBLIOGRAFÍA	112
9.1.	LIBROS.....	112
9.2.	NORMAS NACIONALES E INTERNACIONALES.....	114
9.3.	ARTÍCULOS IEEE	115
9.4.	ARTÍCULOS INTERNET	117
9.5.	OTRAS REFERENCIAS	118
ANEXOS		120

LISTA DE FIGURAS

Pág.

Figura 1	Transitorio oscilatorio de baja frecuencia causado por la energización de bancos de condensadores.....	8
Figura 2	Transitorio de impulso de corriente originada por un rayo.	8
Figura 3	Forma de onda de un hueco de tensión (<i>sag</i>).	9
Figura 4	Forma de onda de una elevación de tensión (<i>swell</i>).	10
Figura 5	Onda con distorsión armónica.	11
Figura 6	Muesca de tensión (Notch) producido por un convertidor.....	11
Figura 7	Familia de funciones Wavelet Daubechies de orden 2 a 10.	14
Figura 8	Esquema de descomposición <i>Wavelet</i>	15
Figura 9	Submuestreo o decimación de una señal.....	16
Figura 10	Esquema de reconstrucción <i>Wavelet</i>	16
Figura 11	Esquema de descomposición y reconstrucción de una señal.	17
Figura 12	Esquema de descomposición de un transitorio oscilatorio en secuencias de aproximación y de detalle para 3 niveles de resolución utilizando la función Bior3.7.	17
Figura 13.	Características extraídas de una perturbación: salida del filtro, coeficientes de detalle y secuencia de detalles.....	22
Figura 14	Características: salida del filtro, coeficientes de detalle y secuencia de detalles extraídas de un evento sag utilizando la función <i>wavelet bior3.9</i> para la transformación.	22
Figura 15	Acercamiento de la Figura 14 en el instante donde comienza la perturbación.	23
Figura 16	Acercamiento de la Figura 14 en el instante donde finaliza la perturbación.	24
Figura 17	Formas de onda de perturbaciones muestreadas a 128 [m/c]	26
Figura 18	Salidas correspondientes a la convolución de las perturbaciones de la Figura 17 con las muestras del FDPA asociado a la función Wavelet Bior3.9.	26
Figura 19	Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones wavelet de la Bior1.5 hasta Bior6.8.	28
Figura 20	Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones wavelet de la Coif1 hasta Coif5	29
Figura 21	Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones wavelet de la Db2 hasta Db8	31
Figura 22	Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones wavelet de la Sym2 hasta Sym8.....	32
Figura 23	Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones wavelet Bior 3.9, Db8, Sym8 y Coif5.	34
Figura 24	Ruido aleatorio con distribución normal, varianza 1 y media 0.....	35
Figura 25	Comparación entre el cálculo del valor RMS y la salida del FDPA asociado a la función Wavelet Bior3.9 para realizar la detección de 5 perturbaciones tipo.....	44

Figura 26 Cálculo de la magnitud de la transformada rápida de <i>Fourier</i> para la señal diferencia de las 5 perturbaciones de la Figura 17	45
Figura 27 Representación de la matriz de Relación de Energías y del vector de relaciones de energía promedio para M funciones wavelet.	50
Figura 28 Matriz Energía-frecuencia para la función wavelet bior6.8.....	52
Figura 29 Matriz Energía-frecuencia para la función wavelet bior3.1.....	52
Figura 30 Comparación entre las energías en por unidad del valor máximo para las funciones wavelet Bior 3.1, 3.7 y 6.8 para el análisis en frecuencia del nivel 4.	53
Figura 31 Matriz Energía-frecuencia para la función wavelet Coif 4.....	54
Figura 32 Matriz Energía-frecuencia para la función wavelet Coif 1.....	54
Figura 33 Comparación entre las energías en por unidad del valor máximo para las funciones wavelet Coif 4 y Coif 1 para el análisis en frecuencia del nivel 4.	55
Figura 34 Matriz Energía-frecuencia para la función wavelet Db 10.	56
Figura 35 Matriz Energía-frecuencia para la función wavelet Db 2.	56
Figura 36 Comparación entre las energías en por unidad del valor máximo para las funciones wavelet Db2 y Db10 para el análisis en frecuencia del nivel 4. .	57
Figura 37 Matriz Energía-frecuencia para la función wavelet Sym 9.....	58
Figura 38 Matriz Energía-frecuencia para la función wavelet Sym 2.....	58
Figura 39 Comparación entre las energías en por unidad del valor máximo para las funciones wavelet Sym2 y Sym9 para el análisis en frecuencia del nivel 4.	59
Figura 40 Valor eficaz muestra a muestra normalizado con respecto a su valor máximo para las señales de prueba <i>sp</i> , <i>sd</i> y <i>sdift</i> para las perturbaciones <i>sag</i> y <i>swell</i> de la Figura 17.	61
Figura 41 Valor eficaz muestra a muestra normalizado con respecto a su valor máximo para las señales de prueba <i>sp</i> , <i>sd</i> y <i>sdift</i> para las perturbaciones Transitorio, <i>Flicker</i> y armónico de la Figura 17.	62
Figura 42 Diagrama de bloques del esquema de identificación para obtener 3 tipos de patrones.....	64
Figura 43 Patrones obtenidos al evaluar DifEn con las perturbaciones de la Figura 17 utilizando para la transformación la función <i>wavelet</i> Bior3.7.	65
Figura 44 Patrones obtenidos a partir de la técnica diferencias de energía para 2 500 perturbaciones, utilizando la función wavelet Bior3.7 para la transformación.	66
Figura 45 Vector patrón resultante de la combinación de TW y RMS.....	67
Figura 46 Patrones de la técnica 2: energía de la perturbación y valor RMS máx y RMS mín para las perturbaciones de la Figura 17, utilizando la función wavelet bior3.7 para la transformación.....	67
Figura 47 Grupo de patrones de la técnica 2: energía de la perturbación y valor RMS máx y RMS mín para 2 500 perturbaciones utilizando la función wavelet bior3.7 para la transformación.	68
Figura 48 Patrones obtenidos a partir de la técnica energía de la diferencia ..	69

Figura 49 Patrones obtenidos a partir de la técnica energía de la señal diferencia y valor RMS máx y RMS mín para 2 500 perturbaciones utilizando la función <i>wavelet</i> Bior3.7 para la transformación.	70
Figura 50 Proceso de clasificación de descriptores utilizando MSV	75
Figura 51 Separación de vectores mediante hiperplanos.	76
Figura 52 Modelo general de un proceso de aprendizaje a partir de ejemplos	77
Figura 53 Hiperplanos de separación. Margen de separación mayor en la derecha, separa mejor las clases [Burges, 98].	79
Figura 54 Hiperplanos de separación utilizando variables de relajación.	82
Figura 55 Transformación de espacio para la separación lineal utilizando la función kernel.	83
Figura 56 Representación de las parejas de parámetros del kernel y del C	89
Figura 57 Conformación de grupos o partes.	89
Figura 58 Entrenamiento con el primer grupo de datos	90
Figura 59 Clasificación y exactitud utilizando el grupo de validación	90
Figura 60 Formación de los segundos grupos (entrenamiento y validación) ..	90
Figura 61 Resultados de la primera pareja de parámetros.....	91
Figura 62 Entrenamiento y clasificación de la MSV	93
Figura 63 Exactitud de entrenamiento de una MSV	95
Figura 64 Patrón swell mal clasificado	98
Figura 65 Esquema de la estrategia de detección, identificación y clasificación.	100
Figura 66 Herramienta computacional: estrategia de detección, identificación y clasificación.	101
Figura 67 Gráfica del ejemplo de separación de dos clases de los datos para el entrenamiento	130
Figura 68 Gráfica del ejemplo de separación de dos clases por los planos clasificadores	131

LISTA DE TABLAS

Pág.

Tabla 1 Clasificación de los fenómenos electromagnéticos.....	12
Tabla 2 Cantidades de funciones <i>Wavelets</i> utilizadas para obtener la magnitud de la respuesta en frecuencia.....	27
Tabla 3 Cálculo de las pendientes de diferentes zonas de transición de la respuesta en frecuencia de los FDPA asociados a las funciones <i>wavelet</i> bior1.5 a bior6.8 y su respectiva longitud de la respuesta al impulso.	28
Tabla 4 Cálculo Valores de las pendientes de diferentes zonas de transición de la respuesta en frecuencia de los FDPA asociados a las funciones Coif1 a y su respectiva longitud de la respuesta al impulso.....	30
Tabla 5 Cálculo de las pendientes de diferentes zonas de transición de la respuesta en frecuencia de los FDPA asociados a las funciones <i>wavelet</i> Db2 a Db8 y su respectiva longitud de la respuesta al impulso.	31
Tabla 6 Cálculo de las pendientes de diferentes zonas de transición de la respuesta en frecuencia de los FDPA asociados a las funciones <i>wavelet</i> Db2 a Db8 y su respectiva longitud de la respuesta al impulso.	33
Tabla 7 Clasificación de las mejores funciones <i>Wavelets</i> según la familia de acuerdo con los criterios de selección.....	33
Tabla 8 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 con y sin ruido para la perturbación <i>sag</i>	36
Tabla 9 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 con y sin ruido para la perturbación <i>swell</i>	37
Tabla 10 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 con y sin ruido para la perturbación transitorio.	38
Tabla 11 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 con y sin ruido para la perturbación <i>flicker</i>	39
Tabla 12 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 con y sin ruido para la perturbación armónico.....	40
Tabla 13 Resumen de los porcentajes de acierto para la detección de 84 perturbaciones con SNR de 20, 40 y 60 decibeles para 4 funciones <i>wavelet</i> considerando un error de detección del 0%.....	41
Tabla 14 Resumen de los porcentajes de acierto para la detección de 84 perturbaciones con SNR de 20, 40 y 60 decibeles para 4 funciones <i>wavelet</i> considerando un error de detección menor o igual al 5 %.	41
Tabla 15 Intervalos ideales de frecuencia y de prueba para una frecuencia de muestreo de 7 680 Hz.....	48
Tabla 16 Funciones <i>wavelets</i> utilizadas para el análisis en frecuencia.	48

Tabla 17 Representación ideal de la matriz energía-frecuencia (dimensión 8x800) en función de los 8 intervalos de frecuencia y 8 niveles de descomposición.....	49
Tabla 18 Matriz de Relación de Energías, vector de relaciones de energía promedio y Duración efectiva de la respuesta al impulso para la familia de <i>wavelets</i> Biortogonal.....	51
Tabla 19 Matriz de Relación de Energías, vector de relaciones de energía promedio y Duración efectiva de la respuesta al impulso para la familia de <i>wavelets</i> Coiflet.....	53
Tabla 20 Matriz de Relación de Energías, vector de relaciones de energía promedio y Duración efectiva de la respuesta al impulso para la familia de <i>wavelets</i> Daubechies (Db2 a Db10).....	55
Tabla 21 Matriz de Relación de Energías, vector de relaciones de energía promedio y Duración efectiva de la respuesta al impulso para la familia de <i>wavelets</i> Symlet (Sym2 a Sym10).....	57
Tabla 22 Funciones <i>wavelet</i> con mejor selectividad en frecuencia, agrupadas según el número de coeficientes de la respuesta al impulso del filtro asociado a la función.	59
Tabla 23 Simbología y colores utilizados en la Figura 4.15.	61
Tabla 24 Resultados de la clasificación de Perturbaciones de la calidad de la energía obtenidas en [Chilukuri, 04].	73
Tabla 25 Resultados de la clasificación de Perturbaciones de la calidad de la energía obtenidas en [Gou-Sheng & Jing, 05].	74
Tabla 26 Características de los patrones obtenidos en el Capítulo 4.	94
Tabla 27 Características de los parámetros utilizados en el entrenamiento y validación.	95
Tabla 28 Modelos de MSV obtenidos para diferentes valores de parámetros C y σ utilizando los tres grupos de patrones.	96
Tabla 29 Porcentajes de acierto para validación (500 perturbaciones) y para prueba (1500 perturbaciones) utilizando el patrón 1.	96
Tabla 30 Porcentajes de acierto para validación (500 perturbaciones) y para prueba (1500 perturbaciones) utilizando el patrón 2.	97
Tabla 31 Porcentajes de acierto para validación (500 perturbaciones) y para prueba (1500 perturbaciones) utilizando el patrón 3.	97
Tabla 32 Clasificación de las cantidades de patrones según su correspondencia, en la prueba controlada para 500 datos.....	97
Tabla 33 Clasificación de las cantidades de patrones según su correspondencia, en la prueba controlada para 1500 perturbaciones.	98
Tabla 34 Porcentajes de acierto para 1500 perturbaciones de prueba utilizando el patrón 2 y el modelo 4 en presencia de ruido con SNR de 20,40 y 60 decibeles.	98
Tabla 35 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el sag.	121

Tabla 36 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el swell.	121
Tabla 37 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el Transitorio.	122
Tabla 38 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el Flicker.	122
Tabla 39 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el Armónico.	123
Tabla 40 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el sag.	124
Tabla 41 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el swell.	124
Tabla 42 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el Transitorio.	125
Tabla 43 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el Flicker.	125
Tabla 44 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el Armónico.	126
Tabla 45 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el sag.	126
Tabla 46 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el swell.	127
Tabla 47 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el Transitorio.	127
Tabla 48 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el Flicker.	128
Tabla 49 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función <i>wavelet</i> 3.9 en presencia de ruido para el Armónico.	128
Tabla 50 Datos con etiqueta.	130
Tabla 51 Características de las técnicas de clasificación.	134
Tabla 52 Porcentajes de acierto para diferentes técnicas de clasificación con los patrones obtenidos en [Vega, Duarte & Ordóñez, 06].	134

LISTA DE ANEXOS

	Pág.
ANEXO A. TABLAS DE PORCENTAJES DE ACIERTOS EN LA DETECCIÓN PARA FUNCIONES <i>WAVELETS</i> EN PRESENCIA DE RUIDO.....	121
ANEXO B. EJEMPLO DE CLASIFICACIÓN UTILIZANDO UNA MSV PARA DOS CLASES	130
ANEXO C. PORCENTAJES DE ACIERTO UTILIZANDO DIFERENTES MÉTODOS DE CLASIFICACIÓN	134

INTRODUCCIÓN

Teniendo en cuenta que las perturbaciones electromagnéticas causan pérdidas económicas considerables, tanto para el sector eléctrico y la industria así como para los usuarios comerciales y residenciales, se hace necesaria la detección, el análisis, la caracterización y posterior clasificación automática de estos fenómenos transitorios y de estado estacionario, de tal forma que permitan tomar medidas al respecto y así poder brindar soluciones adecuadas.

Debido al incremento en el número de dispositivos construidos con base en semiconductores, se presentan variaciones en magnitud, frecuencia y fase de la forma de onda sinusoidal y también desbalances en sistemas trifásicos. Esto hace que muchos equipos sensibles a variaciones en la onda de tensión presenten problemas en su funcionamiento, provocando en muchos casos el deterioro del equipo. Por esto, es necesario establecer estrategias que permitan la detección e identificación rápida del tipo de perturbación, ya que esto da una mayor posibilidad de solución o atenuación de la misma. Los eventos de mayor relevancia son: las caídas de tensión (huecos o hundimientos de tensión), los transitorios electromagnéticos (de alta y de baja frecuencia), el flicker (o parpadeo), las muescas de tensión (notching), los armónicos y la asimetría (desbalances) de las ondas de tensión y corriente en los sistemas trifásicos [NTC 5000, 02].

Debido a la desregulación del sector eléctrico, las empresas operadoras de red se han visto en la necesidad de trazar estrategias para mejorar la calidad del servicio. Una de éstas consiste en monitorizar constantemente el sistema y detectar las fallas que causan inconvenientes en la prestación de un servicio de calidad. Esto con el fin de hacer un seguimiento y caracterización del sistema, para lo cual se hace necesario implementar algoritmos de detección, identificación y clasificación automática de eventos que permitan tomar medidas al respecto.

La resolución CREG 024 de 2005 [CREG 024, 05] reglamenta en su ARTÍCULO 4º el plan para instalar el sistema de medición y registro según el cual para enero de 2006, debe ser posible realizar mediciones en el 100% de las barras de las subestaciones de niveles de tensión 4, 3 y 2, así como en el 5 % de los circuitos a 13,2 kV cuya unidad constructiva reconozca esos equipos, y en la totalidad de los circuitos donde esto ocurra, en un plazo de 2 años más. Asimismo, el ARTÍCULO 5º Plan de Recolección de Datos, plantea que en cada punto de medida se descargará cada 10 minutos la información para ser procesada (cálculo del Pst, THDV, etc). El Operador de Red deberá enviar semanalmente a la CREG un archivo comprimido con las 1008 medidas y los eventos de tensión. Estas señales han debido ser muestreadas como mínimo a 1024 muestras por ciclo ([m/c]) de la fundamental, lo que indica que la cantidad de información (muestras) que se obtendrá de estos equipos digitales

podría ser procesada (depurada antes que el usuario la visualice) por una metodología de interpretación de los datos, es decir, por un algoritmo de detección, identificación y clasificación que obtenga resultados que permitan caracterizar mejor el sistema para que el operador pueda realizar diagnósticos más acertados y buscar una solución rápida a las perturbaciones. Este trabajo de investigación se enmarca en la necesidad de diagnosticar la calidad del servicio de energía eléctrica a nivel regional, nacional y mundial.

Este documento está estructurado a través de siete (7) capítulos de la siguiente forma: El primero describe los alcances y objetivos del mismo. En el segundo se describen los fenómenos transitorios y de estado estacionario que afectan la calidad de onda de tensión en los sistemas de energía eléctrica. Adicionalmente, se presentan los conceptos básicos de la herramienta matemática transformada *Wavelet* Discreta.

En el Capítulo 3 se propone a partir del valor máximo de la magnitud de la salida obtenida en la convolución de la perturbación y el filtro de descomposición pasa-altas (FDPA) asociado a la función *wavelet* Bior3.9, obtener el valor de umbral necesario para realizar la detección de perturbaciones. De igual forma para seleccionar la función *wavelet* adecuada para la detección, se propuso una metodología de selectividad en frecuencia a partir de la zona de transición de la pendiente de la respuesta al impulso del FDPA y la longitud de la misma. También se hace el análisis de la influencia del ruido sobre la señal en la detección, con distintas relaciones señal a ruido (20, 40 y 60 decibeles).

Tres estrategias de identificación se han implementado utilizando descriptores obtenidos a partir de la transformada *Wavelet* discreta y el valor eficaz (valor RMS), y son presentadas el Capítulo 4. A partir de un análisis frecuencial (barrido en frecuencia), se hace la selección de la función *wavelet* más adecuada para la identificación de perturbaciones para las 4 familias de funciones *wavelet* seleccionadas.

En el Capítulo 5 se presenta el estado del arte en la clasificación de perturbaciones de la calidad de la energía. Se resalta la importancia de las técnicas de inteligencia artificial más utilizadas en la investigación, en especial el uso de la máquina de soporte vectorial. Esta herramienta matemática ha sido implementada y se presentan los resultados de simulación utilizando una interfaz diseñada para tal fin. Los elementos a clasificar son los patrones obtenidos en la estrategia de identificación (Capítulo 4). Los resultados obtenidos (cerca al 100% de acierto) permiten validar las hipótesis presentadas en el capítulo 4.

Se presenta en el Capítulo 6 la estrategia de detección, identificación y clasificación de perturbaciones de la calidad, la cual recopila las 3 anteriores estrategias y es implementada en una herramienta computacional que permite

evaluar conjuntos de señales con perturbación. Finalmente se encuentran en el Capítulo 7 las conclusiones y trabajos futuros establecidos a partir de este trabajo de investigación.

1. PLANTEAMIENTO DEL TRABAJO DE INVESTIGACIÓN

1.1. DEFINICIÓN Y ACOTACIÓN DEL PROBLEMA

Este trabajo de investigación está relacionado con la detección, identificación y posterior clasificación de los eventos de la calidad de la energía eléctrica. Las empresas del sector eléctrico (operadores de red) no cuentan actualmente con estrategias o algoritmos que detecten e identifiquen eventos o perturbaciones en el sistema eléctrico de manera rápida y automática.

Por lo tanto, es necesario desarrollar, una estrategia (metodología) que permita detectar el evento ocurrido, caracterizar cada evento en particular, extrayendo descriptores fáciles de diferenciar. Asimismo, esta estrategia debe permitir la clasificación automática de la perturbación detectada y en lo posible la identificación del origen de la mayoría de las perturbaciones ocurridas. En este trabajo de investigación se propone desarrollar una estrategia utilizando la Transformada *Wavelet* Discreta (TWD) como base para la detección (extracción de características de alta frecuencia) e identificación (búsqueda de patrones por medio de sus coeficientes *wavelet*) y utilizando para la clasificación automática las Máquinas de Soporte Vectorial (MSV) por su buen desempeño en la multclasificación y regresión de patrones [Vapnik, 95] y porque los parámetros para su diseño presentan menos alternativas que en las redes neuronales, por ejemplo.

Los equipos instalados (Relés y monitores) están siendo subutilizados dado que no se está aprovechando toda la información que ellos pueden suministrar. Esta información es la que se podrá utilizar para afinar el diseño de la estrategia propuesta, pues para este proyecto se cuenta con los datos de simulaciones de sistemas de potencia y señales generadas sintéticamente. Esta base de datos es el recurso con el que se determinan los descriptores necesarios para la identificación de la perturbación.

El objetivo final de este trabajo de investigación es implementar una estrategia capaz de integrar técnicas que puedan detectar, identificar y clasificar automáticamente perturbaciones de la calidad de las ondas de tensión y corriente basada en la transformada *wavelet* y las MSV, tomando como referencia los estudios realizados con otras técnicas de inteligencia artificial. Cabe precisar que en este trabajo no se considera realizar mediciones de perturbaciones en los sistemas eléctricos.

1.2. OBJETIVOS DE LA INVESTIGACIÓN

En esta investigación se analizó literatura existente sobre las técnicas de detección y clasificación de perturbaciones eléctricas, que en su mayoría utiliza la transformada *Wavelet* para detectar e identificar pero en ninguno de estos trabajos se utilizan las máquinas de soporte vectorial para la clasificación. Es por esto que se plantean los siguientes objetivos.

1.2.1. Objetivo General

Diseñar una estrategia para detectar, identificar y clasificar automáticamente perturbaciones de la calidad de la energía eléctrica.

1.2.2. Objetivos Específicos

- ✓ Determinar patrones para la identificación y caracterización de huecos de tensión, elevaciones de tensión, transitorios electromagnéticos de alta y baja frecuencia, transitorios tipo impulso, muescas de tensión, armónicos y *flicker* a partir de la transformada *Wavelet* y de otras técnicas como el valor eficaz, valor medio y desviación estándar.
- ✓ Determinar una estrategia adecuada para la detección y localización en el tiempo de los eventos de la calidad de la energía eléctrica.
- ✓ Diseñar una estrategia de clasificación automática de eventos de la calidad de la energía eléctrica utilizando máquinas de soporte vectorial (MSV) a partir de los patrones que identifican y caracterizan tales eventos.
- ✓ Implementar una estrategia capaz de integrar técnicas que puedan detectar, identificar y clasificar automáticamente perturbaciones de la calidad de la energía eléctrica utilizando una plataforma computacional.

1.3. RESULTADOS ESPERADOS

Los resultados directos esperados a partir de la culminación de la investigación son:

- ✓ La caracterización de patrones o descriptores para diferenciar una perturbación de otra.
- ✓ Incorporación de una técnica de inteligencia artificial propuesta recientemente para dar solución a un problema de la calidad de la energía en los sistemas eléctricos.

- ✓ Implementar una estrategia capaz de integrar técnicas que puedan detectar, identificar y clasificar automáticamente perturbaciones de la calidad de la energía eléctrica mediante una plataforma computacional.

De manera indirecta y como resultado del desarrollo y la aplicación de las estrategias de detección, identificación y clasificación de perturbaciones en los sistemas de energía eléctrica, se esperan obtener los siguientes resultados:

- ✓ Conocimiento oportuno y seguimiento de las perturbaciones del sistema. De esta forma se cuenta con información básica y necesaria para identificar y caracterizar el sistema dando la posibilidad a expertos de interpretar los posibles problemas y soluciones en el corto plazo.
- ✓ Fortalecimiento de los grupos de investigación vinculados al proyecto en temas de actualidad científica en el ámbito de la Ingeniería Eléctrica.
- ✓ Contribución en la aplicación de técnicas innovadoras en la solución de problemas de ingeniería eléctrica.

2. PERTURBACIONES DE LA CALIDAD DE LA ENERGÍA Y TÉCNICAS DE PROCESAMIENTO

En este capítulo se describen algunos fenómenos transitorios y de estado estacionario que afectan la calidad de onda de tensión en los sistemas de energía eléctrica. Adicional a esto se presentan los conceptos básicos de la herramienta matemática transformada *Wavelet* Discreta. De los eventos que a continuación se presentan, sólo 5 de ellos: huecos de tensión (*sags*), elevaciones de tensión (*swells*), transitorios oscilatorios, transitorios de tipo impulso, armónicos y *flicker*, serán analizados en este estudio debido a su impacto económico (daños producidos a equipos sensibles por la mala calidad en la onda) y en la calidad del servicio de la energía eléctrica. Además estos eventos que también han sido considerados en los estudios que se utilizaron como referencia para este proyecto.

2.1. CALIDAD DE LA ENERGÍA ELÉCTRICA

“La calidad de la energía eléctrica es el conjunto de características físicas de las señales de tensión y corriente, para un tiempo y lugar determinados, que tienen el propósito de satisfacer las necesidades del cliente” [NTC 5000, 02].

La calidad de la energía eléctrica se ve afectada por diferentes eventos o fenómenos electromagnéticos que se presentan en el sistema eléctrico. Éstos son causados principalmente por: descargas atmosféricas, fallas en el sistema, cargas no lineales, maniobras (como conmutación de bancos de condensadores) y otras operaciones que se realizan en el sistema. Estos fenómenos se clasifican en [NTC 5000, 02] e [IEEE 1159, 95] de la siguiente manera: Transitorios Electromagnéticos (Tipo impulso y oscilatorio), armónicos, fluctuaciones de tensión (*Flicker*), huecos de tensión (*sags, dips*), sobretensiones (*swells*), desbalances de tensión, interrupciones, muescas de tensión (*notching*) y variaciones de frecuencia. A continuación se presenta la definición y caracterización de estos fenómenos.

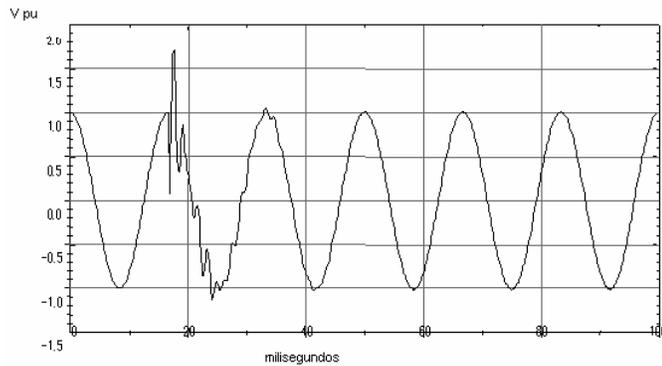
2.1.1. Transitorio Electromagnético

Los transitorios electromagnéticos son eventos de corta duración que se caracterizan por un contenido elevado de componentes de alta frecuencia y se clasifican en: oscilatorios y tipo impulso [IEEE 1159, 95].

2.1.1.1. Transitorio Oscilatorio

Es el cambio repentino a una frecuencia diferente a la de suministro en la condición de estado estacionario de la tensión, la corriente, o ambas, cuyos valores instantáneos cambian de polaridad rápidamente. Son causados principalmente por conexión de condensadores (Figura 1), re-encendidos durante la desconexión de transformadores y por la conexión de líneas. Se clasifican por su contenido de frecuencias como se muestra en la Tabla 1.

Figura 1 Transitorio oscilatorio de baja frecuencia causado por la energización de bancos de condensadores.

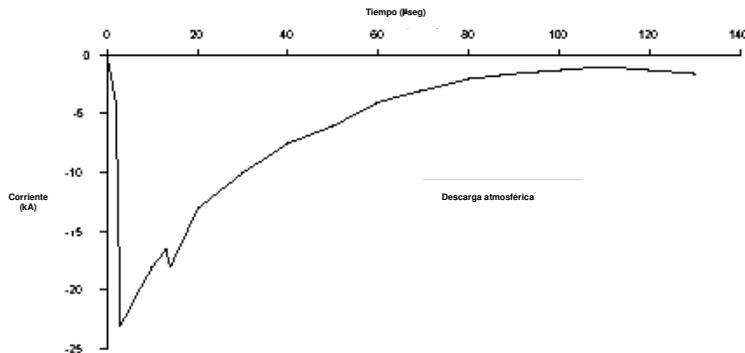


Fuente: [NTC 5000, 02].

2.1.1.2. Transitorios Tipo Impulso

El transitorio de impulso o impulsivo se define como un cambio súbito a una frecuencia distinta a la de suministro, en condición de estado estacionario para la tensión, la corriente, o ambos, que es unidireccional en polaridad. En la Figura 2 se muestra un transitorio de impulso de corriente producido por una descarga atmosférica.

Figura 2 Transitorio de impulso de corriente originada por un rayo.



Fuente: [NTC 5000, 02].

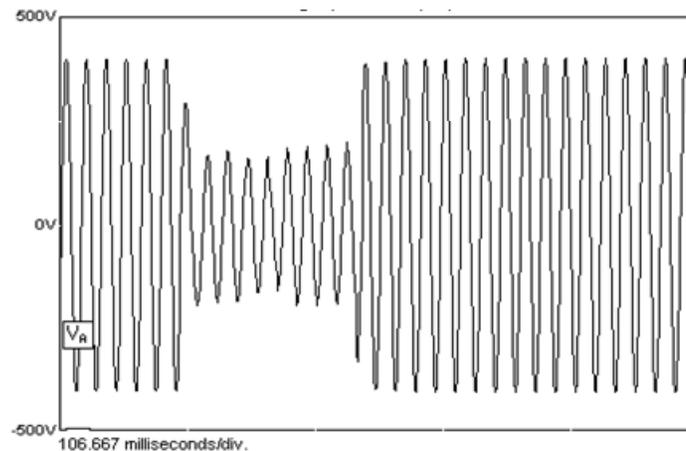
2.1.2. Variaciones de Corta Duración

Se definen como la desviación del valor eficaz (valor RMS) de la onda de tensión del valor nominal para un tiempo mayor que 0,5 ciclos y menor o igual que un minuto, a frecuencia nominal (60 Hz).

2.1.2.1. Hueco de Tensión (*Sag* o *Dip*)

El término en inglés *sag* es traducido al español como *hueco de tensión* y se define como la reducción del valor RMS de la señal de tensión a la frecuencia industrial con una duración entre 0,5 ciclos y 1 minuto. Los valores típicos para la profundidad de un hueco de tensión están entre 0,1 y 0,9 p.u. Estos eventos son causados por: fallas, conmutación de cargas grandes y arranque de motores. Un ejemplo de este fenómeno se puede apreciar en la Figura 3.

Figura 3 Forma de onda de un hueco de tensión (*sag*).

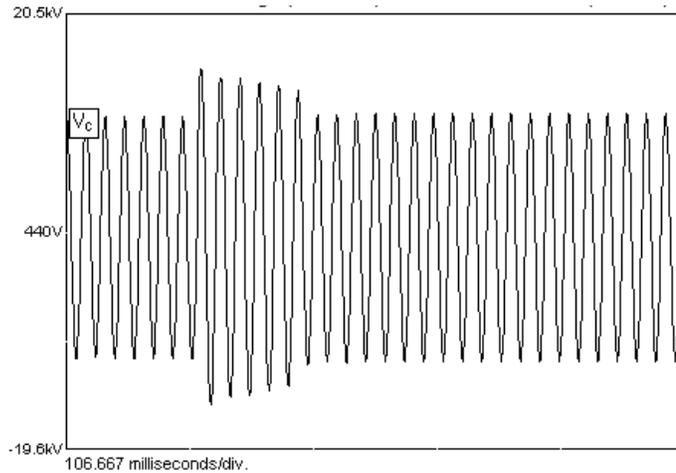


Fuente: [NTC 5000, 02].

2.1.2.2. Elevación de Tensión (*Swell*)

El término en inglés *swell* es traducido al español como *elevación de tensión* y se define como el incremento en el valor RMS de la tensión o la corriente a la frecuencia fundamental con duraciones entre 0,5 ciclos y 1 minuto y con magnitudes entre 1,1 y 1,8 p.u. Las principales causas de las elevaciones de tensión son: la desconexión de cargas grandes y la conexión de grandes bancos de condensadores. La forma de onda característica de este evento se presenta en la Figura 4.

Figura 4 Forma de onda de una elevación de tensión (*swell*).



Fuente: [NTC 5000, 02].

2.1.2.3. Interrupción de Corta Duración

Se define como la ausencia de tensión. Se considera como tal, cuando la señal de tensión decrece a menos de 0,1 p.u. para un tiempo mayor a 0,5 segundos.

2.1.3. Variaciones de Larga Duración

Corresponden a la desviación del valor eficaz (valor RMS) de la tensión, a partir de la tensión nominal, para un tiempo mayor que 1 minuto. Se clasifican como sobretensiones, subtensiones e interrupciones sostenidas.

2.1.4. Desbalance de Tensión

Se considera como la desviación máxima del promedio de la tensión trifásica dividido por el promedio de la tensión, expresado en porcentaje (Ecuación (1), [NTC 5000, 02]).

$$\text{Desbalance de tensión} = \frac{\text{máxima desviación con respecto al promedio}}{\text{Promedio de la tensión}} \times 100 \quad (1)$$

2.1.5. Distorsión de la Forma De Onda

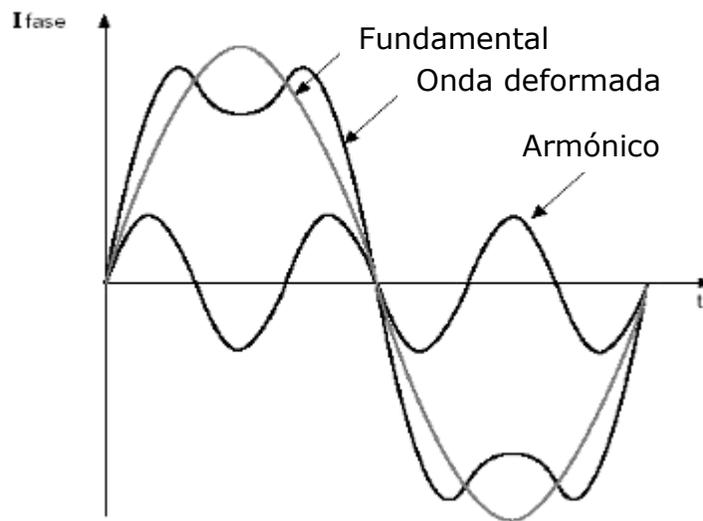
Se define como la desviación, en estado estable, de una onda sinusoidal ideal cuya frecuencia es la frecuencia del sistema de potencia.

2.1.5.1. Armónico

Un armónico es una onda sinusoidal de tensión o corriente cuya frecuencia es múltiplo entero de la frecuencia fundamental del sistema. Una señal con distorsión armónica se define como la suma de varios armónicos los cuales pueden o no estar en fase con la componente fundamental. Los armónicos son

causados por cargas y dispositivos no lineales o variantes con el tiempo. Se caracterizan con el espectro, la distorsión armónica total (*Total Harmonic Distortion-THD*) y la distorsión total de demanda (*Total Demand Distortion-TDD*). En la Figura 5 se muestra una onda con distorsión armónica.

Figura 5 Onda con distorsión armónica.

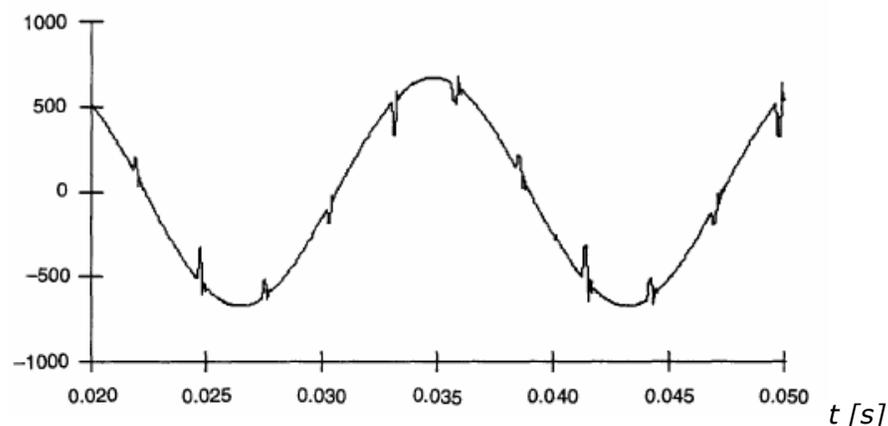


Fuente: [NTC 5000, 02].

2.1.5.2. Muesca de Tensión (*Notch*)

La palabra en inglés *notch* es traducida al español como *muesca* de tensión y se define como una perturbación periódica sobre la onda de tensión causada por la operación normal de equipos electrónicos de potencia cuando la corriente es conmutada de una fase a otra (ver Figura 6).

Figura 6 Muesca de tensión (*Notch*) producido por un convertidor.



Fuente: [NTC 5000, 02].

2.1.6. Fluctuación de Tensión (*Flicker*)

La fluctuación de tensión (la cual causa el fenómeno denominado "*flicker*") es una perturbación de la onda de tensión que ocasiona que el valor eficaz de esta señal fluctúe a una frecuencia desde 1 hasta 30 Hz y con una amplitud que no excede en la mayoría de los casos el $\pm 10\%$ de la tensión nominal.

El "*flicker*" se evidencia por una sensación fisiológica producida por la perturbación eléctrica y consiste en la modulación del valor eficaz de la tensión, lo cual hace que la intensidad en la iluminación de lámparas incandescentes titile produciendo una sensación molesta a los ojos conocida como parpadeo.

En la Tabla 1 se presenta la clasificación de los eventos electromagnéticos que afectan la calidad de la energía eléctrica, de acuerdo con la norma [NTC 5000, 02]. En color azul se encuentran los eventos de estudio de esta investigación.

Tabla 1 Clasificación de los fenómenos electromagnéticos.

Categorías	Contenido Espectral Típico	Duración Típica	Magnitud Típica de Tensión
TRANSITORIOS ELECTROMAGNÉTICOS (TEM)			
De Impulso			
Nanosegundos	5ns de pendiente	< 50 ns	
Microsegundos	1 μ s de pendiente	50ns – 1 ms	
Milisegundos	0,1 ms de pendiente	>1 ms	
Oscilatorios			
Baja frecuencia	< 5 kHz	0,3 – 50 ms	0 – 4 pu
Media frecuencia	5 – 500 kHz	20 μ s	0 – 8 pu
Alta frecuencia	0,5 – 5 MHz	5 μ s	0 – 4 pu
VARIACIONES DE CORTA DURACIÓN (VCD)			
Instantáneas			
Caídas (<i>Sags</i>)		0,5 - 30 ciclos	0,1 – 0,9 pu
Subidas (<i>Swells</i>)		0,5 - 30 ciclos	1,1 – 1,8 pu
Momentáneas			
Interrupción		0,5 s - 3s	< 0,1 pu
Caídas (<i>Sags</i>)		0,5 s - 3s	0,1 – 0,9 pu
Subidas (<i>Swells</i>)		0,5 s - 3s	1,1-1,4 pu
Temporales			
Interrupción		3s-1min	<0,1 pu
Caídas (<i>Sags</i>)		3s-1min	0,1 – 0,9 pu
Subidas (<i>Swells</i>)		3s-1min	1,1 – 1,2 pu
VARIACIONES DE LARGA DURACIÓN (VLD)			
Interrupción, sostenida		>1min	0,0 pu
Subtensiones		>1min	0,8 – 0,9 pu
Sobretensiones		>1min	1,1 – 1,2 pu

Categorías	Contenido Espectral Típico	Duración Típica	Magnitud Típica de Tensión
DESBALANCE (D)		Estado estacionario	0,5 - 2 %
DISTORSIÓN DE LA FORMA DE ONDA (DF)			
DC adicional		Estado estacionario	0 - 0,1 %
Armónicos	0-100 ^{mo} armónico	Estado estacionario	0-20 %
Interarmónicos	0-6 kHz	Estado estacionario	0-2 %
Muecas (Notches)		Estado estacionario	
Ruido	Banda ancha	Estado estacionario	0-1 %
FLUCTUACIONES (F)	<25 Hz	Intermitente	0,1 - 7 %
VARIACIONES DE FRECUENCIA INDUSTRIAL (VFI)		< 10 s	

2.2. TRANSFORMADA WAVELET DISCRETA

En los últimos años la Transformada *Wavelet* ha cobrado gran importancia dado que diversos estudios demuestran su eficacia en aplicaciones de diferentes campos como: la Ingeniería eléctrica, el análisis de fenómenos electromagnéticos, la solución numérica de integrales, la detección de singularidades, las telecomunicaciones, la compresión de audio, video e imagen y también en otras ramas como la óptica, la sismología y la medicina [García, 00], [Vega, 04], [Mora & Colomer, 03]

La transformada *Wavelet* ofrece una ventaja sobre la Transformada de *Fourier* y la Transformada *Fourier* de Corto Tiempo. Esta ventaja consiste en el análisis multiresolución tiempo-frecuencia que permite variar la ventana de análisis tanto en el tiempo como en la frecuencia, realizando un barrido desde las frecuencias altas hasta las bajas en escalas diádicas, con lo cual se analiza todo el espectro de frecuencia de la señal permitiendo separar transitorios de alta frecuencia y corta duración y componentes con bajas y medias frecuencias de mayor duración [Cortes & Vapnik, 95], [Daubichies, 92].

La Transformada *Wavelet* es adecuada para el análisis en estado transitorio, pues el análisis multiresolución tiempo-frecuencia permite localizar la perturbación tanto en el tiempo como en la frecuencia ¿Cómo se logra esto? La Transformada *Wavelet* tiene la siguiente definición:

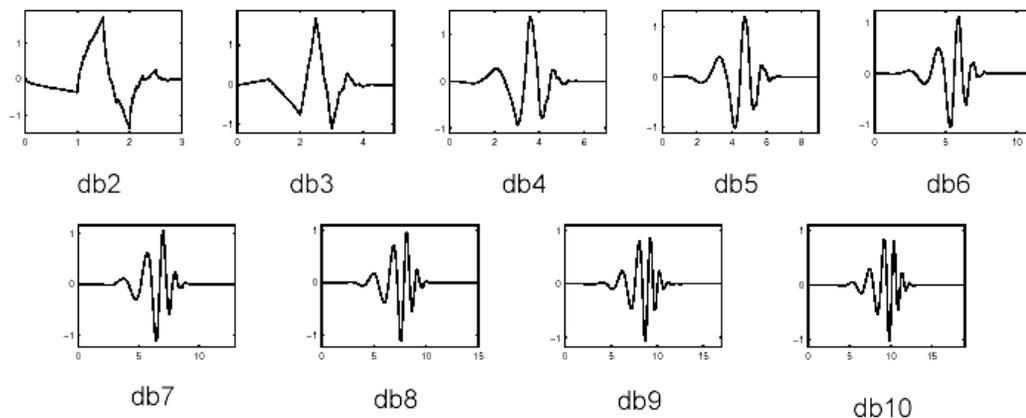
$$(W_{\psi} f)_{(b,a)} = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \quad (2)$$

Dónde $\psi(t)$ es la *Wavelet* madre (función real) y la localización en tiempo y en la frecuencia está determinada por el término:

$$\frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right) \quad (3)$$

Siendo a el factor de escalamiento y b el factor de desplazamiento en el tiempo, con a y $b \in \mathbb{R}$ y $a \neq 0$. Las *Wavelets* más utilizadas en el análisis de señales transitorias son: *Daubichies*, *Fyadic*, *Coiflets*, *Morlet* y *Symlets* [Flores, 02]. En la Figura 7 se aprecia la familia de funciones *Wavelet* de la Db2 a la Db10.

Figura 7 Familia de funciones Wavelet Daubechies de orden 2 a 10.



Fuente: [Matworks, 02].

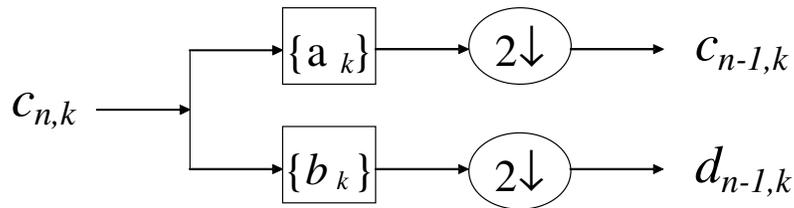
La función *Wavelet* tiene las siguientes características:

- ✓ Es de duración efectiva finita (soporte compacto), lo cual es apropiado para localizar información en el dominio del tiempo.
- ✓ Tiene un espectro pasa-banda con ancho de banda efectivo finito, lo cual es apropiado para localizar la información en el dominio de la frecuencia.
- ✓ El área bajo la curva es cero, es decir que es oscilatoria.
- ✓ La forma de onda es semejante a la del evento en estudio. Para detectar el evento es necesario que la transformada tenga la mayor energía cuando la *Wavelet* coincide con la perturbación.
- ✓ A partir de esta función se genera un conjunto ortogonal de funciones permitiendo realizar operaciones de desplazamiento y escalamiento en ambos dominios. Esto permite realizar el análisis multiresolución y decomponer una señal en diferentes niveles de descomposición sin cruces

de energía; con lo cual se puede usar la relación de *Parseval* para calcular la energía a partir de los coeficientes de la transformación [Chui, 97].

Para descomponer una señal en diferentes niveles de frecuencia, la TW utiliza un algoritmo sencillo que consiste en la convolución de las muestras de la señal $C_{n,k}$ con filtros pasa-bajos a_m y pasa-altos b_m , pasando después por un diezmado por 2. A la salida se obtienen los coeficientes *wavelet* de aproximación $c_{n-1,k}$ y los coeficientes de detalle $d_{n-1,k}$. Este proceso se puede ver gráficamente en la Figura 8 para un solo nivel de descomposición.

Figura 8 Esquema de descomposición *Wavelet*.



Fuente: [Chui, 97].

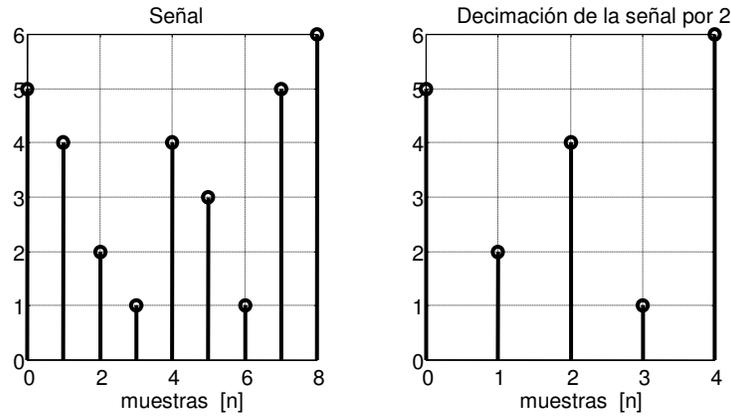
Por tanto, considerando que los coeficientes $c_{n,k}$ corresponden a las muestras de una señal χ [Chui, 97], la secuencia de coeficientes de aproximación $c_{n-1,k}$ y de detalle $d_{n-1,k}$ pueden ser calculados de la siguiente forma:

$$\begin{cases} c_{n-1,k} = \sum_m a_{m-2k} c_{n,m} \\ d_{n-1,k} = \sum_m b_{m-2k} c_{n,m} \end{cases} \quad (4)$$

Se observa de la Ecuación (4) la secuencia de entrada $c_{n,k}$ es convolucionada con los filtros con respuesta al impulso a_k y b_k . Además del proceso de convolución ordinario se observa que en la salida se retienen las muestras pares, originado por el argumento $2k$. Por tanto, las muestras impares desaparecen en este proceso. A esta operación se le conoce con el nombre de submuestreo o diezmado, que en este caso es por un factor de 2 y se denota por $2\downarrow$ [Chui, 97]. Si se desea seguir descomponiendo en el siguiente nivel, es necesario tomar como entrada los coeficientes de aproximación

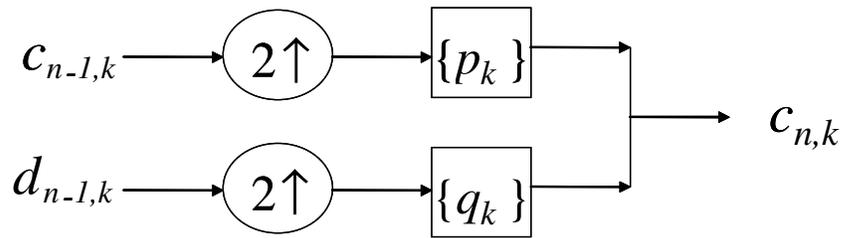
Cuando se realiza la operación de submuestreo a una señal se extraen muestras, en este caso las impares. Esta pérdida de información es definitiva e irre recuperable como se observa en la Figura 9. Esta es una operación variante en el tiempo que ocasiona la no invarianza en el desplazamiento de la Transformación *Wavelet*.

Figura 9 Submuestreo o decimación de una señal



Es posible reconstruir cada una de las descomposiciones en secuencias en el tiempo es decir convertir los coeficientes de aproximación y detalle que están en el dominio *wavelet*, en secuencias de aproximación y detalle en el tiempo para cualquier nivel de descomposición. Esto se logra a partir de un proceso de reconstrucción insertando ceros entre las muestras y filtrando con los filtros de reconstrucción pasa-altos q_k y pasa-bajos P_k adecuados. En la Figura 10 se hace una representación de este proceso.

Figura 10 Esquema de reconstrucción *Wavelet*.



Fuente: [Chui, 97].

De esta forma la secuencia de entrada $c_{n,k}$ se puede recuperar mediante una combinación de las secuencias $c_{n-1,k}$ y $d_{n-1,k}$ como:

$$c_{n,k} = \sum_m \{ p_{k-2m} c_{n-1,m} + q_{k-2m} d_{n-1,m} \} \quad (5)$$

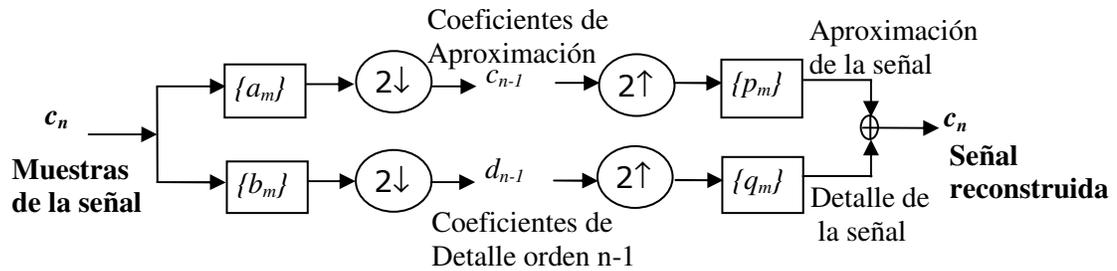
p_k y q_k son conocidas también como las secuencias de doble escala y actúan como filtros que permiten la recuperación de las secuencias en el tiempo.

En la Ecuación (5) la secuencia $c_{n,k}$ se puede calcular como una operación de convolución si en las secuencias $c_{n-1,k}$ y $d_{n-1,k}$ primero se insertan ceros entre

cada muestra. Este proceso se conoce con el nombre de sobremuestreo o interpolación y se denota por $2 \uparrow$ [Chui, 97].

De forma compacta se puede apreciar la secuencia de descomposición y reconstrucción en la Figura 11.

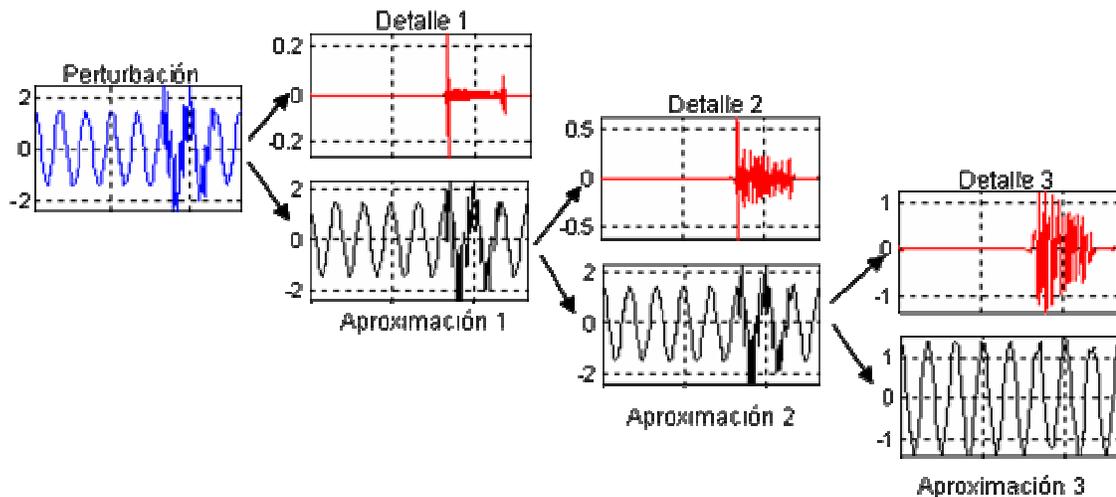
Figura 11 Esquema de descomposición y reconstrucción de una señal.



Fuente: [Chui, 97], [Mallat, 99].

En la Figura 12 se puede apreciar el esquema de descomposición de una perturbación tipo transitorio en secuencias de aproximación y de detalle para 3 niveles de resolución utilizando la función *wavelet* bior3.7. Esta descomposición permite separar la señal en rangos de frecuencia, con lo cual es posible analizar las características extraídas de cada componente aislada. Esta es la base para diferenciar cada una de las perturbaciones. Cabe recordar que la señal original se reconstruye a partir de la suma de todos los detalles y la última aproximación.

Figura 12 Esquema de descomposición de un transitorio oscilatorio en secuencias de aproximación y de detalle para 3 niveles de resolución utilizando la función Bior3.7.



Fuente: Elaborada por el autor.

2.3. CONSIDERACIONES FINALES

En este capítulo se presentó el marco teórico para abordar el desarrollo de las estrategias de detección e identificación, presentadas en los capítulos 3 y 4 respectivamente. Donde se incluyen las definiciones de las perturbaciones que afectan la calidad de la energía y de la transformada *wavelet*. A continuación se presenta la estrategia de detección de perturbaciones que utiliza como base la descomposición de la señal empleando la transformada *wavelet* discreta.

3. ESTRATEGIA DE DETECCIÓN DE PERTURBACIONES

En el tema de detección de perturbaciones, existe un gran número de técnicas y algoritmos. En este trabajo se presentan algunas de ellas y se propone técnica basada en las funciones *Wavelet*, porque permiten detectar y localizar las perturbaciones, y también porque estas funciones son utilizadas en la técnica de identificación (conformación de los patrones necesarios para la clasificación). Adicionalmente, se describen otras técnicas comúnmente utilizadas para detectar eventos.

En este trabajo la detección consiste en encontrar un cambio o variación en un parámetro dado. El valor del parámetro es comparado con el valor de un margen o umbral establecido. Si el margen es excedido, significa que existe o se ha detectado una variación o perturbación de la señal. Debido a esto se propone a partir del valor máximo de la magnitud de la salida obtenida en la convolución de la perturbación y el filtro de descomposición pasa-altas (FDPA) asociado a la función *wavelet* adecuada (Bior3.9), obtener el valor de umbral necesario para realizar la detección de perturbaciones.

Para seleccionar la función *wavelet* adecuada para la detección, se propuso una metodología de selectividad en frecuencia a partir de la zona de transición de la pendiente de la respuesta al impulso del FDPA y la longitud de la misma.

Finalmente se presentan resultados de simulaciones que permiten validar la estrategia de detección de perturbaciones que afectan la calidad de la energía eléctrica y se hace una pequeña comparación con el cálculo del valor RMS muestra a muestra, que es comúnmente utilizado en equipos de monitorización.

3.1. ESTADO DEL ARTE EN LA DETECCIÓN DE PERTURBACIONES

Algunas técnicas utilizadas en la investigación para la detección de perturbaciones se describen a continuación:

En [Daponte, 04] se describe el diseño e implementación del *TransientMeter*, un sistema de monitorización para la detección, clasificación y medición de perturbaciones transitorias en sistemas de energía eléctrica (en ambiente industrial). Utiliza métodos basados en transformada *Wavelet* para la clasificación automática y caracterización de la señal. El esquema de detección es un circuito de disparo que compara la señal original con la obtenida de un filtro pasa bajas con frecuencia de corte 70 Hz. Si la diferencia sobrepasa el

umbral establecido, un multivibrador monoestable genera un pulso TTL que activa la tarjeta de adquisición de datos.

En [Lin, 05] se propone un modelo de detección de perturbaciones para armónicos, *sags* y *swells* utilizando una red neuronal probabilística-*wavelet*, con una arquitectura de dos capas, incluyendo la capa *Wavelet* (la función de activación es una *Wavelet*) y la capa probabilística (Tiene dos subcapas ocultas y una de salida). Se utiliza la transformación *Wavelet* para extraer las características de diferentes perturbaciones y la red probabilística para clasificar los patrones obtenidos. Los resultados de las simulaciones muestran que se acorta el tiempo de procesamiento cuando se realiza la detección y posterior clasificación en una misma red.

El Filtrado *Kalman* es otra técnica de seguimiento, utilizada para la detección. [Styvaktakis, 02] presenta un análisis sobre la utilización del filtro *Kalman* en la detección de huecos de tensión y también en la estimación de la magnitud de la tensión, centrándose en las propiedades de resolución en tiempo para la detección de variaciones rápidas, lentas y rápidas repetitivas [Duarte, 04]. Asimismo [Chowdhury, 91] presenta una técnica de seguimiento para detectar fallas en sistemas de potencia y estimación de pre y post falla en señales de tensión y corriente. El algoritmo propuesto se basa en el filtro *kalman* y la prueba de hipótesis (herramienta estadística). Este esquema se utiliza en relés de protección de líneas de transmisión doble circuito.

En [Duarte, 04] se propone una modificación de la matriz de covarianza de la señal de ruido de la ecuación de estado, lo cual mejora la rapidez de detección en filtros *Kalman* con orden superior a 1. Asimismo, se muestra como el filtro *Kalman* detecta con mayor rapidez que el algoritmo basado en el valor eficaz, cambios de tipo escalón en la amplitud de la señal de tensión.

Otra herramienta muy utilizada y que brinda buenas características de las variaciones de la amplitud de la componente fundamental es el cálculo del valor RMS (este puede ser calculado muestra a muestra o utilizando una fracción del ciclo). "Las cualidades del algoritmo como son la simplicidad, velocidad de cálculo y su bajo requerimiento de capacidad de memoria para almacenar los resultados, hacen que sea la herramienta más utilizada en equipos de monitorización y medición" [Duarte, 04].

En [Chen, 02] se plantea la detección, localización, cuantificación y clasificación de perturbaciones de corta duración. Para esto, plantea una nueva *Wavelet* compleja adaptada con pocas escalas (menos tiempo de cómputo), lo que permite extraer patrones binarios de ambos dominios tiempo y frecuencia. También recalca que existen otros métodos mejores para la detección pero sólo tienen esta cualidad y no la de localización.

La técnica seleccionada para la detección de la perturbación se basa en la transformada *wavelet* discreta, por las características expresadas en el numeral 2.2 (TRANSFORMADA WAVELET DISCRETA), por la sensibilidad que tiene a la variación o cambios en la magnitud y en las componentes de frecuencia de la señal a analizar y por sus ventajas frente a algoritmos como el cálculo del valor eficaz y por los buenos resultados presentados en los trabajos: [Janik & Lobos, 06], [Vega, Duarte & Ordóñez, 06], [Vega, 04] y [Lin, 05] donde se utiliza la secuencia de detalles del primer nivel de descomposición para detectar y localizar los tiempos donde comienza y/o termina una perturbación y por supuesto la duración de la misma. De otra parte [Chen, 02] y [Dwivedi & Singh, 06] utilizan los coeficientes de detalles del primer nivel de descomposición para tal labor en lugar de la secuencia de detalles.

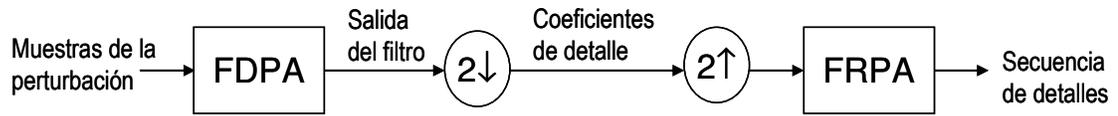
En este trabajo se determinó una forma más simple para detectar y localizar con igual o mejor precisión como en las dos propuestas anteriores; y es a partir de la salida obtenida al convolucionar la señal perturbada con la respuesta al impulso del filtro de descomposición pasa-altas (que llamaremos en adelante FDPA) asociado a una función *wavelet*. A continuación se describe la metodología utilizada para la detección y localización de perturbaciones.

1. Determinación de una técnica capaz de extraer características necesarias para la detección de perturbaciones (salida del FDPA).
2. Selección de la función *wavelet* con buena selectividad en frecuencia (función *wavelet* Bior3.9).
3. Determinación de un umbral que permita decidir si existe o no perturbación.
4. Realizar pruebas necesarias para validar la propuesta de detección y localización.

3.2. TÉCNICA DE DETECCIÓN BASADA EN LA TRANSFORMADA WAVELET

El cálculo de la transformada *Wavelet* discreta de una señal en el tiempo permite descomponer dicha señal en diferentes niveles de energía, dando la posibilidad de extraer características necesarias para caracterizar su comportamiento. En el primer nivel de descomposición de detalle se obtienen los coeficientes de detalle necesarios para la detección del inicio y/o final de la perturbación, éstos se obtienen a partir de la convolución de la señal perturbada con el FDPA asociado a una función *wavelet* específica y luego se diezma este resultado por dos, como se puede observar en la Figura 13. A partir de estos coeficientes de detalle, es posible obtener la secuencia de detalles realizando operaciones de inserción de ceros y luego convolucionar este resultado con un filtro de reconstrucción pasa-altas (FRPA) asociado a la misma función *wavelet* utilizada en la descomposición.

Figura 13. Características extraídas de una perturbación: salida del filtro, coeficientes de detalle y secuencia de detalles.

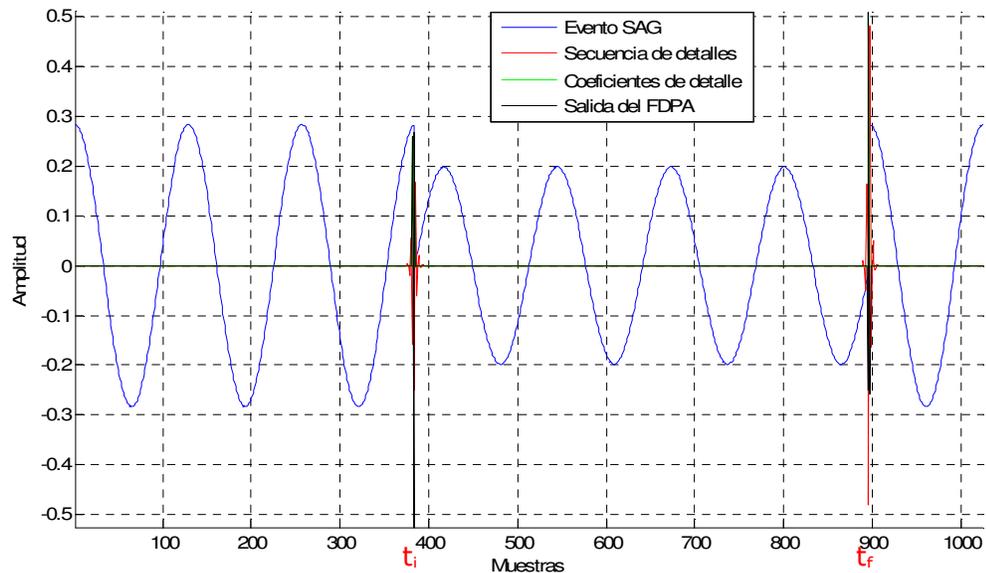


Fuente: Elaborada por el autor.

A partir del diagrama de la Figura 13, se toma como ejemplo una perturbación *sag* (con una magnitud de tensión del 70% y desfasado $\pi/4$ en el punto de inicio de la perturbación, muestreada a 3 840 Hz) y se le aplica todo el proceso, obteniéndose las siguientes tres características: salida del filtro, coeficientes de detalle y secuencia de detalles (ver Figura 14).

Los coeficientes de detalle obtenidos, tienen la mitad de las muestras de la perturbación. Para poder graficar estos coeficientes es necesario insertar un cero entre cada muestra para que todas características puedan ser observadas en una misma figura.

Figura 14 Características: salida del filtro, coeficientes de detalle y secuencia de detalles extraídas de un evento sag utilizando la función *wavelet bior3.9* para la transformación.

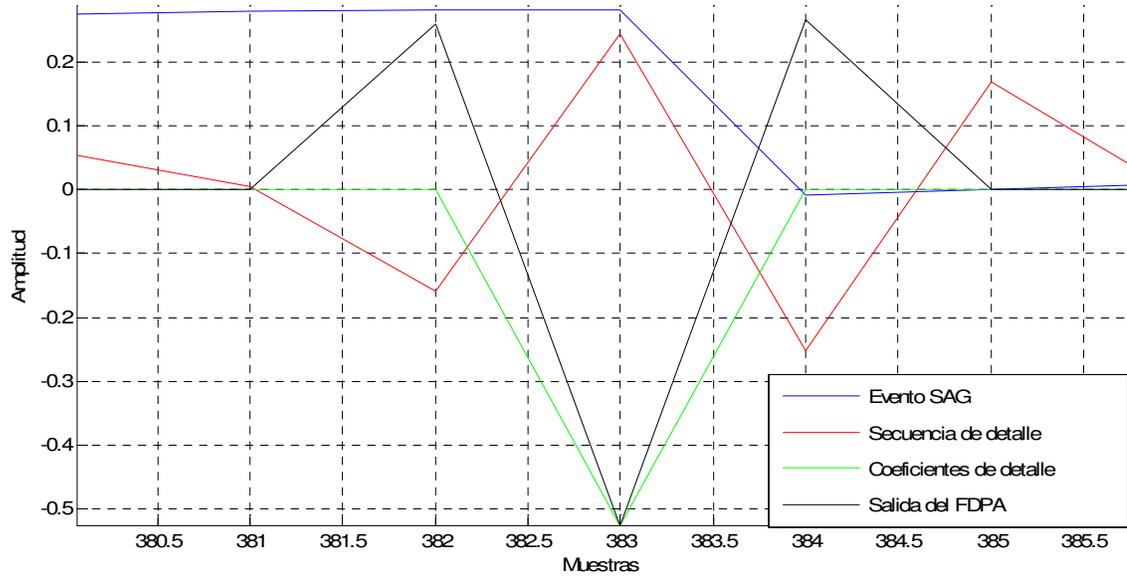


Fuente: Elaborada por el autor.

Es posible a partir de las diferentes características obtenidas, determinar el instante de inicio y/o final y duración de la perturbación. En la Figura 15 se

presenta un acercamiento de la Figura 14 en el instante donde comienza la perturbación.

Figura 15 Acercamiento de la Figura 14 en el instante donde comienza la perturbación.

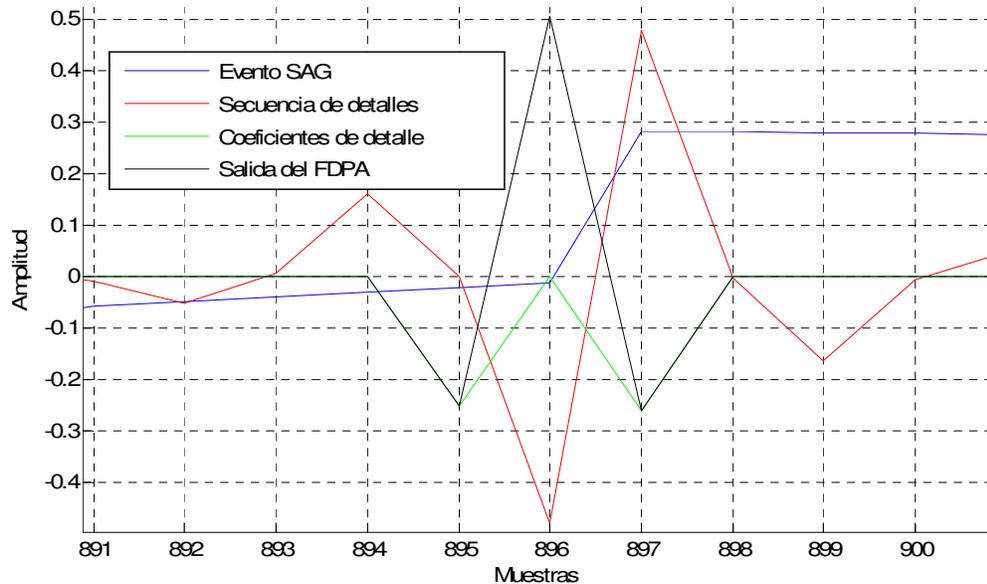


Fuente: Elaborada por el autor.

En la Figura 15 se puede observar que para este caso particular, la salida del FDPA y los coeficientes de detalle, tiene su valor máximo negativo justo una muestra antes del inicio de la perturbación, es decir en la posición 383. Por su parte la secuencia de detalle presenta su valor máximo negativo en la posición 384. La salida del filtro tiene una ventaja sobre los coeficientes de detalle y sobre la secuencia de detalles y es que sólo necesita realizar la convolución entre la perturbación y el FDPA. Además hay que tener en cuenta que la posición obtenida mediante la salida del FDPA, sólo hay que agregarle una muestra obtener el valor deseado. Conociendo la posición en la cual comienza la perturbación, es posible calcular el tiempo de inicio (t_i) y el tiempo final (t_f) de la perturbación dividiendo la posición obtenida sobre la frecuencia de muestreo de la señal. También es posible calcular la duración de la perturbación mediante la diferencia entre t_f y t_i .

En la Figura 16 se pueden observar las tres características obtenidas, en el instante donde finaliza la perturbación. Cabe anotar que los coeficientes de detalles pierden la mitad de muestras después del filtrado y al intentar reconstruirla insertando ceros, es posible que el valor máximo haya sido eliminado, como es el caso que se presenta en instante donde finaliza la perturbación.

Figura 16 Acercamiento de la Figura 14 en el instante donde finaliza la perturbación.



Fuente: Elaborada por el autor.

En la Figura 16 se muestra claramente como el valor máximo de los coeficientes de detalle que debería estar en el mismo lugar de la salida del FDPA, es de valor cero debido a la inserción de los mismos.

¿Cómo se determina si existe o no perturbación? Después de haber obtenido el valor máximo de la salida del FDPA ya sea negativo o positivo, éste se compara con un umbral establecido, si supera este valor, se considera que existe una perturbación. Antes de calcular el valor del umbral es necesario seleccionar una función *wavelet* con buena selectividad en frecuencia.

3.3. SELECCIÓN DE LA WAVELET

Para la selección de la función *Wavelet* o el conjunto de funciones *Wavelets* que permitan un mejor desempeño en la detección de perturbaciones, se procedió a evaluar cada una de ellas en un determinado grupo familias¹ definido. Las familias *Wavelets* analizadas son: Biortogonales (Bior), *Coiflets* (Coif), *Symlets* (Sym) y *Daubechies* (Db); estas familias son funciones discretas de duración efectiva finita y poseen un numeroso conjunto de funciones *Wavelets* para desarrollar las pruebas. No se utilizan otras *Wavelets* porque en su mayoría son funciones continuas. Las características principales

¹ A partir de una función *Wavelet* madre pueden ser generadas más funciones *Wavelet*. por ejemplo la *Wavelet* Daubechies (Db) tiene la familia Db1, Db2, Db3...DbN (Cap. 2).

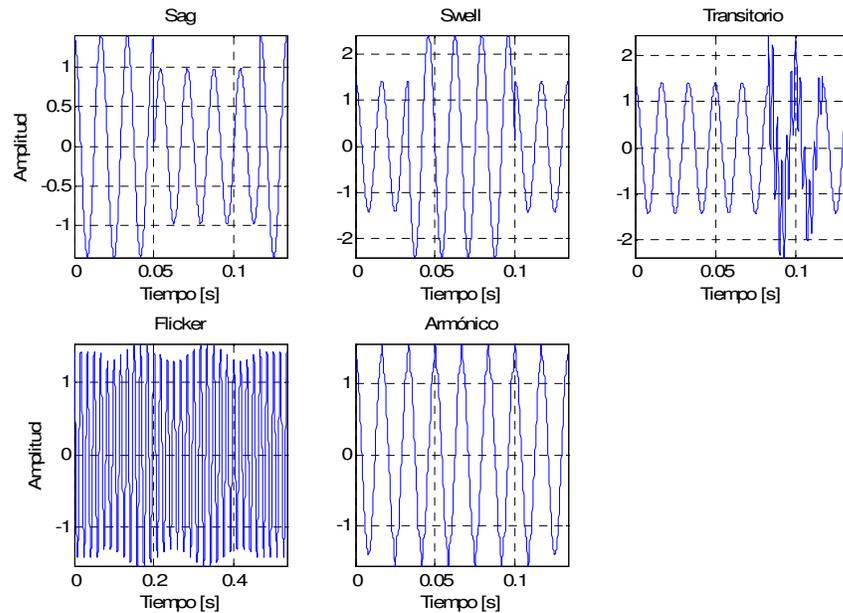
del conjunto de *Wavelet* utilizado en la búsqueda de la función *Wavelet* más adecuada para el proceso de detección son [Daubichies, 92]:

- ✓ Ortogonalidad
- ✓ Biorortogonalidad
- ✓ Soporte compacto
- ✓ Simetría
- ✓ Posibilidad de calcular la transformada *wavelet* discreta

Para la selección de la mejor *Wavelet* se propuso el criterio de ***selectividad en frecuencia y longitud de la respuesta al impulso del filtro***. La mejor selectividad en frecuencia se determina a partir de la mayor pendiente de la zona de transición de la respuesta en frecuencia del filtro de descomposición pasa-altas de la función *Wavelet* seleccionada. De esta forma se busca detectar y ubicar en el tiempo los cambios bruscos (alta frecuencia) que corresponden al inicio de una perturbación. A la vez se busca la menor longitud de la respuesta al impulso de este filtro para que el tiempo de cálculo en la detección sea el menor posible.

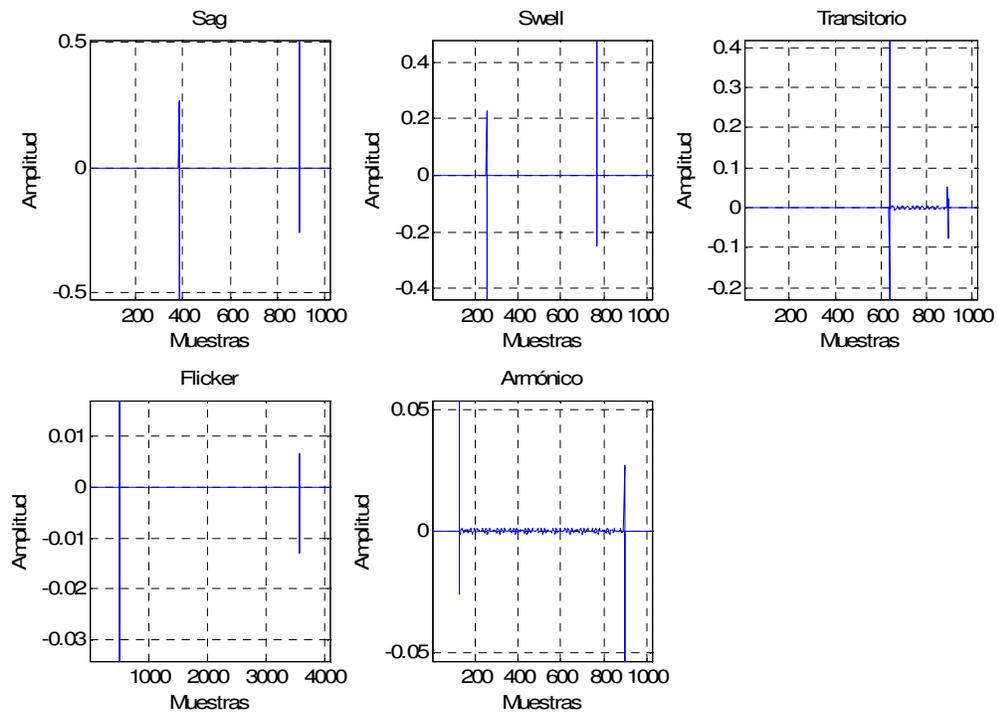
Como ya se había mencionado, se utilizará para la detección la salida del FDPA de una función *wavelet*. El filtro pasa-altas permite seleccionar información o contenido de alta frecuencia. Un cambio brusco en la forma de onda se ve reflejado en el espectro en las frecuencias altas. En la Figura 17 se presentan 5 señales sintéticas que corresponden a perturbaciones electromagnéticas *sag*, *swell*, transitorio oscilatorio, *flicker* y armónico. Estas señales fueron muestreadas a 128 muestras por ciclo de 60 Hz [m/c] (3 840 Hz) y se procesaron 8 ciclos excepto para la perturbación *flicker* que se presenta con 32 ciclos. En la Figura 18 se presentan las salidas correspondientes a cada perturbación de la Figura 17 convolucionada con las muestras de la respuesta al impulso del FDPA asociado a la función *Wavelet* Bior3.9 la cual corresponde a la mejor función *wavelet* de acuerdo con los criterios de selectividad en frecuencia y longitud de la respuesta al impulso del filtro.

Figura 17 Formas de onda de perturbaciones muestreadas a 128 [m/c]



Fuente: Elaborada por el autor.

Figura 18 Salidas correspondientes a la convolución de las perturbaciones de la Figura 17 con las muestras del FDPA asociado a la función *Wavelet* Bior3.9.



Fuente: Elaborada por el autor.

Es posible apreciar en la Figura 18 la localización del inicio y/o fin del evento. También es de notar que las amplitudes de las salidas de las perturbaciones *flicker* y armónico son muy pequeñas comparadas con el resto de las salidas, esto se debe a que estas señales presentan variaciones marcadas en sus componentes de frecuencia y no en magnitud.

Para encontrar la mejor función *wavelet* utilizando el criterio de selectividad en frecuencia y la longitud de la respuesta al impulso del FDPA asociado a la función *wavelet*, se procede inicialmente a calcular la magnitud de la respuesta en frecuencia para cada uno de ellos de acuerdo con la familia de la función *wavelet* asociada. Después de esta operación se procede a calcular la pendiente de la región cuasi-recta (zona de transición) de cada respuesta en frecuencia obtenida. La mayor pendiente obtenida se relaciona directamente con la mejor selectividad. En segunda instancia se tiene en cuenta la longitud de la respuesta al impulso del FDPA. La mejor relación entre estos criterios, indica la función *wavelet* más adecuada.

En la Tabla 2 se presenta la cantidad de funciones *Wavelets* para las 4 familias seleccionadas.

Tabla 2 Cantidades de funciones *Wavelets* utilizadas para obtener la magnitud de la respuesta en frecuencia.

	Biortogonales	Coiflets	Daubechies	Symlets	TOTAL
Cantidad	13	5	7	7	32

Fuente: Elaborada por el autor.

Para cada *wavelet* se evaluó la magnitud de la respuesta en frecuencia del FDPA para obtener las pendientes en diferentes zonas de transición que están entre el 75% y 20% del máximo valor de la respuesta en frecuencia de cada filtro.

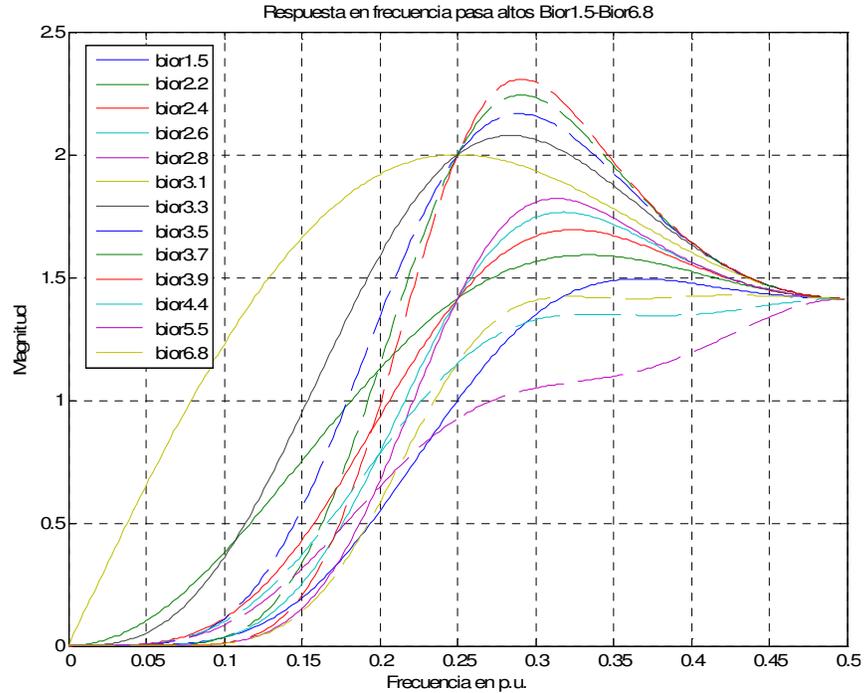
3.3.1. Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* Biortogonales

De la *wavelet* Biortogonal madre se derivan 15 *wavelet* hijas y estas son:

Bior 1.1 bior 1.3 bior 1.5 bior 2.2 bior 2.4 bior 2.6
 bior 2.8 bior 3.1 bior 3.3 bior 3.5 bior 3.7 bior 3.9
 bior 4.4 bior 5.5 y bior 6.8.

De estas 15 funciones *wavelet* biortogonales se descartaron la *bior 1.1* y la *bior 1.3* por presentar una banda de transición muy amplia. En la Figura 19 se muestra la magnitud de la respuesta en frecuencia de cada uno de los FDPA asociados a las funciones *wavelet* biortogonales de la *bior1.5* hasta *bior6.8*.

Figura 19 Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* de la Bior1.5 hasta Bior6.8.



Fuente: Elaborada por el autor.

Puede notarse en la Figura 19 que a medida que aumenta el número de la función *wavelet* bior, la pendiente tiende a ser mayor. En la Tabla 3 se presenta la pendiente de cada FDPA bior en diferentes zonas de transición. La selección de la función *Wavelet* se ha realizado a partir del promedio de estas pendientes. Asimismo, se presenta la longitud de la respuesta al impulso de cada filtro.

Tabla 3 Cálculo de las pendientes de diferentes zonas de transición de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* bior1.5 a bior6.8 y su respectiva longitud de la respuesta al impulso.

Zona\Bior	1.5	2.2	2.4	2.6	2.8	3.1	3.3	3.5	3.7	3.9	4.4	5.5	6.8
70-50 %	8,98	7,50	10,48	13,01	15,30	10,35	13,10	16,31	19,21	21,94	8,22	4,73	11,88
75-40 %	8,95	7,51	10,45	12,98	15,17	10,49	13,09	16,21	19,11	21,77	8,21	4,13	11,85
75-20 %	8,72	7,54	10,17	12,47	14,56	11,20	12,81	15,61	18,30	20,74	8,17	5,01	11,49
60-40 %	9,15	7,77	10,63	13,13	15,34	11,34	13,35	16,42	19,30	21,96	8,54	6,27	12,09
Promedio	8,95	7,58	10,43	12,90	15,09	10,85	13,09	16,14	18,98	21,61	8,29	5,04	11,83

muestras de h[n]	2	3	3	3	3	4	4	4	4	4	7	11	11
------------------	---	---	---	---	---	---	---	---	---	---	---	----	----

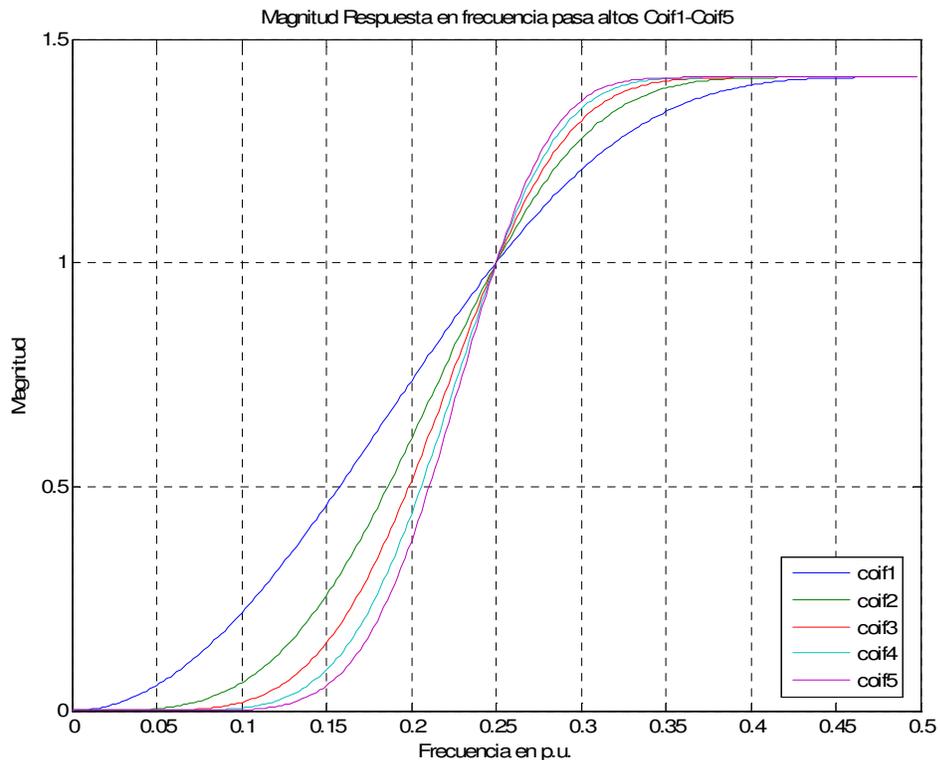
Fuente: Elaborada por el autor.

De la Tabla 3 se concluye que la magnitud de la respuesta en frecuencia del FDPA asociado a la función *wavelet* bior3.9 es la de mayor pendiente promedio y con una longitud de su respuesta al impulso de tan solo 4 muestras.

3.3.2. Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* Coiflet

La magnitud de la respuesta en frecuencia de los cinco (5) FDPA asociados a la función *wavelet* Coif (Coif1 a Coif5) se presentan en la Figura 20. Se puede observar que a medida que aumenta el orden del filtro, también mejora la selectividad del mismo.

Figura 20 Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* de la Coif1 hasta Coif5



Fuente: Elaborada por el autor.

De la Figura 20 se puede notar que el FDPA dado por la función *wavelet* coif5, tiene buena selectividad comparado con el resto pertenecientes a la misma familia. Sin embargo, la longitud de la respuesta al impulso (30) de este FDPA, es mayor que cualquiera de las longitudes de los FDPA asociados a la familia Biortogonal.

Tabla 4 Cálculo Valores de las pendientes de diferentes zonas de transición de la respuesta en frecuencia de los FDPA asociados a las funciones Coif1 a y su respectiva longitud de la respuesta al impulso.

Coif	1	2	3	4	5
70-50 %	5,35	7,83	9,75	11,36	12,75
75-40 %	5,35	7,82	9,72	11,28	12,72
70-20 %	5,43	7,72	9,50	11,00	12,36
60-40 %	5,57	8,07	9,98	11,60	13,02
Promedio	5,43	7,86	9,74	11,31	12,71

Muestras de h[n]	6	12	18	24	30
------------------	---	----	----	----	----

Fuente: Elaborada por el autor.

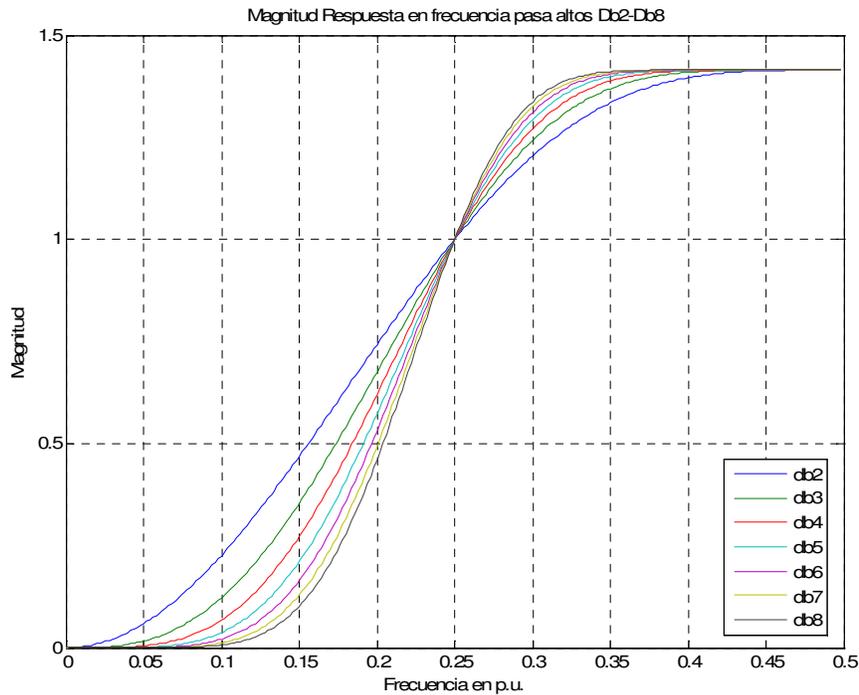
De la Tabla 4 se aprecia que aún el FDPA asociado a la función *wavelet* bior3.9 es el que menos muestras tiene (4 muestras), con un valor de pendiente mayor que el asociado a la función *wavelet* Coif5.

3.3.3. Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* Daubechies

La longitud de la respuesta al impulso de los FDPA asociados a esta familia a diferencia de los correspondientes a otras familias *wavelets*, se definen a partir de una ecuación matemática. Esta función es desarrollada en [Daubechies, 92] y la longitud de la respuesta a impulso del FDPA ($2*N$) se relaciona con el grado N de la función *wavelet* (DbN). Por ejemplo, la función Daubechies 4 (Db4) tiene 8 coeficientes.

En la Figura 21 se presenta la magnitud de la respuesta en frecuencia de los FDPA asociados a la función *wavelet daubechies* desde Db2 hasta Db8. En la misma figura se muestra cómo a medida que se aumenta el orden la *wavelet*, la pendiente mejora notablemente.

Figura 21 Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* de la Db2 hasta Db8



Fuente: Elaborada por el autor.

La Figura 21 las respuestas en frecuencia de los FDPA asociados a las funciones *wavelet daubechies* muestran un comportamiento similar al presentado en la familia de funciones *wavelet Coiflet* (Figura 20). A continuación se presenta en la Tabla 5 el cálculo de las pendientes correspondientes a las zonas de transición de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* Db2 a Db8 y la longitud de la respuesta al impulso correspondiente.

Tabla 5 Cálculo de las pendientes de diferentes zonas de transición de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* Db2 a Db8 y su respectiva longitud de la respuesta al impulso.

Db	2	3	4	5	6	7	8
70-50 %	5,35	6,51	7,49	8,40	9,17	9,90	10,61
75-40 %	5,24	6,50	7,57	8,48	9,35	10,10	10,79
70-20 %	5,35	6,51	7,49	8,40	9,17	9,90	10,61
60-40 %	5,47	6,75	7,82	8,77	9,62	10,40	11,15
Promedio	5,35	6,57	7,59	8,51	9,32	10,08	10,79

Muestras de h[n]	4	6	8	10	12	14	16
------------------	---	---	---	----	----	----	----

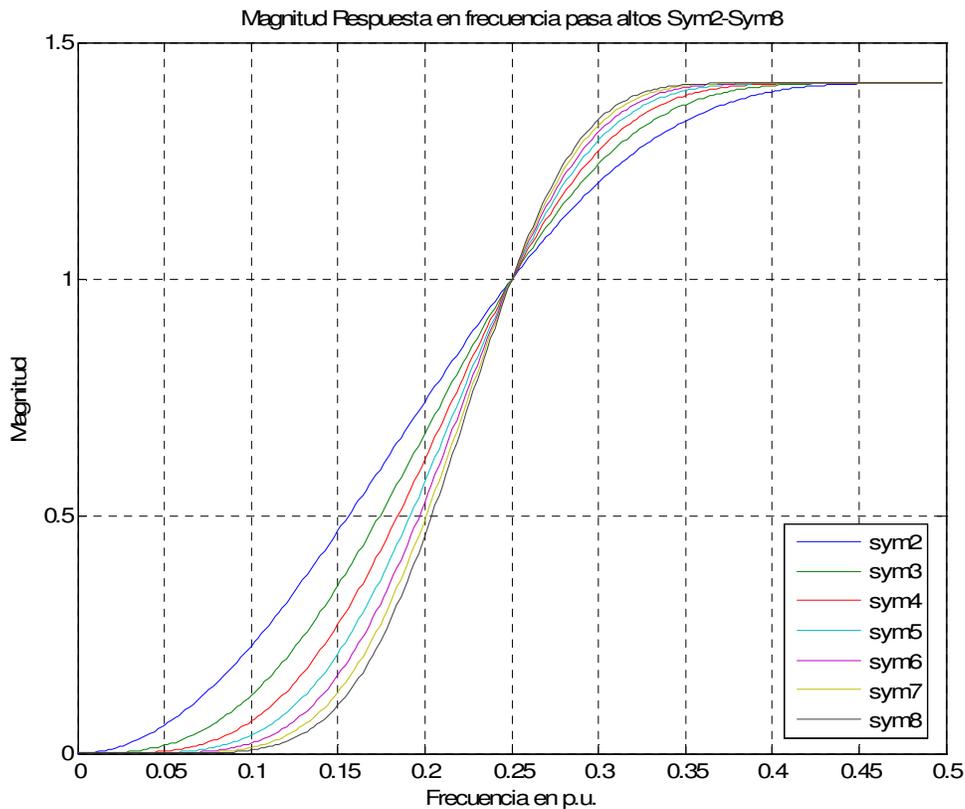
Fuente: Elaborada por el autor.

Es de notar que el valor promedio de las pendientes obtenidas para la familia de funciones *wavelet* Daubechies, no superan el valor obtenido por la familia Bior. Al analizar el caso de la función *wavelet* Bior3.9 que tiene una pendiente 5 veces mayor que la función Db2 y ambas con el mismo número de coeficientes, es posible afirmar que la función bior3.9 sigue teniendo las mejores características de selectividad para la detección.

3.3.4. Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* Symlet

Los filtros de las *wavelets* *Symlet* tienen características muy parecidas a las de los filtros de las *Daubechies*. Su estructura es similar pues se generan de la misma forma, por medio de una ecuación matemática desarrollada también por [Daubichies, 92]. El número de coeficientes también guarda la misma relación de las *daubechies*. En la Figura 22 se muestra la respuesta en frecuencia de los filtros pasa-altos *Symlet* desde sym2 hasta sym8.

Figura 22 Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* de la Sym2 hasta Sym8



Fuente: Elaborada por el autor.

En la Tabla 6 se encuentra el cálculo de las pendientes de los filtros *Symlets* y sus respectivas duraciones efectivas.

Tabla 6 Cálculo de las pendientes de diferentes zonas de transición de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* Db2 a Db8 y su respectiva longitud de la respuesta al impulso.

Sym	2	3	4	5	6	7	8
70-50 %	5,23	6,49	7,56	8,51	9,34	10,12	10,84
75-40 %	5,24	6,50	7,57	8,48	9,35	10,10	10,79
70-20 %	5,35	6,51	7,49	8,40	9,16	9,90	10,61
60-40 %	5,47	6,75	7,82	8,77	9,62	10,40	11,15
Promedio	5,32	6,56	7,61	8,54	9,37	10,13	10,85

Muestras de h[n]	4	6	8	10	12	14	16

Fuente: Elaborada por el autor.

Cabe resaltar que los valores de las pendientes asociados a la función *wavelet* daubechies (Tabla 5) y *Symlets* (Tabla 6) tienen un alto grado de similitud. Por tanto, la comparación con las pendientes asociadas a la función *wavelet* Biorotogonal, presenta la misma característica.

En la Tabla 7 se presenta el mayor valor de pendiente promedio asociado a la función *wavelet* correspondiente a cada familia seleccionada junto con la respectiva longitud de las muestras de su respuesta al impulso, h[n].

Tabla 7 Clasificación de las mejores funciones *Wavelets* según la familia de acuerdo con los criterios de selección.

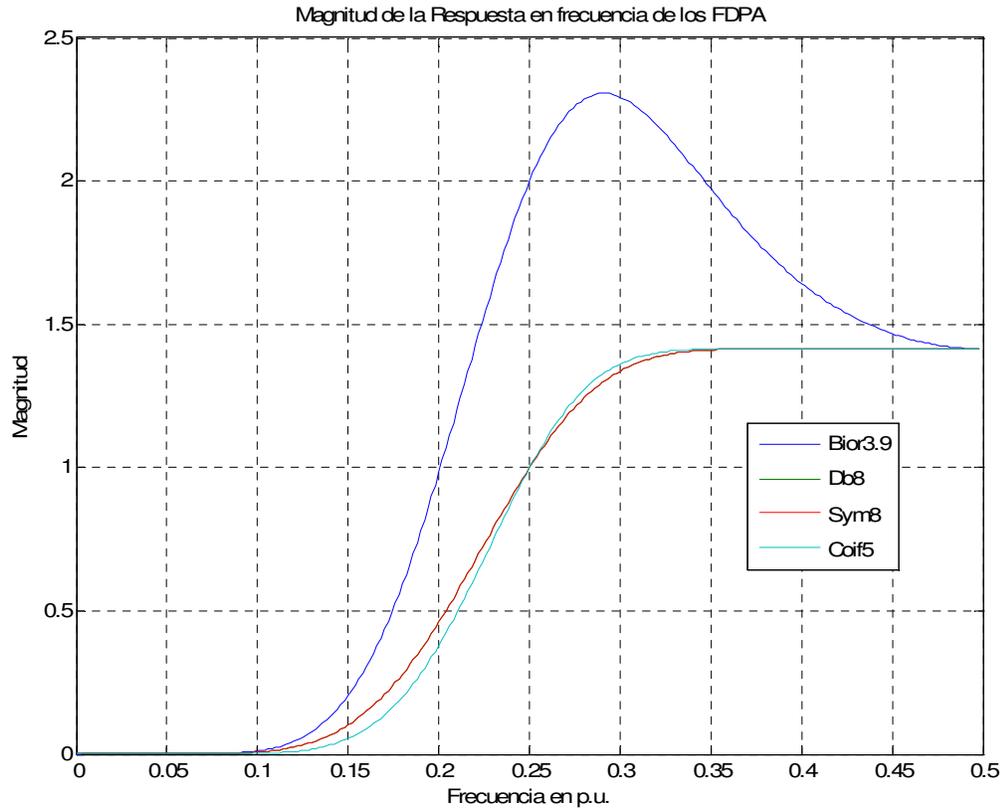
	Biorotogonales	Coiflets	Daubechies	Symlets
Función Wavelet	Bior3.9	Coif5	Db8	Sym8
Pendiente promedio	21,61	12,71	10,79	10,85
Muestras de h[n]	4	30	16	16

Fuente: Elaborada por el autor.

De la Tabla 7 se selecciona la función *wavelet* Bior3.9 como la de mejor respuesta en frecuencia por cumplir con los criterios de mayor valor de pendiente promedio y también por tener la menor longitud de la respuesta al impulso.

En la Figura 23 se presenta la magnitud de la respuesta en frecuencia de los 4 FDPA asociados a las funciones *wavelet* de la Tabla 7.

Figura 23 Magnitud de la respuesta en frecuencia de los FDPA asociados a las funciones *wavelet* Bior 3.9, Db8, Sym8 y Coif5.



Fuente: Elaborada por el autor.

Puede apreciarse en la Figura 23 que la inclinación de la pendiente para el FDPA correspondiente a la función *wavelet* Bior3.9 es mayor que en los FDPA correspondiente a las otras funciones.

A partir de la selección de la función *wavelet* adecuada para la detección, se procede a calcular el valor del umbral necesario para decidir si existe o no perturbación.

3.4. CÁLCULO DEL UMBRAL

La determinación del umbral requiere de un proceso de sintonización de acuerdo con las características del sistema eléctrico que se esté monitorizando. En este trabajo se realiza una exploración con diferentes tipos de perturbaciones para determinar un punto inicial para este umbral. Se analiza el

comportamiento de las amplitudes obtenidas en la salida de la convolución de la perturbación con el FDPA asociado a la función *wavelet* Bior3.9, tanto para la perturbación con ruido como sin éste. Es necesario también tomar los límites establecidos por las referencias [NTC 5000, 02] e [IEEE 1159, 95] para cada perturbación (ver Tabla 1).

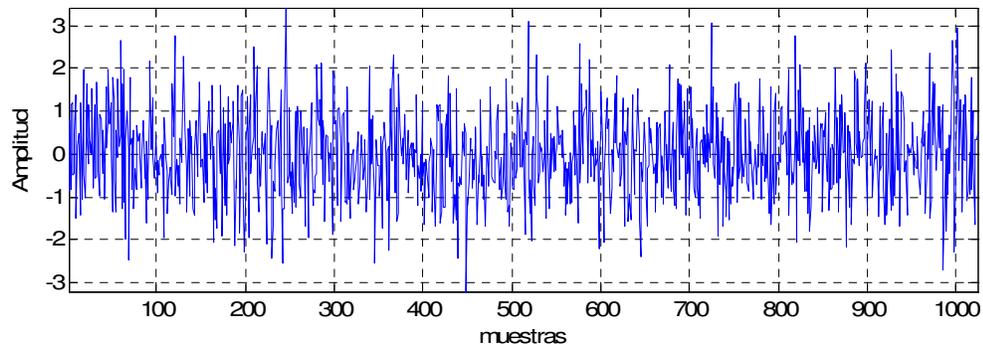
Para un conjunto de 84 perturbaciones de prueba (para *sag*, *swell* y armónico se tomaron 16 señales por cada uno y 18 para transitorio y *flicker*) con variaciones en amplitud, frecuencia y punto de inicio de la perturbación. Se obtuvo la salida del FDPA mencionado, a la cual se le calculó el valor máximo de la magnitud y su posición en muestras para calcular el error porcentual con respecto a un ciclo de 128 muestras, conociendo previamente el punto de inicio de la perturbación. Los resultados que se presentan a continuación corresponden a señales con una duración de 8 ciclos y perturbaciones con duraciones de 4 ciclos con y sin ruido. El valor eficaz del pre-evento (señal senoidal) es uno.

Para el análisis con ruido, se adiciona a la perturbación una señal aleatoria con varianza 1, media 0 y cuyos elementos están normalmente distribuidos como se muestra en la Figura 24. La señal de ruido es ponderada por tres valores para las respectivas pruebas y son [0,1 0,01 0,001] con los que se obtiene una relación señal a ruido de [20 40 60] decibeles, respectivamente. Para el cálculo de la relación señal a ruido SNR (sigla en inglés *signal to noise ratio*) se utiliza (8)

$$SNR = 10 \log_{10} \left(\frac{EnPer}{EnRuido} \right) \quad (6)$$

calculando previamente la energía de la perturbación (EnPer) y la energía del ruido aleatorio (EnRuido).

Figura 24 Ruido aleatorio con distribución normal, varianza 1 y media 0



Fuente: Elaborada por el autor.

A continuación se presentan las tablas correspondientes al análisis de la detección de diferentes perturbaciones *sag* en ausencia y en presencia de ruido para SNRs de 20, 40 y 60 decibeles (dB) y con variaciones de ángulo de fase, amplitud y punto de inicio de la perturbación. Se presentan los valores máximos de la magnitud de la salida del FDPA en ausencia y en presencia de ruido, la posición calculada donde inicia la perturbación (sólo en ausencia de ruido) a partir del valor máximo calculado; y el error porcentual de la detección para ambas situaciones (con y sin ruido). Además, se presenta el error porcentual de la secuencia de detalles, el cual es muy similar al obtenido con la salida del FDPA, requiriendo esta última menos procesamiento para su cálculo. La nomenclatura utilizada en las tablas es la siguiente:

MagV%	Magnitud de la Tensión en porcentaje
MáxSal	Valor máximo de la magnitud de la salida del FDPA
Pos	Posición de la detección en muestras
ErS%	Error porcentual de detección de la salida del FDPA
ErD%	Error porcentual de la secuencia de detalles
Ini p	Inicio de la perturbación en muestras
3er	Magnitud del tercer armónico en porcentaje
5to	Magnitud del quinto armónico en porcentaje
7mo	Magnitud del séptimo armónico en porcentaje
DAT	Distorsión armónica total en porcentaje

Tabla 8 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 con y sin ruido para la perturbación *sag*.

	MagV%	Sin ruido				SNR 20 dB		SNR 40 dB		SNR 60 dB	
		MáxSal	Pos	ErS%	ErD%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini p 272 sin fase	95	0,019	271	0	0	0,249	178,1	0,0319	0	0,01872	0
	90	0,038	271	0	0	0,249	178,1	0,0508	0	0,03766	0
	50	0,189	271	0	0	0,249	178,1	0,2024	0	0,18924	0
	10	0,341	271	0	0	0,301	0	0,354	0	0,34081	0
Ini p 304 sin fase	95	0,016	303	0	0,78	0,249	203,1	0,0264	2,344	0,0162	0
	90	0,033	303	0	0,78	0,249	203,1	0,0347	0	0,03255	0
	50	0,163	303	0	0,78	0,249	203,1	0,1655	0	0,16331	0
	10	0,294	303	0	0,78	0,253	0	0,2962	0	0,29406	0
Ini p 272 fase pi/4	95	0,344	271	0	0	0,304	0	0,3569	0	0,34374	0
	90	0,346	271	0	0	0,305	0	0,3588	0	0,34558	0
	50	0,361	271	0	0	0,32	0	0,3735	0	0,36031	0
	10	0,375	271	0	0	0,335	0	0,3882	0	0,37503	0
Ini p 304 fase pi/4	95	0,147	303	0	0	0,249	203,1	0,1452	0	0,14739	0
	90	0,122	303	0	0	0,249	203,1	0,1203	0	0,12243	0
	50	0,077	303	0	0,78	0,249	203,1	0,0794	0	0,0772	0
	10	0,277	303	0	0,78	0,249	203,1	0,279	0	0,27684	0

Fuente: Elaborada por el autor.

En ausencia de ruido, la técnica de detección permite localizar el evento de manera precisa, de igual forma la secuencia de detalles, tiene similar capacidad pero realizando mayor cálculo. De la Tabla 8 se tiene también que la técnica de detección es inmune a SNRs superiores o iguales a 40 dB para las perturbaciones tipo *sag* utilizadas en esta prueba debido a la sensibilidad a los cambios de magnitud de la misma ante este tipo de perturbaciones. Por otra parte una SNR del orden de los 20 dB genera errores considerables en la técnica de detección, sólo magnitudes del *sag* cercanas al 10% y algunos con cambio en la fase, permiten ser detectados con esta técnica.

La norma [NTC 5000, 02] plantea que el límite para determinar una perturbación *sag* es del 90% de su magnitud de tensión, esta técnica permite detectar valores superiores a los aconsejados por la norma, aún con SNR alrededor de 40 dB. El valor del umbral empírico encontrado en estas simulaciones para esta perturbación en particular, está por encima de 0,016 que es el valor obtenido para el 95% de la magnitud de la tensión del *sag* con SNR de 60 dB.

En la Tabla 9 se presentan los resultados para el conjunto de perturbaciones *swell* considerados.

Tabla 9 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 con y sin ruido para la perturbación *swell*.

	MagV%	Sin ruido				SNR 20 dB		SNR 40 dB		SNR 60 dB	
		MáxSal	Pos	ErS%	ErD%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini p 272 sin fase	105	0,019	272	0	0	0,249	178,1	0,0264	6,25	0,01918	0
	110	0,038	272	0	0	0,249	178,1	0,0264	6,25	0,03812	0
	150	0,189	272	0	0	0,249	178,1	0,1765	0	0,1897	0
	180	0,303	272	0	0	0,343	0	0,2902	0	0,30338	0
Ini p 304 sin fase	105	0,016	304	0	0,78	0,249	203,1	0,0264	18,75	0,01648	0
	110	0,033	304	0	0,78	0,249	203,1	0,0307	0	0,03283	0
	150	0,163	304	0	0,78	0,249	203,1	0,1614	0	0,16359	0
	180	0,262	304	0	0,78	0,302	0	0,2595	0	0,26165	0
Ini p 272 fase pi/4	105	0,34	272	0	0,78	0,3	0	0,3532	0	0,34006	0
	110	0,338	272	0	0,78	0,298	0	0,3514	0	0,33822	0
	150	0,324	272	0	0,78	0,283	0	0,3367	0	0,3235	0
	180	0,313	272	0	0,78	0,272	0	0,3256	0	0,31246	0
Ini p 304 fase pi/4	105	0,197	304	0	0	0,249	203,1	0,1951	0	0,1973	0
	110	0,222	304	0	0	0,263	0	0,2201	0	0,22225	0
	150	0,422	304	0	0	0,463	0	0,4197	0	0,42189	0
	180	0,572	304	0	0	0,612	0	0,5695	0	0,57162	0

Fuente: Elaborada por el autor.

De la Tabla 9 se observa un comportamiento similar al analizado en la perturbación *sag*, es decir que ambas perturbaciones pueden ser detectadas de manera adecuada con esta estrategia a pesar de una SNR del orden de 20 dB.

Puede observarse en esta misma tabla que perturbaciones *swell* con desfase pueden ser detectados inclusive si la SNR es del orden de 10 dB, esto es debido al cambio brusco de la onda, lo que se ve reflejado en una variación en alta frecuencia. El valor de umbral empírico puede ser de 0,016 para una SNR de 60 dB y 105% de amplitud de tensión.

En cuanto a las pruebas con la perturbación transitoria, puede notarse en la Tabla 10 que la técnica de detección es sensible a pequeñas variaciones en amplitud y a cambios de frecuencia en la perturbación. Una SNR de 40 dB puede provocar errores en la detección de algunos transitorios de baja magnitud, debido a que el ruido aleatorio tiende a parecerse al mismo evento. Puede decirse que esta técnica de detección es adecuada para perturbaciones *sags*, *swells* y transitorios oscilatorios de baja frecuencia si se considera un error de detección menor al cinco por ciento (aproximadamente seis muestras). El modelo de la perturbación transitoria que se adiciona al pre-evento utilizado para la simulación es el siguiente:

$$P_{tran} = \exp\left(-\frac{t}{\tau}\right) * \cos(2\pi * ft + \phi) \quad (7)$$

Donde P_{tran} indica la perturbación transitoria, τ la constante de relajación (20 ms), ϕ es el ángulo de fase de la oscilación y ft es la frecuencia oscilatoria igual a [300 1000 3000] Hz.

Tabla 10 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 con y sin ruido para la perturbación transitorio.

		Sin ruido					SNR 20 dB		SNR 40 dB		SNR 60 dB	
	Mag V	Frec Hz	MáxSal	Pos	ErS%	ErD%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Inicio pos 272	0.1 pu	300	0,036	271	0	0,78	0,257	10,16	0,0327	0	0,03599	0
		1000	0,041	271	0	0,78	0,257	10,16	0,0377	0	0,04102	0
		3000	0,114	276	3,91	4,69	0,282	7,813	0,1149	7,813	0,11564	3,91
	0,5 pu	300	0,18	271	0	0,78	0,257	10,16	0,1767	0	0,17997	0
		1000	0,205	271	0	0,78	0,257	10,16	0,2018	0	0,20513	0
		3000	0,572	276	3,91	4,69	0,713	7,813	0,5607	3,906	0,57355	3,91
	4 pu	300	1,44	271	0	0,78	1,411	0	1,4366	0	1,43985	0
		1000	1,641	271	0	0,78	1,612	0	1,6378	0	1,64108	0
		3000	4,579	276	3,91	4,69	4,626	3,906	4,5674	3,906	4,58026	3,91
Inicio pos 304	0.1 pu	300	0,036	303	0	0,78	0,257	35,16	0,0426	0	0,03611	0
		1000	0,041	303	0	0,78	0,257	35,16	0,0476	0	0,04114	0
		3000	0,114	308	3,91	4,69	0,257	35,16	0,1127	3,906	0,11335	3,91

	0,5 pu	300	0,18	303	0	0,78	0,257	35,16	0,1866	0	0,1801	0
		1000	0,205	303	0	0,78	0,257	35,16	0,2117	0	0,20525	0
		3000	0,572	308	3,91	4,69	0,712	3,906	0,5707	3,906	0,57126	3,91
	4 pu	300	1,44	303	0	0,78	1,412	0	1,4464	0	1,43997	0
		1000	1,641	303	0	0,78	1,613	0	1,6477	0	1,6412	0
		3000	4,579	308	3,91	4,69	4,719	3,906	4,5774	3,906	4,57798	3,91

Fuente: Elaborada por el autor.

En el caso del evento transitorio es más difícil definir el valor de umbral debido a las múltiples variaciones que puede tener este fenómeno tanto en frecuencia como en magnitud. Es posible iniciar con un valor de umbral empírico de 0,03 para detectar transitorios con amplitud desde 0,1 p.u. con frecuencia desde 300 Hz en ambientes con SNR desde 40 dB.

En la Tabla 11 se presentan los resultados para el evento *flicker*, donde se puede apreciar claramente que es un evento que produce valores máximos de la salida del FDPA muy pequeños, comparados con los valores de máximos obtenidos con las anteriores perturbaciones. No obstante, como se trata de un evento de estado estacionario la detección de este evento puede completarse con una estrategia de identificación como la que se propone en el capítulo 4.

Tabla 11 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 con y sin ruido para la perturbación *flicker*.

		Sin ruido				SNR 20 dB		SNR 40 dB		SNR 60 dB		
Mag V	Frec Hz	MáxSal	Pos	ErS%	ErD%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%	
Ini pos 272	0.1 %	8	9E-05	272	0	2,34	0,249	178,1	0,0264	6,25	0,00286	4,69
		15	4E-04	272	0	0	0,249	178,1	0,0264	6,25	0,00286	4,69
		24	2E-04	272	0	0	0,249	178,1	0,0264	6,25	0,00286	4,69
	0.5 %	8	4E-04	272	0	0	0,249	178,1	0,0264	6,25	0,00286	4,69
		15	0,002	272	0	0	0,249	178,1	0,0264	6,25	0,00286	4,69
		24	0,001	272	0	0	0,249	178,1	0,0264	6,25	0,00286	4,69
	5 %	8	0,004	272	0	0	0,249	178,1	0,0264	6,25	0,00353	0
		15	0,019	272	0	0	0,249	178,1	0,0316	0	0,01842	0
		24	0,011	272	0	0	0,249	178,1	0,0264	6,25	0,01092	0
Ini pos 304	0.1 %	8	1E-04	304	0	0,78	0,249	203,1	0,0264	18,75	0,00286	29,7
		15	3E-04	304	0	0,78	0,249	203,1	0,0264	18,75	0,00286	29,7
		24	3E-04	304	0	0,78	0,249	203,1	0,0264	18,75	0,00286	29,7
	0.5 %	8	6E-04	304	0	0,78	0,249	203,1	0,0264	18,75	0,00286	29,7
		15	0,001	304	0	0,78	0,249	203,1	0,0264	18,75	0,00286	29,7
		24	0,002	304	0	0,78	0,249	203,1	0,0264	18,75	0,00286	29,7
	5 %	8	0,006	304	0	0,78	0,249	203,1	0,0264	18,75	0,00636	0
		15	0,014	304	0	0,78	0,249	203,1	0,0264	18,75	0,01362	0
		24	0,015	304	0	0,78	0,249	203,1	0,0264	18,75	0,01553	0

Fuente: Elaborada por el autor.

Esta estrategia de detección sólo permite detectar perturbaciones *flicker* con amplitudes de la salida del FDPA alrededor de 0,0028 en ambiente con SNR alrededor de 60 dB, es decir, en un ambiente con una SNR menor sería imposible detectarlas. El límite de umbral establecido por las anteriores perturbaciones no permitiría detectar este fenómeno. Quizá haya la posibilidad de combinar esta estrategia con un método de identificación que permita detectar la presencia de esta perturbación.

En el caso de la perturbación armónico, es posible detectarlo en un ambiente con bajo contenido de ruido, a pesar de esto es un fenómeno de estado estacionario y requiere ser acompañado con un método de identificación que permita asegurar dicha variación. En la Tabla 12 se observa que los valores máximos obtenidos en estas simulaciones están en un rango un poco menor al obtenido para las primeras tres perturbaciones pero mayor al de la perturbación *flicker* pudiendo ser detectada la perturbación armónico mejor que este último.

Tabla 12 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 con y sin ruido para la perturbación armónico.

		Mag del armónico %				Sin ruido				SNR 20 dB		SNR 40 dB		SNR 60 dB	
		3er	5to	7mo	DAT	MáxSal	Pos	ErS%	ErD%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Fase cero	0,9	0,7	0,4	1,21	0,004	271	0	0	0,249	178,1	0,0264	6,25	0,00339	0	
	7	0,7	0,4	7,05	0,015	271	0	0	0,249	178,1	0,0282	0	0,01504	0	
	0,9	4	0,4	4,12	0,015	271	0	0	0,249	178,1	0,0275	0	0,01428	0	
	7	4	0,4	8,07	0,026	271	0	0	0,249	178,1	0,0391	0	0,02592	0	
	0,9	0,7	2	2,3	0,002	271	0	1,56	0,249	178,1	0,0265	6,25	0,00286	4,69	
	7	0,7	2	7,31	0,014	271	0	0	0,249	178,1	0,0266	0	0,01341	0	
	0,9	4	2	4,56	0,013	271	0	0	0,249	178,1	0,0264	6,25	0,01265	0	
	7	4	2	8,31	0,025	271	0	0	0,249	178,1	0,0375	0	0,02429	0	
Fase 180 3er armónico	0,9	0,7	0,4	1,21	4E-04	272	0,78	1,56	0,249	178,1	0,0264	6,25	0,00286	4,69	
	7	0,7	0,4	7,05	0,011	271	0	0,78	0,249	178,1	0,0264	6,25	0,01169	0	
	0,9	4	0,4	4,12	0,011	271	0	0	0,249	178,1	0,0263	6,25	0,01084	0	
	7	4	0,4	8,07	0,002	270	0,78	0,78	0,249	178,1	0,0263	6,25	0,00286	4,69	
	0,9	0,7	2	2,3	0,001	271	0	0,78	0,249	178,1	0,0265	6,25	0,00286	4,69	
	7	0,7	2	7,31	0,013	271	0	0,78	0,249	178,1	0,0265	6,25	0,01332	0	
	0,9	4	2	4,56	0,009	271	0	1,56	0,249	178,1	0,0264	6,25	0,00921	0	
	7	4	2	8,31	0,003	270	0,78	0,78	0,249	178,1	0,0264	6,25	0,00363	0,78	

Fuente: Elaborada por el autor.

El valor de umbral para esta perturbación puede ser de 0,0028 para ambientes con SNR de 60 dB. En ambientes con mayor ruido es imposible detectarla.

A continuación se presentan dos tablas resumen de los porcentajes de acierto en la detección de 84 perturbaciones en diferentes ambientes de ruido para las

4 funciones *wavelet* más destacadas. En el Anexo A se presentan en detalle las correspondientes tablas para cada función *wavelet*. De las dos tablas, la primera considera un error del 0% en la detección, es decir, en Tabla 13 se presentan los porcentajes de acierto cuando el tiempo de detección calculado coincide exactamente con el que la función tiene. La segunda permite un error menor o igual al 5% (ver Tabla 14), siendo este error aceptable ya que está en el orden de 6 muestras.

Tabla 13 Resumen de los porcentajes de acierto para la detección de 84 perturbaciones con SNR de 20, 40 y 60 decibeles para 4 funciones *wavelet* considerando un error de detección del 0%.

Perturbación	Bior 3.9 %			Coif5 %			Db8 %			Sym8 %		
	20dB	40dB	60dB	20dB	40dB	60dB	20dB	40dB	60dB	20dB	40dB	60dB
Sag	43,75	93,75	100	0	0	0	0	0	0	0	0	0
Swell	43,75	87,5	100	0	0	0	0	0	0	6,25	0	0
Transitorio	22,22	55,56	55,56	0	0	0	0	0	0	0	25	37,5
Flicker	0	5,556	33,33	0	0	0	0	0	0	0	0	12,5
Armónico	0	12,5	75	0	0	0	0	0	0	0	0	12,5

Fuente: Elaborada por el autor.

De la Tabla 13 se tiene que la función *wavelet* Bor3.9 permite detectar con precisión la mayoría de las perturbaciones (considerando un error de detección igual al 0 %.), caso contrario ocurre con las otras funciones *wavelet*, es decir, la selección de la función *wavelet* para la detección fue adecuada.

Tabla 14 Resumen de los porcentajes de acierto para la detección de 84 perturbaciones con SNR de 20, 40 y 60 decibeles para 4 funciones *wavelet* considerando un error de detección menor o igual al 5 %.

Perturbación	Bior 3.9			Coif5			Db8			Sym8		
	20dB	40dB	60dB	20dB	40dB	60dB	20dB	40dB	60dB	20dB	40dB	60dB
Sag	43,75	100	100	31,25	87,5	100	43,75	87,5	100	31,25	87,5	100
Swell	43,75	81,25	100	31,25	81,25	100	43,75	81,25	100	56,25	81,25	100
Transitorio	50	83,33	88,89	44,44	88,89	88,89	38,89	83,33	88,89	38,89	66,67	61,11
Flicker	0	5,556	55,56	0	0	38,89	0	0	38,89	0	0	33,33
Armónico	0	31,25	100	0	0	93,75	0	0	68,75	0	12,5	75

Fuente: Elaborada por el autor.

El porcentaje de acierto menor o igual a 5% presenta a todas las funciones *wavelet* con características similares para la detección (ver Tabla 14), pero en el acierto para SNR de 40 y 60 decibeles, la función Bior3.9 sigue dominando con tan solo cuatro muestras en la respuesta al impulso del FDPA. Es de esperar este comportamiento debido a que las 4 funciones *wavelet* presentan buena selectividad en frecuencia.

3.5. CONSIDERACIONES FINALES

La metodología presentada en este capítulo para la detección de perturbaciones ha arrojado buenos resultados con las simulaciones realizadas, presentando porcentajes de acierto del orden del 100% principalmente para perturbaciones *sag*, *swell* y armónico si se considera la presencia de ruido con SNR de 60 decibeles y si se consideran errores de detección menores o iguales a 5%. Para ambientes ruidosos con SNR menores a 40 dB, los fenómenos *flicker* y armónico no presentan buena localización en tiempo a menos que las amplitudes sean suficientemente fuertes (Porcentajes de acierto menores al 30 %). De igual forma la perturbación transitorio tiene buena localización dependiendo de las magnitudes del evento, pues se consideraron en la prueba magnitudes del orden de 0,1 en pu (valor pequeño para un evento que normalmente tiene magnitudes del orden de 2 en pu).

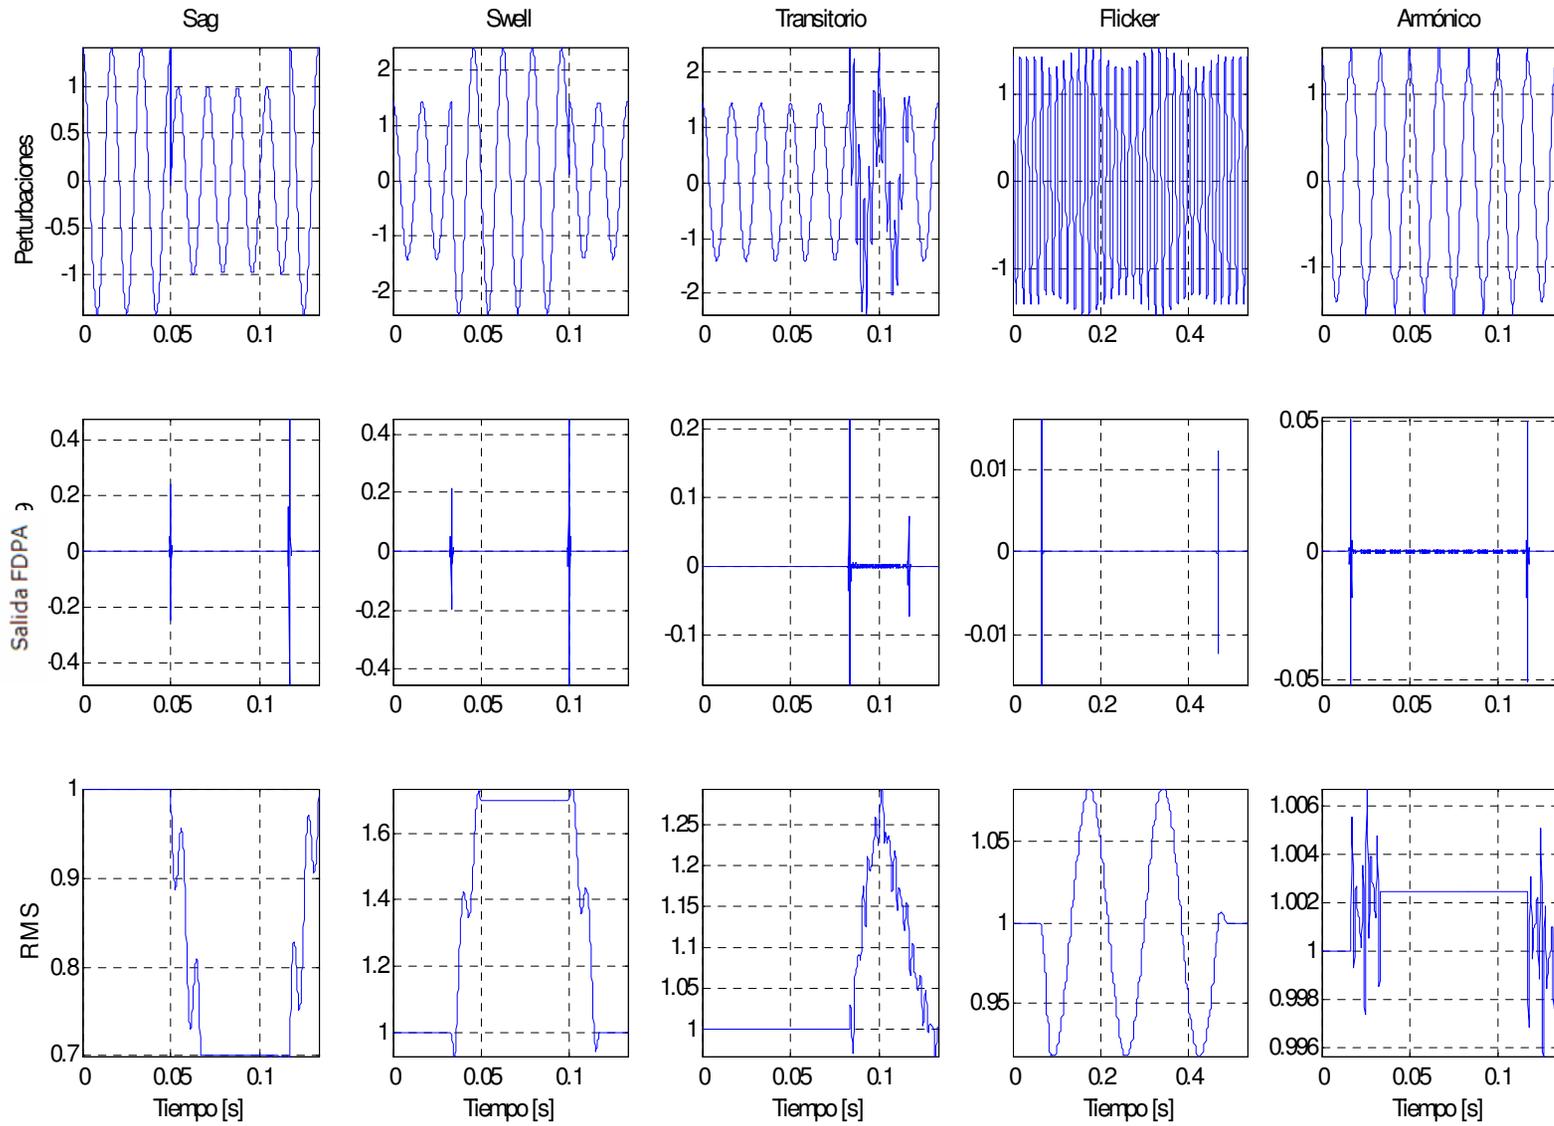
Se propuso un método para la selección de una función *wavelet* basado en la pendiente de la zona de transición y la longitud de la respuesta al impulso del FDPA. Los resultados demuestran que fue una buena elección esta metodología y se resalta el compromiso buena selectividad y menor longitud de la respuesta al impulso (4 muestras) del FDPA asociado a la función *wavelet*, dando como resultado la función *wavelet* Bior3.9., superando a funciones *wavelet* como la daubechies 4 (con respuesta al impulso de 8 muestras) que es relacionada en números e importantes artículos de carácter científico y tecnológico. Por tanto cabe resaltar el aporte del estudio realizado en esta investigación.

La propuesta de obtener la salida del FDPA para la detección puede realizar la localización de igual forma que la secuencia de detalles del primer nivel de descomposición (utilizada en numerosos trabajos de relacionados con la detección), requiriendo esta última opción mayor número de cálculos. Cabe resaltar que si se desea implementar algoritmos de detección en tiempo real (en procesadores digitales) es deseable que la longitud de la respuesta al impulso del FDPA asociado a la función *wavelet* sea lo menor posible para realizar el cálculo con mayor rapidez. Esta propuesta de utilizar la salida del FDPA, es un aporte a la detección de perturbaciones y los resultados de las simulaciones realizadas en este capítulo permiten confirmar el buen desempeño de la metodología propuesta.

Por otro lado se presenta una forma empírica para calcular el umbral que permite decidir si existe o no perturbación, esto con el fin de detectar el inicio de la perturbación a partir del valor máximo del cálculo de la magnitud de la salida obtenida al convolucionar la perturbación con la respuesta al impulso del FDPA asociado a la función *wavelet* Bior3.9. No obstante, el umbral debe ajustarse de acuerdo a las características del sistema eléctrico que se esté monitorizando.

Para finalizar, en la Figura 25 se presenta un ejemplo comparativo entre el cálculo del valor eficaz y la salida del FDPA utilizando la función *Wavelet* Bior3.9, para realizar la detección de 5 perturbaciones tipo (perturbaciones de la Figura 17). Es fácil apreciar en esta figura, que ambas técnicas permiten detectar el inicio de la perturbación pero el cálculo del valor eficaz presenta dificultades en la localización del final debido a las variaciones que presenta el patrón para perturbaciones con variaciones en el contenido frecuencial como es el caso del Transitorio, el *flicker* y el armónico. Utilizar la salida del FDPA para la detección puede realizar la localización de la ocurrencia de la perturbación independientemente si la variación de la señal ocurre sólo en magnitud o si por el contrario ocurre en la adición de componentes de frecuencia diferentes a la fundamental lo que permite mejor localización que utilizar el cálculo del valor RMS.

Figura 25 Comparación entre el cálculo del valor RMS y la salida del FDPA asociado a la función *Wavelet* Bior3.9 para realizar la detección de 5 perturbaciones tipo.



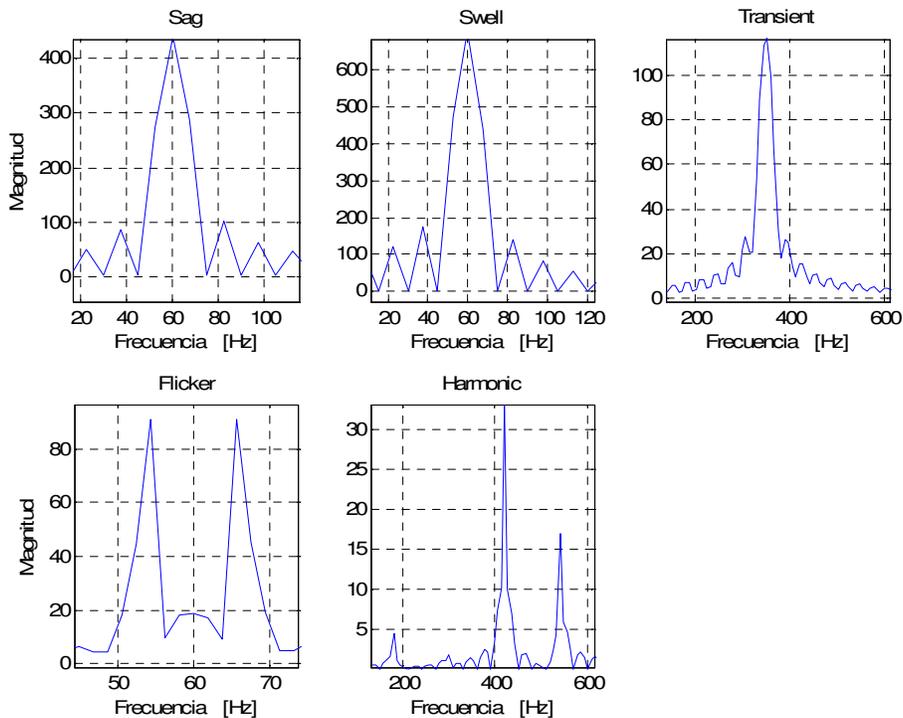
Fuente: Elaborada por el autor.

4. ESTRATEGIA DE IDENTIFICACIÓN: OBTENCIÓN DE DESCRIPTORES

En esta sección se presentan las 3 estrategias de identificación implementadas en este trabajo, utilizando descriptores obtenidos a partir de la transformada *Wavelet* discreta y el valor eficaz (valor RMS). La selección de la función *wavelet* más adecuada para la identificación de perturbaciones se hace a partir del análisis frecuencial (barrido en frecuencia) para las 4 familias de funciones *wavelet* elegidas.

¿Por qué utilizar TWD y valor RMS para identificar las perturbaciones de la calidad de la energía? A partir del cálculo de la magnitud de la transformada rápida de *Fourier* de la señal diferencia (se refiere a la diferencia entre la señal perturbada y la señal pre-evento) de cada una de las 5 perturbaciones de la Figura 17, es posible observar en la Figura 26 la similitud que tienen las magnitudes de la FFT de los eventos *sag* y *swell*. Lo anterior se debe a que el contenido frecuencial es muy parecido, sólo se diferencian en el valor de la magnitud de los coeficientes de *Fourier*.

Figura 26 Cálculo de la magnitud de la transformada rápida de *Fourier* para la señal diferencia de las 5 perturbaciones de la Figura 17



Fuente: Elaborada por el autor.

Otra situación se presenta en los eventos transitorio, *flicker* y armónico, donde cada espectro presenta diferencias muy notorias en el ancho de banda respectivo. Esto es, al presentarse cambios en las frecuencias de estas señales, en su espectro se ve reflejado directamente este cambio o variación de frecuencia. Esto permite proponer una estrategia de extracción de características que combine cambios o variaciones en la magnitud (como es el caso del valor RMS) con variaciones en el dominio de la frecuencia (como en el caso de la Transformada de *Fourier* o la Transformada *Wavelet*).

A continuación se presentan algunos trabajos que hacen parte del estado del arte en la identificación de patrones de eventos de la calidad de la energía eléctrica.

[Flores, 02] presenta que para la extracción de características puede ser utilizada la transformada *Wavelet* o los filtros *Kalman*. La *Wavelet* es muy utilizada principalmente porque permite cuantificar características para diferentes tipos de perturbaciones. Agrega también, que muchos investigadores no están totalmente de acuerdo con el uso de la *Wavelet*, porque las características obtenidas dependen considerablemente del tipo de *Wavelet* madre seleccionada.

En [Chen, 02] se utilizan 5 condiciones binarias como patrones, extraídos del dominio *Wavelet* y del dominio del tiempo, para la cuantificación y clasificación de los mismos. Se establecen reglas (condicionales) binarias, es decir, si cumple la condición se le asigna 1 y en caso contrario 0 y con ello establece criterios para la clasificación.

La estrategia desarrollada en [Gaouda, 99] consiste en tomar cada secuencia de coeficientes de detalle de cada nivel de descomposición y calcular su desviación estándar. Estos valores generan un patrón, tanto para una señal pura como para la señal con perturbación, a partir del cual se pueden diferenciar las dos señales. Esta diferenciación no es adecuada en algunas perturbaciones en particular, lo que provoca mayor grado de incertidumbre al clasificar los patrones posteriormente.

[Resende, 01] realiza un trabajo similar al de [Gaouda, 99], pero no utiliza la desviación estándar si no que calcula la energía de los coeficientes de cada nivel de detalle (la cual es equivalente a la energía de los detalles de la señal cuando se utiliza la *wavelet* madre *Daubechies*) tanto para la señal sinusoidal pura como para la señal con perturbaciones y luego se hace la diferencia nivel a nivel. Esta estrategia ha permitido obtener buenos resultados en la identificación de perturbaciones [Vega, 04], [Vega, Duarte & Ordóñez, 06].

Los principales problemas que se presentan al clasificar perturbaciones, son los relacionados con la obtención de descriptores adecuados que permitan una alta diferenciación entre cada uno de esos patrones. Lograr obtener descriptores

adecuados, garantiza una posterior clasificación con menos incertidumbre. A continuación se presenta un análisis en frecuencia que permite la selección de la *wavelet* más adecuada para la identificación y se describen las técnicas utilizadas para la identificación de perturbaciones (obtención de patrones).

4.1. ANÁLISIS EN FRECUENCIA DE LA TRANSFORMADA WAVELET DISCRETA

Para decidir qué función *Wavelet* es adecuada para la identificación de las perturbaciones, se hace necesario idear una técnica que permita seleccionar la función *wavelet* con mejor selectividad para el rango de frecuencias de cada nivel de descomposición *wavelet*.

Para realizar un análisis en frecuencia que permita determinar la función o funciones *wavelets* con buena selectividad, es decir, que separen la energía correspondiente a cada nivel de la mejor forma, es necesaria la siguiente metodología:

1. Determinar los rangos de frecuencia correspondientes a cada nivel de descomposición. Los rangos ideales y los rango necesarios para las simulaciones y pruebas.
2. Determinar la cantidad de señales necesarias para hacer un barrido en frecuencia y los niveles de descomposición adecuados para el análisis en frecuencia de las funciones *wavelet*.
3. Calcular la energía de los coeficientes de detalle de cada nivel de descomposición, para cada una de las señales senoidales de prueba. Después de calcular estas energías, se agrupan y se suman de acuerdo al rango perteneciente a cada nivel. Esto permite cuantificar la energía que es capaz de separar la función *wavelet* utilizada. Por medio de una relación de energías entre la correspondiente al rango deseado y la del rango no deseado, se tiene una estimación de la selectividad en frecuencia de la función para cada nivel de descomposición. Finalmente se promedian todos los niveles, para obtener un sólo valor para cada función.
4. El procedimiento del ítem anterior, se repite para cada una de las funciones *wavelet* seleccionadas para cada familia. El menor valor del promedio de las relaciones de energía de todos los niveles calculados, representa el mayor grado de selectividad en frecuencia de la función.
5. El siguiente criterio para seleccionar la función *wavelet* necesaria para calcular los patrones de perturbaciones de la calidad de la energía, son las muestras de la respuesta al impulso del filtro pasa-altos de descomposición asociado a la función *wavelet*. La menor cantidad de muestras posibles con buena selectividad, hace más rápido es el cálculo del patrón.

6. Finalmente se calculan 3 tipos diferentes de patrones a partir de la energía de los coeficientes de detalle *wavelet* y el cálculo del valor RMS utilizando las *wavelet* con mejor selectividad según los criterios expuestos.

En la Tabla 15 se presentan los rangos ideales de frecuencia para 8 niveles de detalle (niveles de descomposición *wavelet* asociados a filtros pasa-altas). Estos rangos están dados para una señal de 60 [Hz] muestreada a 128 [m/c], por consiguiente se tiene una frecuencia de muestreo de 7 680 [Hz]. También se encuentran los rangos utilizados para las simulaciones y prueba. Estos rangos son obtenidos de la división del ancho de banda en F_s/N donde N varía en potencia de dos.

Tabla 15 Intervalos ideales de frecuencia y de prueba para una frecuencia de muestreo de 7 680 Hz.

Nivel de Descomposición	Intervalo ideal de frecuencia en [Hz] para 128 [m/c]	Intervalo de frecuencia [Hz] Utilizado en la prueba
1	1 920 – 3 840	1 921 – 3 800
2	960 – 1 920	961 – 1 920
3	480 – 960	481 – 960
4	240 – 480	241 – 480
5	120 – 240	121 – 240
6	60 – 120	61 – 120
7	30 – 60	31 – 60
8	15 – 30	16 – 30

Fuente: Elaborada por el autor.

Se generan sintéticamente 800 señales senoidales de amplitud unitaria, 100 para cada rango de frecuencia desde 16 hasta 3 800 [Hz] igualmente espaciadas. A partir de las 800 señales seleccionadas, se procede a realizar el análisis en frecuencia para cada una de las funciones *wavelet* de la Tabla 16.

Tabla 16 Funciones *wavelets* utilizadas para el análisis en frecuencia.

	Biorortogonales (15)	Coiflets (5)	Daubechies (9)	Symlets (9)
Wavelets Seleccionadas	Bior1.1 a Bior3.9	Coif1 a coif5	Db2 a Db10	Sym2 a Sym10

Fuente: Elaborada por el autor.

El análisis en frecuencia consiste en calcular la energía de los coeficientes de detalle de cada uno de los 8 niveles de descomposición, utilizando cada una de

las 800 señales senoidales de prueba. De esta forma se obtiene una matriz con dimensión 8x800 para cada función *wavelet*; ésta puede ser graficada para observar el comportamiento de la energía de los coeficientes de detalle de cada nivel de descomposición en función de la frecuencia de cada señal senoidal (se llamará en adelante matriz energía-frecuencia MEF). En la Tabla 17 está la representación ideal de la matriz energía-frecuencia para los 8 intervalos de frecuencia y 8 niveles de descomposición. En color rojo está el intervalo de las frecuencias que idealmente pertenecen al nivel de descomposición seleccionado. En color blanco están los intervalos de frecuencia que no pertenecen a dicho nivel.

Tabla 17 Representación ideal de la matriz energía-frecuencia (dimensión 8x800) en función de los 8 intervalos de frecuencia y 8 niveles de descomposición.

Niveles	Interv 1	Interv 2	Interv 3	Interv 4	Interv 5	Interv 6	Interv 7	Interv 8
1								
2								
3								
4								
5								
6								
7								
8								

Fuente: Elaborada por el autor.

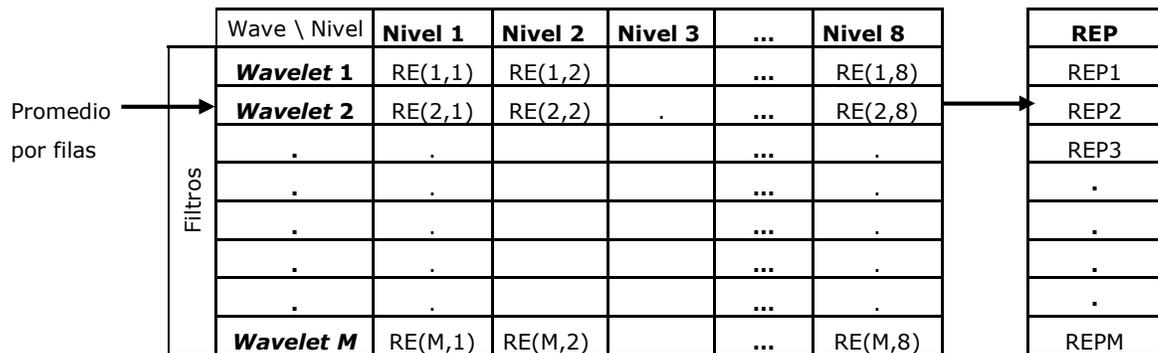
Después de calculada la matriz energía-frecuencia, suman todas las energías pertenecientes a cada uno de los 8 intervalos en cada nivel de descomposición, con lo cual se tiene una matriz de 8x8. A partir de esta matriz se calcula para cada nivel de descomposición, la relación (relación de energía RE) entre la energía del intervalo ideal de frecuencia perteneciente al nivel de descomposición respectivo (En_{Nivel}) y la suma de la energía de los intervalos restantes (En_{Cero}), donde idealmente la energía debe ser cero, por medio de la expresión $RE = En_{Cero}/En_{Nivel}$. De esta operación se tiene un vector de 8 posiciones para cada función *wavelet*. Por ejemplo para el nivel de descomposición 1, se calcula la suma de las energías del intervalo 8 (100 energías pertenecientes a las frecuencias entre 1 921 y 3 800 Hz) y las energías de los restantes intervalos del 1 al 7.

La relación RE que idealmente debe ser cero, representa una estimación de la selectividad en frecuencia del filtro pasa-altas asociado a la función *wavelet*, para cada nivel de descomposición. Debido a que es necesario tener una función *wavelet* con buena selectividad en frecuencia para todos los niveles, es necesario promediar el valor de RE de todos los niveles para obtener un sólo valor para cada función *wavelet*. La relación de energías promedio (REP) sigue siendo un indicador de la selectividad en frecuencia de la función *wavelet*,

entre más cercano a cero sea el valor REP, mayor será la selectividad en frecuencia de dicha función.

En la Figura 27 se hace una representación de una matriz de relación de energías acompañada (MRE) a la derecha del vector de relaciones de energías promedio (VREP) para M funciones *wavelet*.

Figura 27 Representación de la matriz de Relación de Energías y del vector de de relaciones de energía promedio para M funciones *wavelet*.



Fuente: Elaborada por el autor.

Dependiendo de la familia de funciones *wavelet*, se presenta una tabla con la MRE acompañada del respectivo VREP, con el cual se ordenan las la funciones *wavelets* de menor a mayor valor de REP. Seguida a esta tabla se muestran las gráficas de las matrices energía-frecuencia para la función *wavelet* con menor y mayor selectividad respectivamente según el criterio de selección señalado anteriormente. Cabe anotar que como ejercicio se analiza hasta el nivel 8 de descomposición, pero para el análisis en particular del problema de las perturbaciones de energía eléctrica, es suficiente hasta el nivel 7 debido a que en el nivel 8 la información no tiene relevancia en esta investigación (información por debajo de los 30 Hz). Por lo tanto, para calcular el promedio de la Relación de energía sólo se tiene en cuenta hasta el nivel 7.

4.1.1. Familia *wavelet* Bior

Para esta familia se analizaron 15 funciones *wavelet* (Ver Tabla 16). En la Tabla 18 se encuentran los resultados del análisis en frecuencia. Se presenta la matriz de Relación de Energías, el vector de relaciones de energía promedio y la duración de la respuesta al impulso (Duración efectiva - D.E.) de cada filtro de descomposición pasa-altas para la familia de *wavelets* Biortogonal.

Tabla 18 Matriz de Relación de Energías, vector de relaciones de energía promedio y Duración efectiva de la respuesta al impulso para la familia de *wavelets* Biortogonal.

Bior	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	VREP	D.E.
6.8	0,114	0,2443	0,2699	0,3456	0,2575	0,3184	0,3909	0,2772	11
3.7	0,0686	0,2483	0,342	0,3941	0,3217	0,3665	0,4175	0,3084	4
3.9	0,0686	0,2149	0,2815	0,4987	0,3509	0,3554	0,4512	0,3173	4
5.5	0,1231	0,3301	0,365	0,333	0,3516	0,3745	0,3863	0,3234	11
2.8	0,1726	0,2765	0,3043	0,4201	0,2973	0,3759	0,4717	0,3312	3
2.6	0,1726	0,3107	0,3356	0,3251	0,3718	0,4247	0,4408	0,3402	3
4.4	0,1336	0,3303	0,3577	0,3425	0,3783	0,436	0,4305	0,3441	7
2.4	0,1726	0,3601	0,3878	0,3816	0,4403	0,5164	0,5297	0,3984	3
3.5	0,0686	0,2942	0,3889	0,4525	0,4115	0,4649	0,7087	0,3985	4
2.2	0,1728	0,4558	0,5079	0,5763	0,6082	0,6229	0,6593	0,5147	3
3.3	0,0687	0,3779	0,5284	0,6154	0,6526	0,8359	0,8068	0,5551	4
1.5	0,5378	0,7676	0,7043	0,6703	0,669	0,6738	0,526	0,6498	2
1.3	0,5375	0,8276	0,7856	0,7821	0,7597	0,7288	0,6027	0,7177	2
1.1	0,5364	1,025	1,0868	1,0791	1,0607	1,0038	0,8199	0,9445	2
3.1	0,0688	0,5378	1,0192	1,7424	2,6833	4,1405	7,4001	2,5132	4

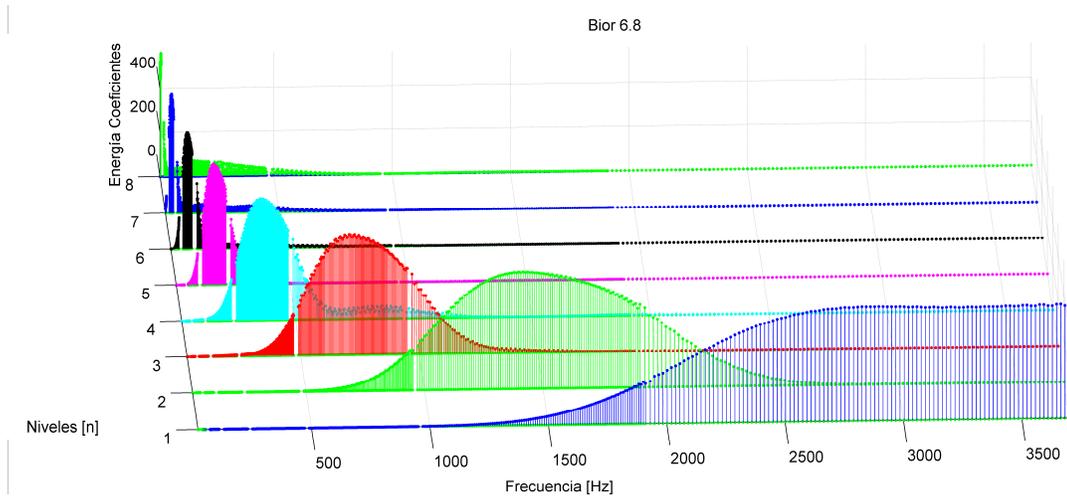
Fuente: Elaborada por el autor.

En la Tabla 18 se resalta en color rojo y negrilla la función *wavelet* con la menor REP (Bior6.8), es decir, aquella con mejor selectividad. En color gris se muestra la función *wavelet* con la mayor REP (Bior3.1). En la Figura 28 y Figura 29 se presentan las gráficas de la MEF para cada una de estas dos funciones, respectivamente.

En la Figura 28 es posible observar que en cada nivel de descomposición, las energías correspondientes al intervalo de frecuencia ideal se diferencian con facilidad (bior 6.8). Caso contrario ocurre en la Figura 29 donde las energías correspondientes a diferentes intervalos de frecuencias se encuentran esparcidas en todo el nivel de descomposición.

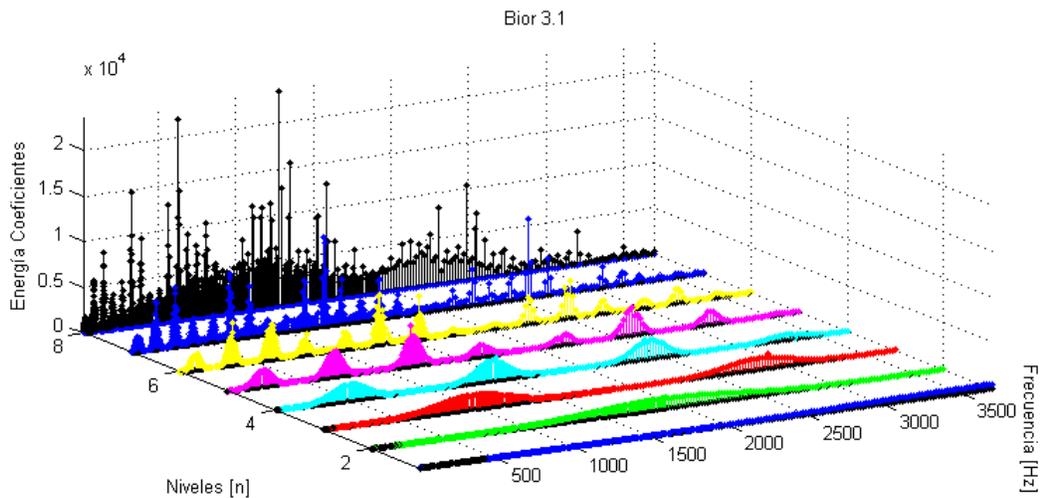
De la Tabla 18, las dos funciones *wavelet* con mejor selectividad en frecuencia son la Bior6.8 y la Bior3.7, esta última con respuesta al impulso de menor duración (4 muestras y la otra con 11).

Figura 28 Matriz Energía-frecuencia para la función *wavelet* bior6.8.



Fuente: Elaborada por el autor.

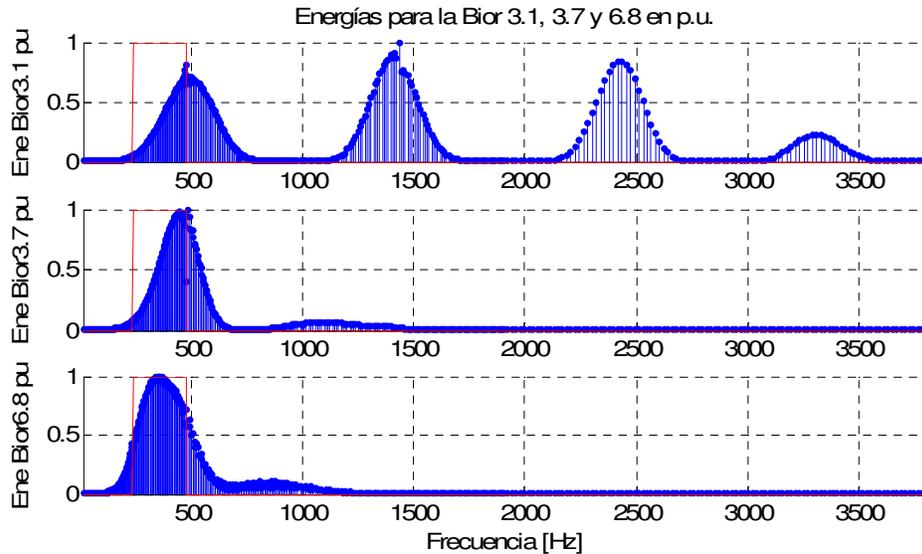
Figura 29 Matriz Energía-frecuencia para la función *wavelet* bior3.1.



Fuente: Elaborada por el autor.

En la Figura 30 se hace una comparación entre las funciones *wavelet* Bior3.1, Bior3.7 y Bior6.8 a partir del análisis en frecuencia para el nivel de descomposición 4 (Se pudo haber utilizado otro nivel de descomposición, pero se seleccionó éste por estar en mitad). La línea continua (rojo) muestra el filtro ideal para el nivel de descomposición 4. Las energías se encuentran normalizadas respecto al valor máximo para cada función.

Figura 30 Comparación entre las energías en por unidad del valor máximo para las funciones *wavelet* Bior 3.1, 3.7 y 6.8 para el análisis en frecuencia del nivel 4.



Fuente: Elaborada por el autor.

Es posible observar en la Figura 30 que la función *wavelet* Bior 6.8 tiene mayor selectividad en frecuencia respecto a la Bior 3.1 debido a que esta última tiene componentes de energía de gran amplitud en intervalos de frecuencia no deseados (para el nivel 4 se ha considerado el intervalo ideal de frecuencias entre 250 y 470 Hz). Por otro lado la función *wavelet* Bior 3.7 atenúa bien los rangos de frecuencia que están en la banda de rechazo, no obstante la función *wavelet* Bior 6.8 se ajusta mejor al rango ideal de frecuencias que se ha considerado.

4.1.2. Familia de funciones *wavelet* Coif

En la Tabla 19 se presenta el resultado del análisis en frecuencia para las 5 funciones *wavelets* pertenecientes a esta familia.

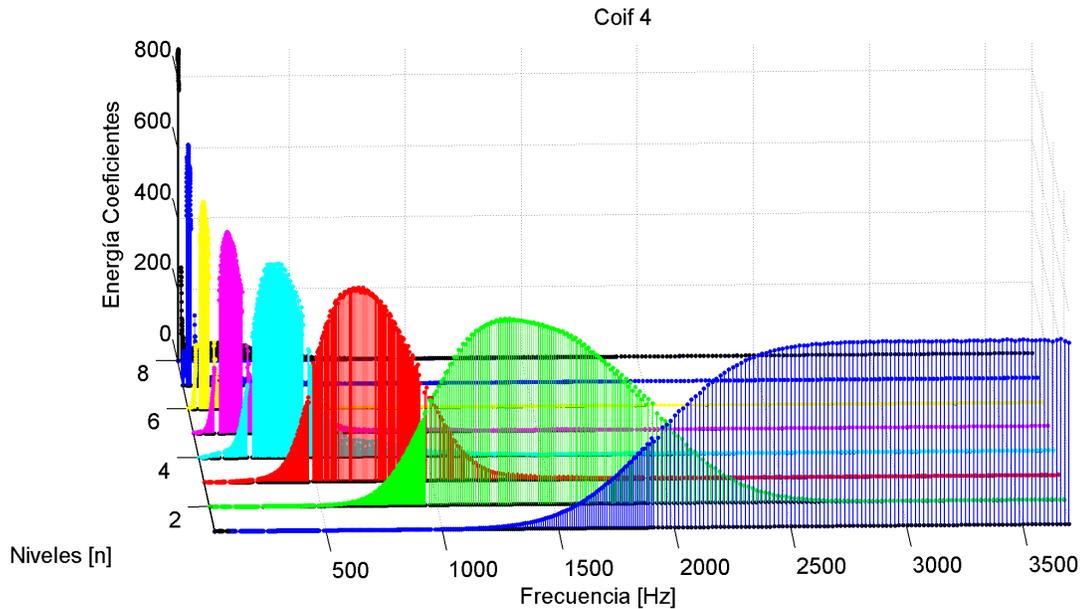
Tabla 19 Matriz de Relación de Energías, vector de relaciones de energía promedio y Duración efectiva de la respuesta al impulso para la familia de *wavelets* Coiflet.

Coif	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	REP	D.E.
4	0,133	0,2419	0,2634	0,3376	0,3269	0,2851	0,3153	0,2719	24
5	0,118	0,2119	0,2405	0,3414	0,5019	0,2682	0,2697	0,2788	30
3	0,1559	0,2868	0,3181	0,3659	0,2948	0,3657	0,4068	0,3134	18
2	0,1965	0,371	0,3785	0,3835	0,4034	0,4536	0,4514	0,3768	12
1	0,3063	0,5891	0,6017	0,6329	0,6393	0,6492	0,6649	0,5833	6

Fuente: Elaborada por el autor.

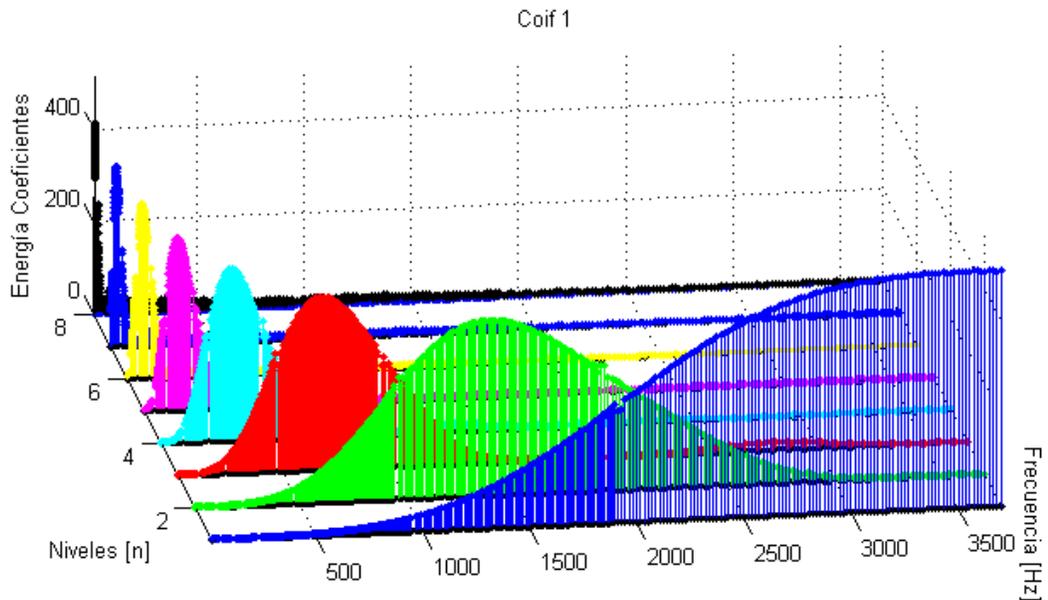
De la Tabla 19 se tiene que la función *wavelet* con mejor selectividad de frecuencia es Coif 4, la cual tiene asociados filtros con respuesta al impulso de 24 muestras. En la Figura 31 y Figura 32 se presentan las gráficas de la MEF para cada una de estas dos funciones, respectivamente.

Figura 31 Matriz Energía-frecuencia para la función *wavelet* Coif 4.



Fuente: Elaborada por el autor.

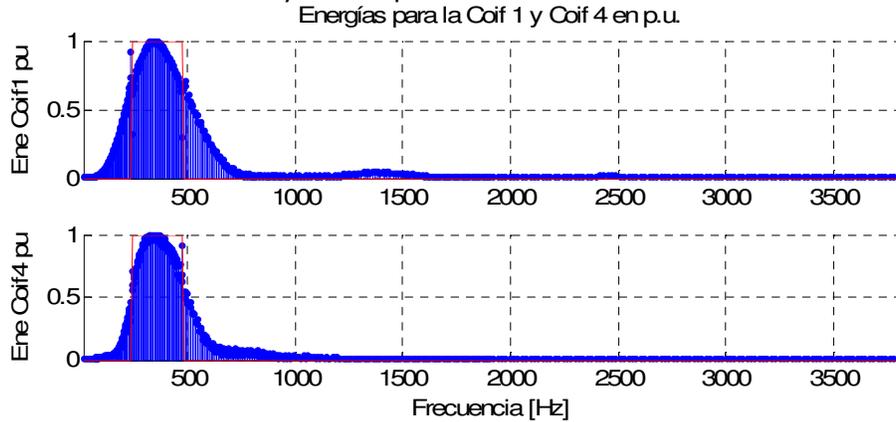
Figura 32 Matriz Energía-frecuencia para la función *wavelet* Coif 1.



Fuente: Elaborada por el autor.

En la Figura 33 se hace una comparación entre las funciones *wavelet* Coif1 y Coif4 a partir del análisis en frecuencia para el nivel de descomposición 4.

Figura 33 Comparación entre las energías en por unidad del valor máximo para las funciones *wavelet* Coif 4 y Coif 1 para el análisis en frecuencia del nivel 4.



Fuente: Elaborada por el autor.

De la Figura 33 se tiene que la función *wavelet* Coif4 tiene mayor selectividad en frecuencia ya que concentra mejor la energía en el intervalo ideal de frecuencia y atenúa mejor en la banda de rechazo que la función *wavelet* Coif1.

4.1.3. Familia de funciones *wavelet* Db

En la Tabla 20 se presenta el resultado del análisis en frecuencia para las 9 primeras *wavelets* pertenecientes a esta familia considerando una longitud máxima de respuesta al impulso de 20 muestras, para los filtros asociados a estas funciones.

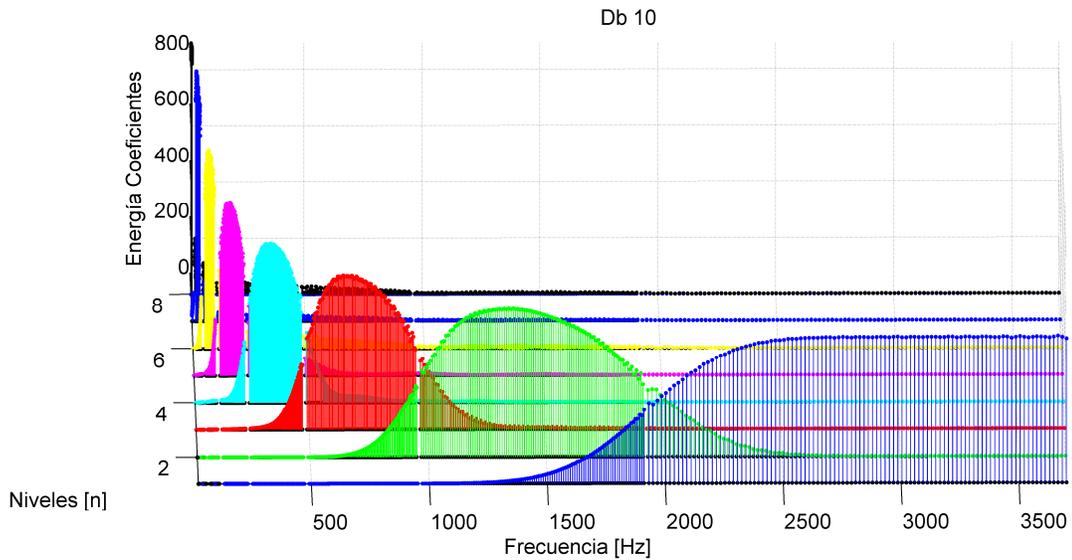
Tabla 20 Matriz de Relación de Energías, vector de relaciones de energía promedio y Duración efectiva de la respuesta al impulso para la familia de *wavelets* Daubechies (Db2 a Db10).

Db	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	REP	D.E.
10	0,1225	0,2125	0,2261	0,2565	0,3295	0,3238	0,2087	0,2399	20
8	0,1449	0,2594	0,2702	0,3099	0,2695	0,2682	0,3216	0,2634	16
9	0,1344	0,2277	0,2465	0,3142	0,2811	0,3687	0,2107	0,2548	18
7	0,1534	0,2735	0,2763	0,3531	0,2853	0,3033	0,3208	0,2808	14
6	0,1612	0,2856	0,2901	0,329	0,3376	0,2823	0,3113	0,2853	12
5	0,1735	0,3304	0,3551	0,3489	0,3308	0,3106	0,3704	0,3171	10
4	0,1965	0,3771	0,3745	0,3672	0,3949	0,457	0,5323	0,3856	8
3	0,238	0,4435	0,4589	0,472	0,4966	0,5145	0,5359	0,4513	6
2	0,3161	0,6095	0,6079	0,5876	0,5726	0,553	0,4944	0,5344	4

Fuente: Elaborada por el autor.

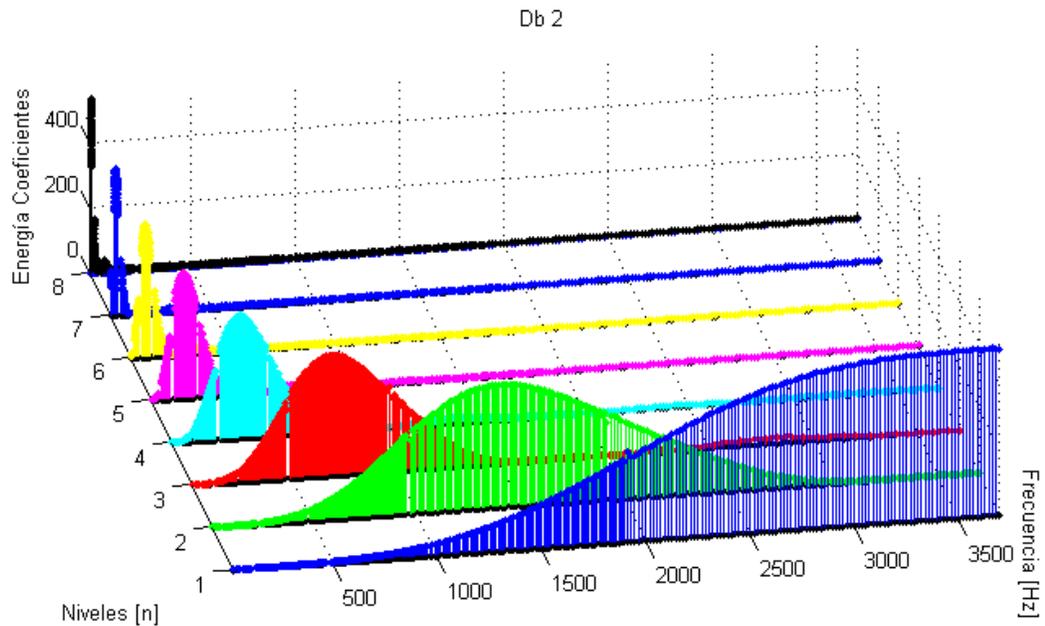
De la Tabla 20 se tiene que la función Db 10 tiene mejor selectividad en frecuencia, esto es de esperarse pues la tendencia de los filtros asociados a esta familia es la de mejorar su selectividad a medida que aumenta el orden de la función. En la Figura 34 y Figura 35 se presenta el análisis en frecuencia para la función Db10 y Db2, respectivamente.

Figura 34 Matriz Energía-frecuencia para la función *wavelet* Db 10.



Fuente: Elaborada por el autor.

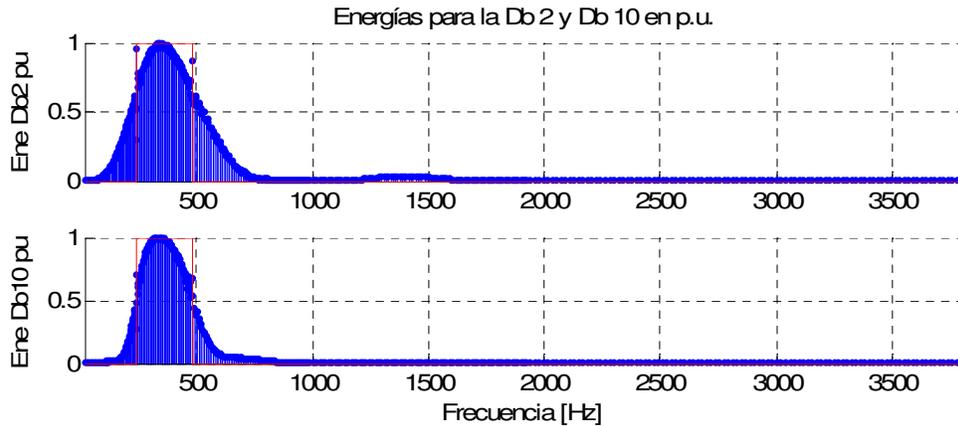
Figura 35 Matriz Energía-frecuencia para la función *wavelet* Db 2.



Fuente: Elaborada por el autor.

En la Figura 36 se hace una comparación entre las funciones *wavelet* Db2 y Db10 a partir del análisis en frecuencia para el nivel de descomposición 4.

Figura 36 Comparación entre las energías en por unidad del valor máximo para las funciones *wavelet* Db2 y Db10 para el análisis en frecuencia del nivel 4.



Fuente: Elaborada por el autor.

4.1.4. Familia de filtros *wavelet* Sym

En la Tabla 21 se presenta el análisis en frecuencia para las 9 primeras funciones de esta familia.

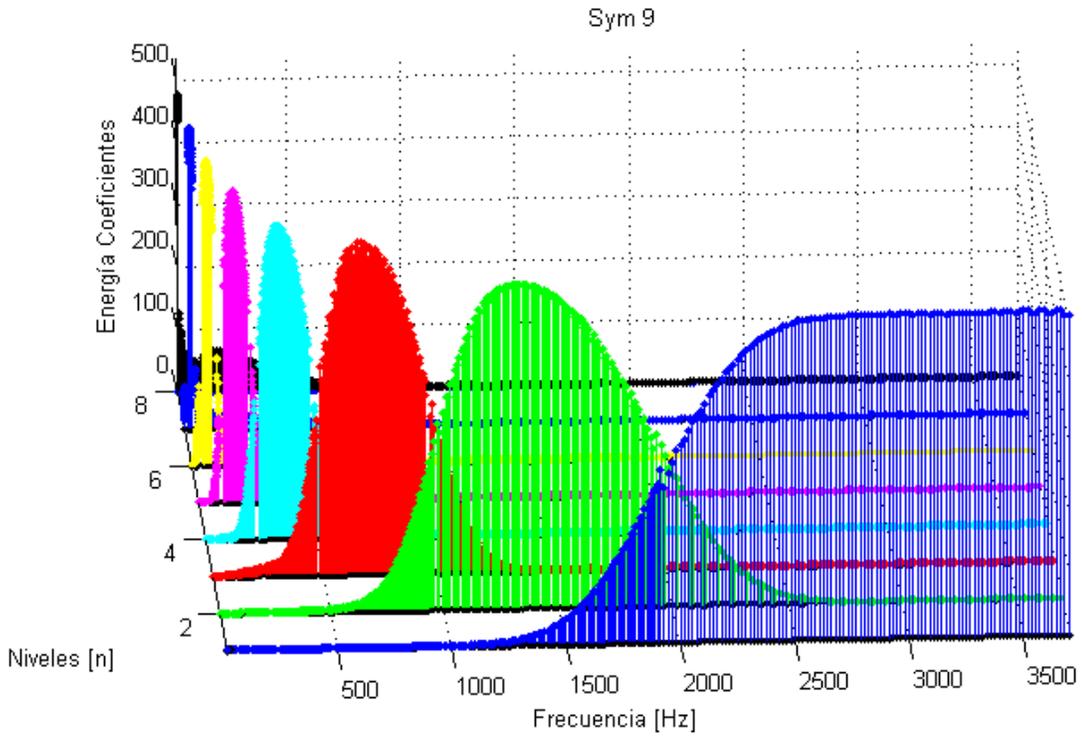
Tabla 21 Matriz de Relación de Energías, vector de relaciones de energía promedio y Duración efectiva de la respuesta al impulso para la familia de *wavelets* Symlet (Sym2 a Sym10).

Sym	Nivel 1	Nivel 2	Nivel 3	Nivel 4	Nivel 5	Nivel 6	Nivel 7	REP	D.E.
9	0,137	0,2505	0,2757	0,2459	0,2307	0,2391	0,2714	0,2358	18
10	0,1263	0,2265	0,2463	0,3333	0,256	0,3097	0,3663	0,2663	20
8	0,1416	0,2515	0,2759	0,306	0,3025	0,311	0,3639	0,2789	16
7	0,1466	0,2616	0,2979	0,2737	0,2804	0,3197	0,3883	0,2812	14
5	0,1855	0,3487	0,3319	0,318	0,3061	0,3297	0,2979	0,3025	10
6	0,1648	0,3047	0,3171	0,3095	0,3454	0,3813	0,4353	0,3226	12
4	0,2059	0,379	0,3859	0,4058	0,4244	0,4616	0,5323	0,3993	8
3	0,238	0,4435	0,4589	0,472	0,4966	0,5145	0,5359	0,4513	6
2	0,3161	0,6095	0,6079	0,5876	0,5726	0,553	0,4944	0,5344	4

Fuente: Elaborada por el autor.

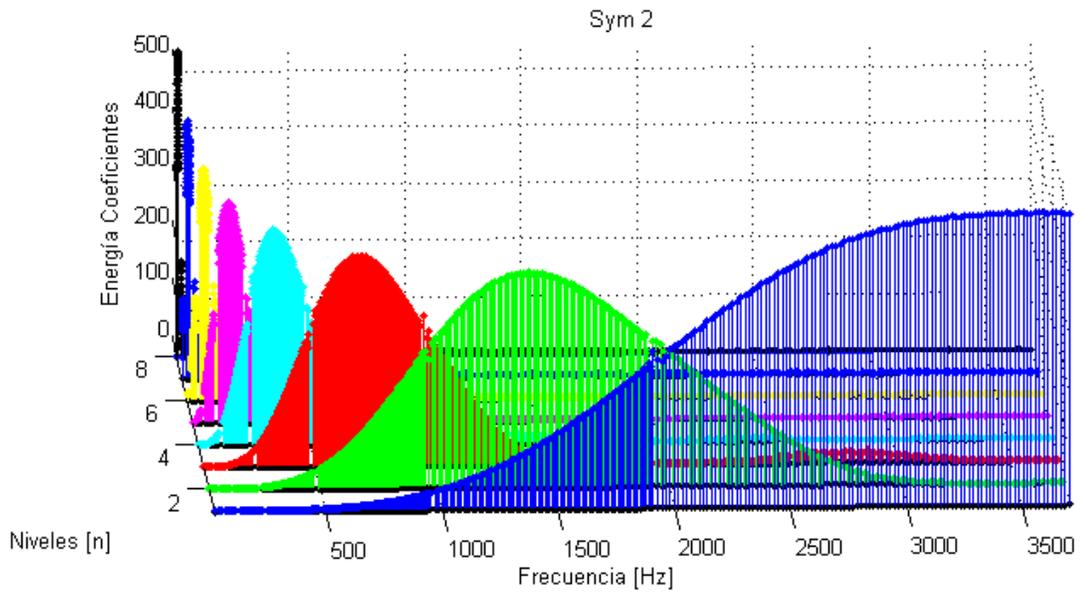
En la Figura 37 se presenta el análisis en frecuencia (MEF) de la función Sym9 para cada nivel de descomposición y en la Figura 38 el respectivo análisis en frecuencia para la función Sym 2.

Figura 37 Matriz Energía-frecuencia para la función *wavelet* Sym 9.



Fuente: Elaborada por el autor.

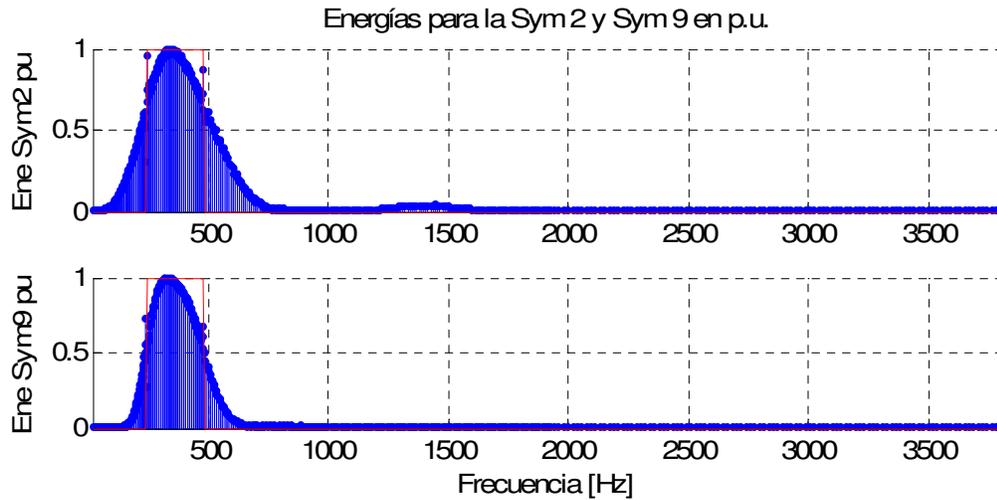
Figura 38 Matriz Energía-frecuencia para la función *wavelet* Sym 2.



Fuente: Elaborada por el autor.

En la Figura 39 se hace una comparación entre las funciones *wavelet* Sym2 y Sym9 a partir del análisis en frecuencia para el nivel de descomposición 4.

Figura 39 Comparación entre las energías en por unidad del valor máximo para las funciones *wavelet* Sym2 y Sym9 para el análisis en frecuencia del nivel 4.



Fuente: Elaborada por el autor.

En la Figura 39 se observa que la función Sym9 tiene mejor selectividad en frecuencia que la función Sym2, porque la energía se concentra mucho más en el rango de frecuencia ideal y no tiende a esparcirse en otras frecuencias.

Para seleccionar la función *wavelet* adecuada se considerará también la cantidad de muestras de la respuesta al impulso de los filtros de descomposición. La *wavelet* seleccionada se espera que tenga el menor promedio de relación de energía y menor número posible de coeficientes.

En Tabla 22 se presentan las funciones *wavelet* con mejor selectividad en frecuencia (dada por la REP de menor a mayor) y agrupadas según el número de coeficientes de la respuesta al impulso del filtro pasa-altas asociado a cada la función. En rojo se representa la función *wavelet* con mejor selectividad para cada grupo.

Tabla 22 Funciones *wavelet* con mejor selectividad en frecuencia, agrupadas según el número de coeficientes de la respuesta al impulso del filtro asociado a la función.

Wavelet	Bior3.7	Coif1	Db3	Sym3	Bior6.8	Coif2	Db6	Sym6	Sym9	Db9	Coif3
REP	0,308	0,583	0,451	0,451	0,277	0,377	0,285	0,323	0,236	0,255	0,313
D.E.	4	6	6	6	11	12	12	12	18	18	18

Fuente: Elaborada por el autor.

A continuación se plantean las estrategias de identificación a partir del valor eficaz y la transformada *wavelet* (el análisis de las gráficas de hará para la función *wavelet* Bior3.7, debido a la gran cantidad de gráficas resultantes si se toman también las funciones Bior6.8 y Sym9), para determinar los patrones que permitan caracterizar las perturbaciones de la calidad de la energía.

4.2. TRANSFORMADA WAVELET DISCRETA Y VALOR RMS PARA IDENTIFICAR PERTURBACIONES

A partir de los trabajos desarrollados en [Gaouda, 99],[Gaouda, 02][Gaouda, 02] [Resende, 01], [Vega, 04], la transformada *Wavelet* ha brindado una buena alternativa en la identificación de perturbaciones. Los resultados obtenidos en estos trabajos son buenos pero se contempla la posibilidad de mejorarlos. Es así como se analizaron otras alternativas que combinan el cálculo de valor eficaz y la transformada *Wavelet*.

En esta estrategia de identificación, se obtuvieron 3 grupos o tipos de patrones. El primero utiliza en esencia la propuesta presentada por [Resende, 01] que consiste en el cálculo de la diferencia de las energías de los coeficientes de detalle de 7 niveles de descomposición *Wavelet* de la señal de pre-evento y la señal perturbada. La segunda propuesta calcula la energía de los coeficientes de detalle de 6 niveles de descomposición sólo de la señal perturbada y adicional a esto se considera el valor máximo y mínimo del cálculo del valor eficaz de la perturbación analizada. Por último, la opción tres calcula la energía de los coeficientes de detalle de la señal diferencia, es decir, de la diferencia entre la señal pre-evento y la señal perturbada, y considera al igual que en la anterior propuesta, el valor máximo y mínimo del cálculo del valor RMS de la señal perturbada.

Cada uno de los grupos de patrones se detalla a continuación, no sin antes presentar otros tipos de patrones que hicieron parte de la investigación y que ayudaron a determinar los 3 que finalmente se estudiaron.

El trabajo previo para la obtención de patrones a partir de las perturbaciones, se basó esencialmente en la utilización de transformadas, valor RMS y parámetros estadísticos. Inicialmente se utilizó el valor eficaz y los parámetros estadísticos como la varianza, media y desviación estándar para las siguientes señales de prueba:

- ✓ Señal perturbada (*sp*)
- ✓ Señal pre-evento (*sb*)
- ✓ Señal diferencia ($sd = sp - sb$).
- ✓ Señal *sfd*, resultado de calcular la magnitud de la FFT de *sd*.
- ✓ Señal *sdift*, resultado de calcular la diferencia entre la magnitud de la FFT de *sb* y la magnitud de la FFT de *sp*.

El cálculo de la FFT de sd y sp se realiza sobre una ventana deslizante de duración equivalente a un ciclo de la componente fundamental. Esta ventana de desplaza muestra a muestra.

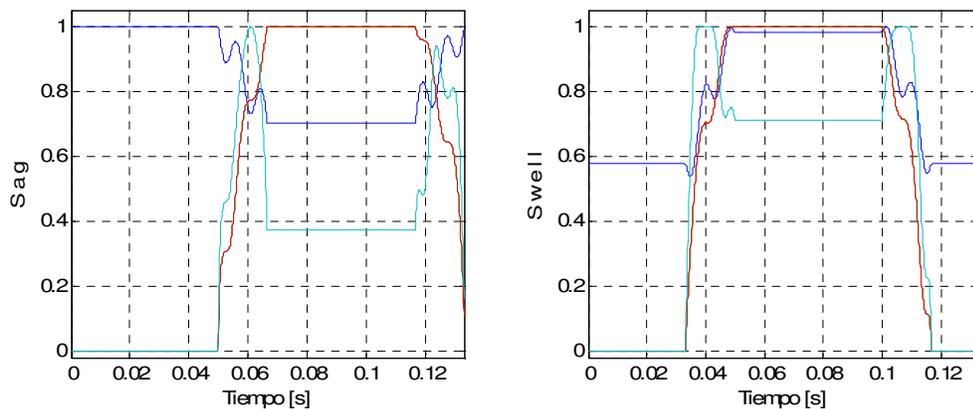
En la Figura 40 se presenta el resultado de aplicar el cálculo del valor eficaz sobre las señales de prueba sp , sd , sfd y $sdift$ correspondiente a las perturbaciones: hueco de tensión $-sag-$ y elevación de tensión $-swell-$. No se grafica el cálculo del valor RMS sobre la señal sb ni sfd porque la primera es un valor constante y la segunda es proporcional al valor eficaz de sd por la relación de *Parseval*. Las gráficas se encuentran normalizadas con respecto al valor máximo para tener una mejor apreciación de las mismas. En la Figura 41, se presenta el resultado obtenido para las tres perturbaciones restantes: transitorio, fluctuación de tensión $-flicker-$ y armónico. Es decir, que por cada perturbación se presentan 3 gráficas. Cada color corresponde al cálculo de valor RMS de una señal de prueba en particular. En la Tabla 23, se encuentra especificado el color correspondiente para cada señal de prueba.

Tabla 23 Simbología y colores utilizados en la Figura 4.15.

Símbolo	Significado	Color
sp	Señal con perturbación	Azul
sd	Señal diferencia entre sb y sp	Rojo
$sdift$	Diferencia de la magnitud de la FFT de sb y sp	Cyan

Fuente: Elaborada por el autor.

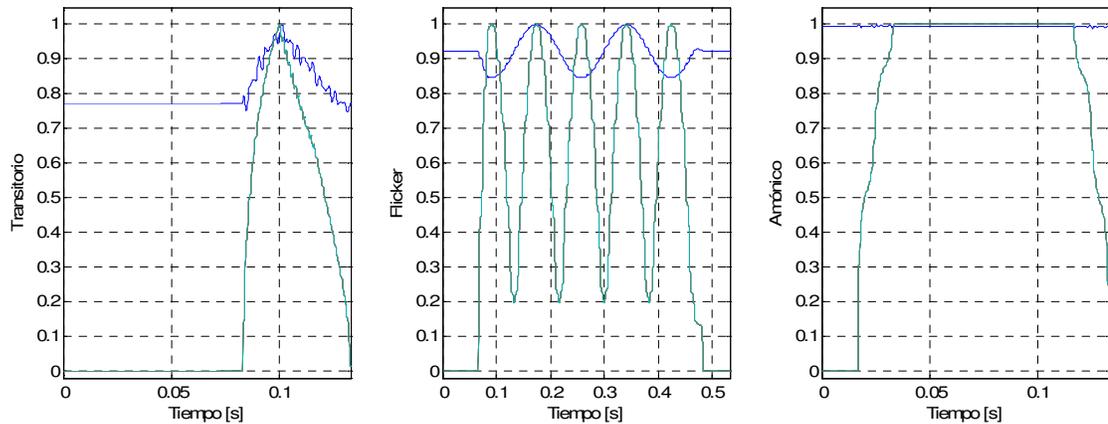
Figura 40 Valor eficaz muestra a muestra normalizado con respecto a su valor máximo para las señales de prueba sp , sd y $sdift$ para las perturbaciones sag y $swell$ de la Figura 17.



Fuente: Elaborada por el autor.

De la Figura 40 se observa que es posible diferenciar claramente los fenómenos *sag* y *swell* a partir del cálculo del valor RMS muestra a muestra de la señal perturbada (línea azul).

Figura 41 Valor eficaz muestra a muestra normalizado con respecto a su valor máximo para las señales de prueba *sp*, *sd* y *sdift* para las perturbaciones Transitorio, *Flicker* y armónico de la Figura 17.



Fuente: Elaborada por el autor.

Para los eventos transitorios, *flicker* y armónico de la Figura 41, el cálculo de valor eficaz presenta muchas variaciones, es decir, para el transitorio por ejemplo crece y decrece su valor durante la duración del evento, en el caso del *flicker*, se observan oscilaciones senoidales y en el armónico, se presenta muy poca variación de la magnitud en el cálculo de valor eficaz de la señal perturbada, esto se puede apreciar más claramente en la Figura 25 del capítulo anterior cuando se realiza una comparación entre el cálculo del valor RMS y la descomposición *wavelet* para la detección de perturbaciones. Las gráficas RMS de las señales *sd* y *sdift* presentan un comportamiento muy similar, mas no igual, superponiéndose *sdift* sobre *sd*.

Adicional a las anteriores estrategias (valor RMS y transformada de *Fourier*), también se calcularon los valores de la media, desviación estándar y el valor absoluto para cada grupo de señales de prueba. El resultado fue muy similar al observado en el cálculo de valor RMS, por tanto sólo se presenta el cálculo del valor RMS y el de la transformada de Fourier.

En este análisis de patrones hay que tener en cuenta que para la posterior clasificación de los mismos, es necesario establecer un número máximo de descriptores para realizar el proceso de clasificación. Para el cálculo del valor RMS o FFT, el vector patrón tendría un tamaño igual a la mitad del número de muestras de la señal analizada. Esto puede provocar efectos indeseados en el método de clasificación como: tiempo de entrenamiento prolongado y

sobredimensionamiento (en el caso de las redes neuronales) al momento de entrenar. Por ejemplo, si se toma un ciclo de señal muestreada a 128 [m/c] de 60 [Hz], se tendrán 128 (para RMS muestra a muestra) ó 64 (para la FFT) datos para analizar, lo cual hace tediosa la implementación en cualquier sistema de clasificación.

Debido a lo anterior, es necesaria una estrategia que permita extraer características de la perturbación en lo posible con un conjunto de datos muy inferior al de la señal original. Esto con el fin de hacer más rápida su posterior clasificación. Se proponen a continuación las siguientes 3 alternativas que combinan el cálculo de la transformada *Wavelet* con el cálculo del valor eficaz.

Para entender el principio de funcionamiento de cada una de las tres alternativas de identificación, se presenta en la Figura 42 el diagrama de bloques del esquema de identificación para obtener 3 tipos de patrones. Por ejemplo, para la obtención del Patrón 1, es necesario primero extraer la señal pre-evento (*sb*) a partir de la señal perturbada (*sp*) (señal de entrada del sistema), luego se calculan los coeficientes de detalle de transformada *Wavelet* para 7 niveles de descomposición. A estos coeficientes se les calcula la energía tanto para la señal *sb* como para la señal *sp* para cada nivel de descomposición. Seguido se calcula la diferencia entre estos dos vectores de energía y se obtiene el Patrón 1.

El patrón 2 se forma a partir de la energía de los coeficientes de detalle de la transformada *Wavelet* para 6 niveles de descomposición para la señal perturbada (*sp*) y se adicionan dos términos que son:

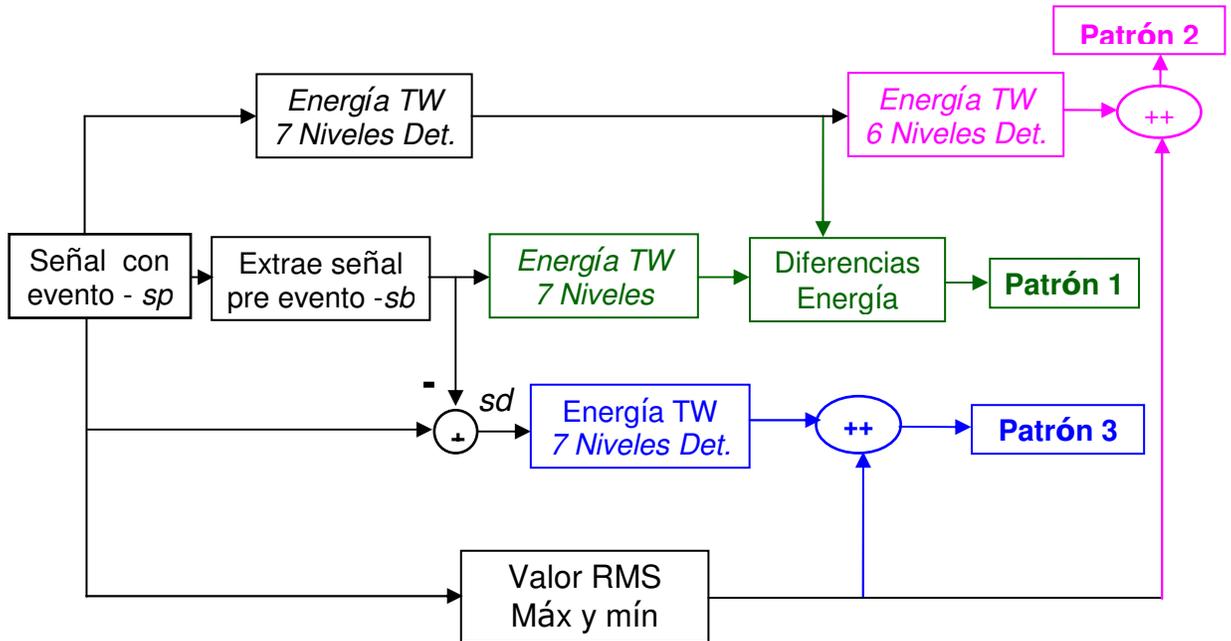
1. La diferencia entre el valor RMS máximo obtenido de la perturbación y el valor RMS promedio del pre-evento (RMS máx).
2. La diferencia entre el valor RMS mínimo obtenido de la perturbación y el valor RMS promedio del pre-evento (RMS mín).

Estos dos términos son multiplicados por el valor máximo del vector de energías resultante de los 6 niveles de descomposición. La anterior ponderación se basa en la observación de los valores obtenidos en el vector de energías de detalle resultante y los obtenidos a partir de valor RMS. Debido a que el vector de energías obtenido para cada perturbación varía significativamente en magnitud, es necesario que los valores RMS máx y RMS mín, no presenten magnitudes demasiado grandes que opaquen al vector de energías de detalle ni tampoco magnitudes tan pequeñas que los hagan insignificantes ante el vector de energías de detalle.

En el cálculo del Patrón 3 se requiere por su parte hacer la diferencia entre la señal *sp* y la señal *sb*, a esa señal diferencia *sd* calcularle la energía de los coeficientes de detalle de 7 niveles de descomposición y luego adherir los términos RMS máx y RMS mín al vector anterior.

En la Figura 42, el símbolo \oplus significa suma vectorial y $\oplus\oplus$ significa que se añaden datos a otro vector, es decir, que ocurre la concatenación entre dos vectores para formar un nuevo vector de mayor tamaño.

Figura 42 Diagrama de bloques del esquema de identificación para obtener 3 tipos de patrones.



Fuente: Elaborada por el autor.

4.2.1. Diferencias de energía de coeficientes *Wavelet* - Patrón 1

En esta primera propuesta se utiliza el concepto de las diferencias de energía por nivel, de los coeficientes de descomposición *Wavelet* (coeficientes de detalles) para 7 niveles de descomposición, obtenidos tanto para la perturbación como para la señal pre-evento. Esta técnica de identificación es planteada por [Resende, 01] y es utilizada también en [Vega, 04] obteniéndose buenos resultados utilizando para la transformación la función *wavelet* Db4 y se tomaron 8 niveles de descomposición.

De la Tabla 15 se tiene que en el nivel de descomposición 8 la componente de frecuencia ideal de la señal que se desee analizar está en el rango de 15 a 30 [Hz]. El contenido de la información característico de los eventos de la calidad de la energía eléctrica para este rango de frecuencias no es significativo; por tal razón, en este trabajo se considera sólo hasta el nivel 7 y no se sigue descomponiendo la señal en más niveles de menor resolución. Además, sólo se puede llegar hasta el nivel 8 para cierta cantidad de muestras porque la operación de diezmado por 2 retira siempre la mitad de las muestras cada vez

que realiza una descomposición, es decir, si se tienen 1024 muestras de una señal, en el nivel 8 quedarían sólo 4 muestras finales.

[Resende, 01] propone la ecuación (8):

$$dp(j)(\%) = \left[\frac{En_per(j) - En_ref(j)}{En_ref(m)} \right] * 100 \quad (8)$$

Donde:

$dp(j)(\%)$: es la desviación de la energía de la perturbación respecto a la señal pre-evento en cada nivel j .

$En_per(j)$: es la energía de la señal perturbada en cada nivel j .

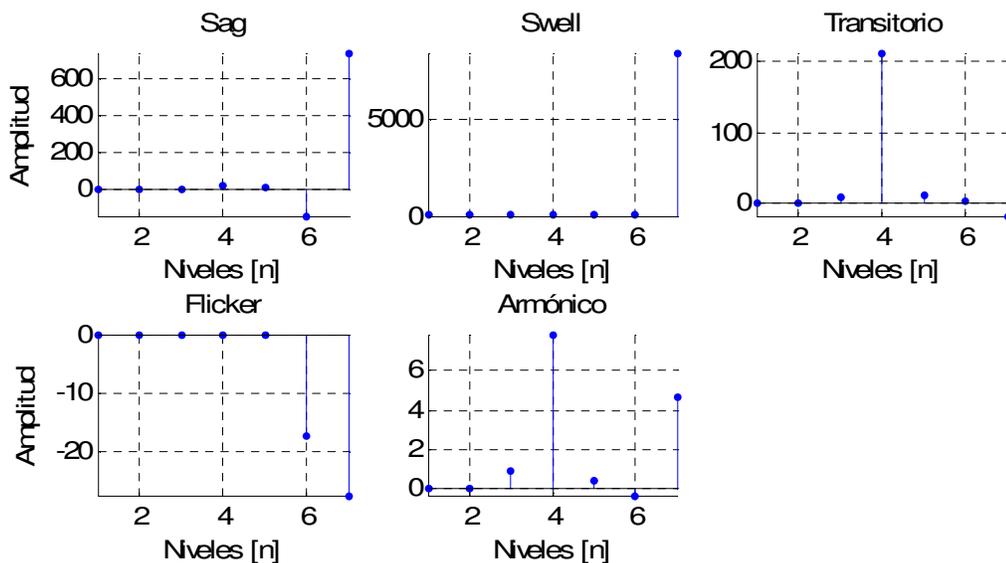
$En_ref(j)$: es la energía de la señal de pre-evento en cada nivel j .

$En_ref(m)$: es la energía de la señal de pre-evento en el nivel de mayor energía (m).

* $j = 1, 2, 3, \dots N$ (N es el número de niveles de descomposición)

A partir de (8) se propone una ecuación más sencilla, en la cual sólo se hace la diferencia entre los En_per y En_ref de la siguiente forma $DifEn = En_per - En_ref$, es decir, sin calcular el porcentaje respecto a la referencia y se llamará diferencia de las energías. Al calcular $DIFen$ a las formas de onda de la Figura 17, se obtienen los patrones de la Figura 43 utilizando la función *wavelet* Bior3.7 para la transformación.

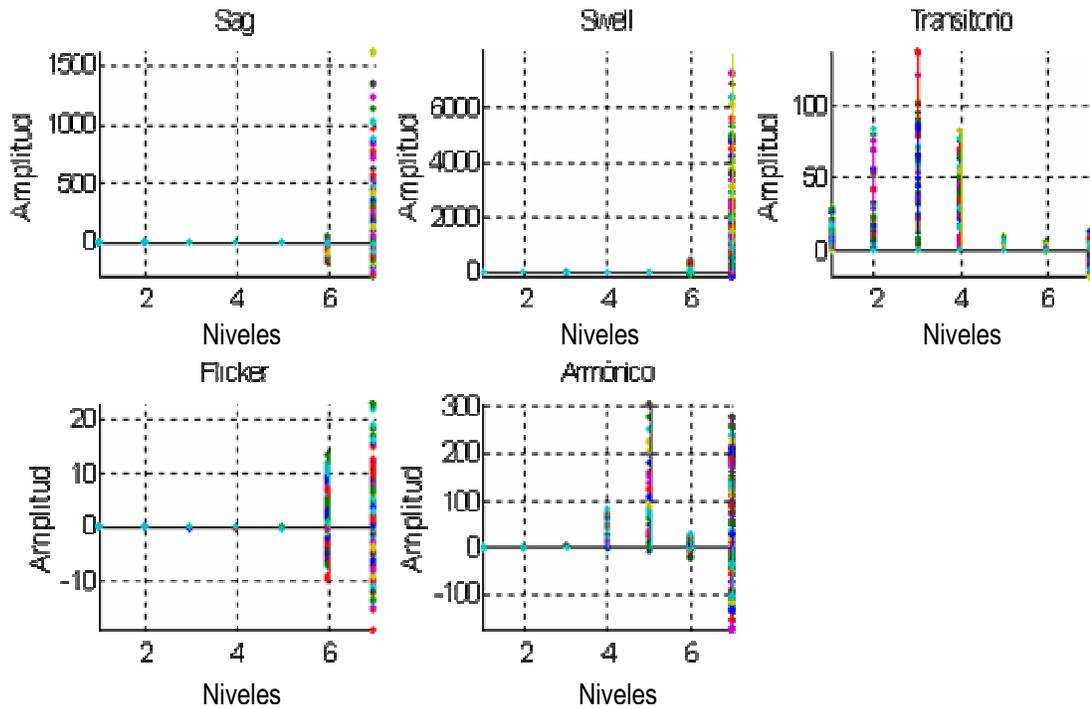
Figura 43 Patrones obtenidos al evaluar $DifEn$ con las perturbaciones de la Figura 17 utilizando para la transformación la función *wavelet* Bior3.7.



Fuente: Elaborada por el autor.

El patrón obtenido a partir de esta estrategia de identificación con 7 valores de energía, se exponen en la Figura 44 tomado 2 500 señales de la base de datos y utilizando la función *Wavelet* Bior3.7 para la transformación.

Figura 44 Patrones obtenidos a partir de la técnica diferencias de energía para 2 500 perturbaciones, utilizando la función *wavelet* Bior3.7 para la transformación.



Fuente: Elaborada por el autor.

En la Figura 44 es posible apreciar la variación positiva y negativa de gran amplitud en el mismo nivel que presentan la mayoría de los eventos, principalmente en el nivel 6 y 7. Esto hace que se dificulte la posterior clasificación para estos eventos. Es de notar que los patrones cambian de acuerdo a la variación de las características de magnitud y frecuencia de la perturbación. Por ejemplo, la elevación de tensión –*swell*- presenta un valor positivo en el nivel de descomposición 7, la magnitud de este valor es proporcional a la variación de la elevación de tensión de la perturbación. A continuación se presenta otro esquema que utiliza algunos de los elementos de esta técnica y la adición de valor RMS.

4.2.2. Energía de la perturbación a partir de coeficientes *Wavelet* y valor eficaz – patrón 2

En esta estrategia se toma la señal perturbada sp , se calcula inicialmente la energía de los coeficientes de detalle de cada uno de los 7 niveles de descomposición, luego a este vector se le añaden dos posiciones más

correspondientes al valor RMS máx y RMS mín descrito en el numeral 4.2 y se representa en la Figura 45, dónde N7 significa nivel 7. La adición de los valores RMS máx y RMS mín permite diferenciar de manera contundente las perturbaciones *sag* y *swell*, esto se fundamenta en el análisis previo de las características de estas dos perturbaciones cuando se calcula el valor RMS muestra a muestra (RMS-MM) de la señal *sp* como se presentó en la Figura 40. De igual forma es posible apreciar en la misma figura que valor RMS-MM calculado en el pre-evento sirve de referencia para diferenciar el valor RMS-MM calculado para el instante donde ocurre el evento *sag* que es menor que la referencia y el del *swell* que por el contrario es mayor que esta misma referencia.

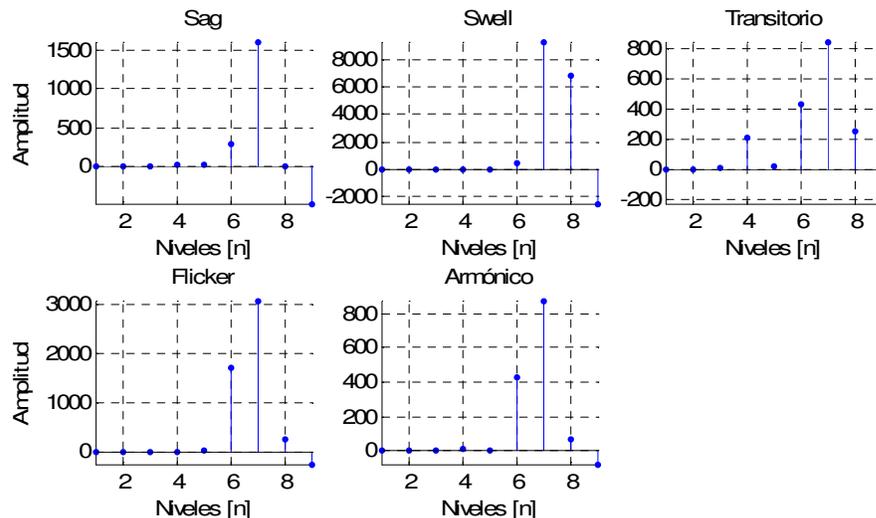
Este análisis y el realizado a la Figura 26 al comienzo de este capítulo, evidencia que las perturbaciones con cambios o variaciones de amplitud se reflejan en la magnitud del cálculo del valor eficaz y las perturbaciones con alto contenido frecuencial, se identifican mejor utilizando una transformación espectral como es el caso de la transformada *Wavelet*, que realiza un proceso de descomposición en niveles o bandas de frecuencia.

Figura 45 Vector patrón resultante de la combinación de TW y RMS.

N1	N2	N3	N4	N5	N6	N7	RMS máx	RMS Mín
----	----	----	----	----	----	----	---------	---------

En la Figura 46 se presentan los patrones obtenidos a partir de la energía los coeficientes *wavelet* y el cálculo del valor RMS máx y RMS mín para las perturbaciones de la Figura 17, utilizando para la transformación la función *wavelet* Bior3.7.

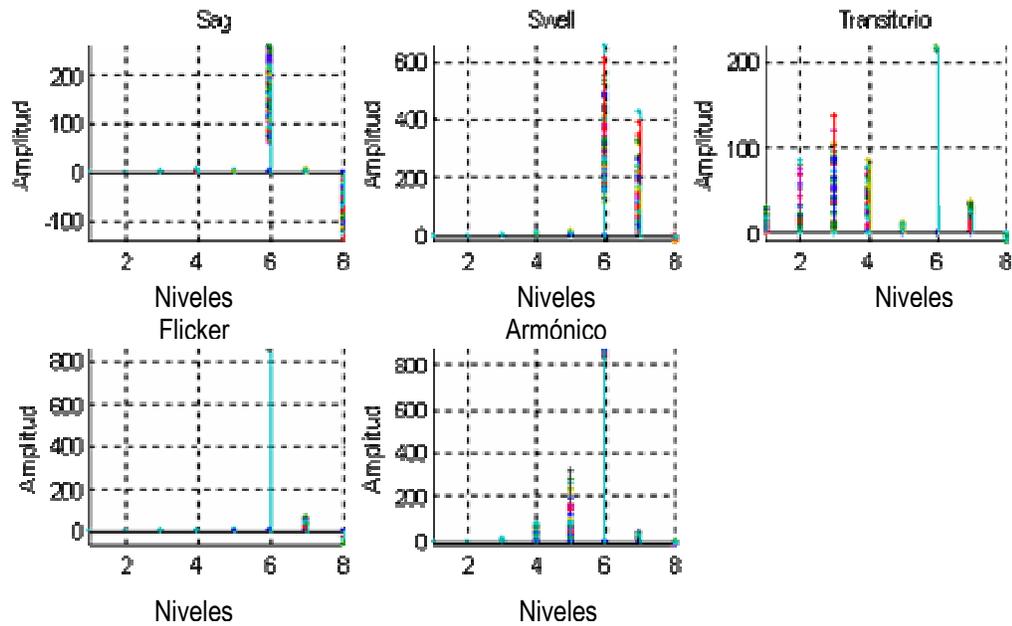
Figura 46 Patrones de la técnica 2: energía de la perturbación y valor RMS máx y RMS mín para las perturbaciones de la Figura 17, utilizando la función *wavelet* bior3.7 para la transformación



Fuente: Elaborada por el autor.

Es posible apreciar en la Figura 46 que en todas las perturbaciones el nivel 7 presenta un gran contenido de energía, esto es debido a la componente de frecuencia fundamental. Esto hace que no se resalten las componentes de frecuencia de las perturbaciones. Por este motivo se elimina este nivel y los descriptores finales, en total 8, se presentan en la Figura 47 utilizando el conjunto de señales de prueba de la base de datos.

Figura 47 Grupo de patrones de la técnica 2: energía de la perturbación y valor RMS máx y RMS mín para 2 500 perturbaciones utilizando la función *wavelet bior3.7* para la transformación.



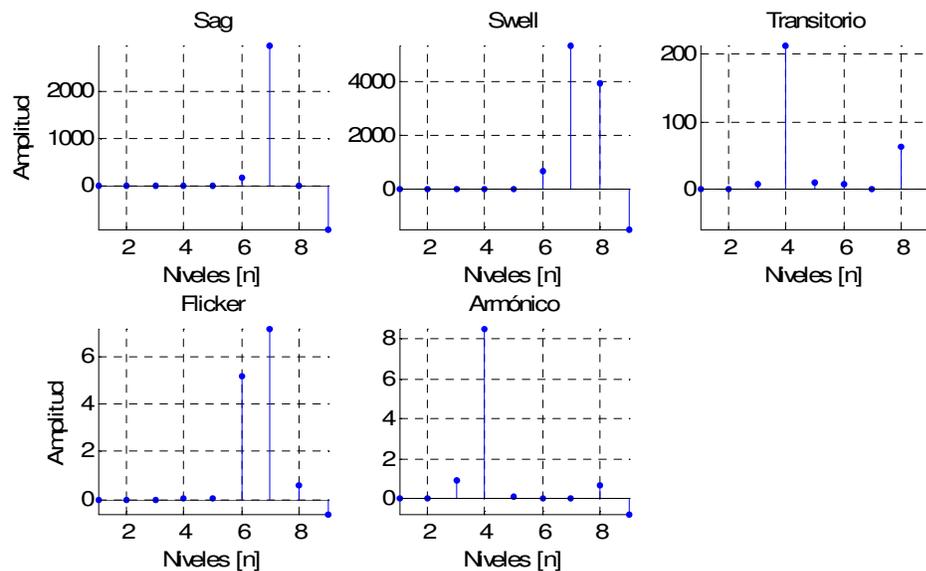
Fuente: Elaborada por el autor.

De la Figura 47 se tiene que es posible diferenciar las perturbaciones a partir de éstos descriptores. Para el caso del *sag* y *swell* con la ayuda del valor máx y mín es posible establecer la diferencia debido a que el valor RMS máx en el evento *sag* es muy pequeño mientras que en el evento *swell* es considerablemente grande respecto al valor máximo del patrón. Por otro lado el valor RMS mín es de valor negativo y con gran amplitud para el *sag* y por el contrario es bastante pequeño para el *swell*. Los eventos con variaciones en sus componentes de frecuencia como son el transitorio, el *flicker* y el armónico, presentan diferencias notorias en su patrón. Para el caso del *flicker* el valor RMS máx y RMS mín, presentan la misma magnitud pero con signo contrario, esto no sucede en los otros eventos. El transitorio presenta mayores componentes de energía en los niveles 1 al 4, contenido de frecuencia en el rango de 240 a 3 840 Hz que es característico del mismo. Por su parte el evento armónico tiene componentes en gran parte del espectro pero sobre todo en los niveles 3, 4 y 5 que tienen un rango de frecuencias entre los 120 a 960 Hz.

4.2.3. Cálculo de la energía de la señal diferencia y valor eficaz

En esta técnica se realiza el cálculo de la energía de los coeficientes de detalle de la transformada *Wavelet* de la señal diferencia *sd* para 7 niveles de descomposición, obtenida ésta última a partir de la diferencia de *sp* y *sb*. Al igual que la técnica anterior se añade también el valor RMS máx y RMS mín como se muestra en la Figura 48.

Figura 48 Patrones obtenidos a partir de la técnica energía de la diferencia

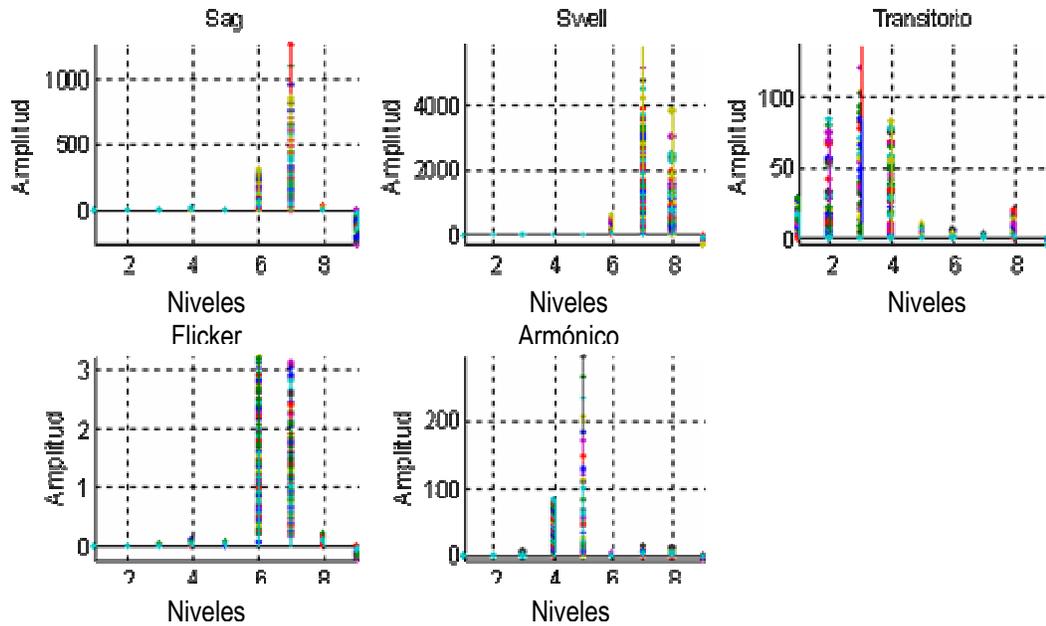


Fuente: Elaborada por el autor.

El resultado presentado en la Figura 48 muestra una fácil diferenciación entre los patrones de cada perturbación. Principalmente en los eventos *sag* y *swell*, donde la diferencia la hace el valor RMS máx y RMS mín (posiciones 8 y 9). El evento transitorio y armónico pueden presentar algunas similitudes en su forma pero los valores de las amplitudes hacen la diferencia. El evento *flicker* es totalmente distinto a los demás y esto sucede porque las frecuencias contenidas en este evento están en las cercanías de los 60 Hz. Como la componente fundamental de la señal es eliminada, es posible observar las frecuencias respectivas de este evento, también es acompañado de un valor RMS máx y RMS mín de la misma amplitud y diferente signo.

En la Figura 49 se presenta el patrón 3 (de tamaño 9) utilizando el conjunto de señales de prueba de la base de datos y la función *wavelet* Bior3.7 para la transformación.

Figura 49 Patrones obtenidos a partir de la técnica energía de la señal diferencia y valor RMS máx y RMS mín para 2 500 perturbaciones utilizando la función *wavelet* Bior3.7 para la transformación.



Fuente: Elaborada por el autor.

De la Figura 49 se puede apreciar la alta diferenciación entre los patrones de las perturbaciones. Al calcular la diferencia entre la señal pre-evento y la señal perturbada, se obtiene automáticamente la característica de la perturbación en el dominio tiempo. Cuando se calcula la energía por nivel de descomposición se obtienen las características en cada rango de frecuencia (señales que poseen variaciones en las componentes de frecuencia) y con el cálculo del valor eficaz se obtiene la información de las variaciones en amplitud (caídas y elevaciones de tensión). Con esta técnica es posible resaltar las características de las perturbaciones analizadas en este estudio, debido a la alta diferenciación que obtiene en sus patrones al ser comparados de forma visual.

Es necesario evaluar cada uno de los 3 patrones con una técnica de clasificación que permita estimar cual de los 3 grupos de patrones posee la mayor diferenciación. El patrón 2 se presenta como uno de los patrones más opcionados para la labor de identificar perturbaciones.

4.3. CONSIDERACIONES FINALES

En este capítulo se presentó la investigación relacionada con el proceso de identificación de perturbaciones de la calidad de la energía eléctrica, el cual

debe permitir la posterior clasificación de las mismas. Se aborda el tema del problema que se presenta al clasificar perturbaciones y se plantea una metodología para la obtención de descriptores adecuados que permitan una alta diferenciación entre cada uno de los patrones. Esto permite garantizar una adecuada clasificación con un menor rango de incertidumbre.

Se planteó una estrategia para seleccionar una función *wavelet* adecuada para identificación de patrones, es decir, la posibilidad seleccionar un filtro pasaltas asociado a una función *wavelet* capaz de identificar de manera adecuada las características de cada perturbación. Para esto se planteó un análisis en frecuencia (barrido en frecuencia) utilizando señales senoidales generadas sintéticamente para calcular la energía de los coeficientes de detalle para 8 niveles de descomposición (utilizando el conjunto de funciones *wavelet* de la Tabla 16), a partir de estas energías se calcula una relación que permite seleccionar de manera adecuada las funciones *wavelet* con mejor selectividad.

Debido a que cada perturbación tiene información en determinados niveles de energía o rangos de frecuencia, es posible diferenciar un evento de otro utilizando como herramienta el cálculo de la energía de los coeficientes *wavelet* por nivel de descomposición. Adicional a esto el cálculo del valor RMS o valor eficaz, es de gran ayuda para diferenciar perturbaciones que presentan significativos cambios de amplitud. A partir de estas dos propuestas que combinan la identificación de señales con el contenido espectral y con los cambios de amplitud, se plantean 3 tipos de patrones para identificación de perturbaciones que afectan la calidad de la energía eléctrica.

De igual forma se presentó también el trabajo previo desarrollado que permitió conformar estas estrategias (cálculo de la transformada de *Fourier*, valor RMS y parámetros estadísticos) y se resaltó la ventaja de obtener la energía de los coeficientes de detalle de la transformada *Wavelet* ante los coeficientes de la transformada *Fourier* por el tamaño del vector resultante. Al aplicar la TF a una señal, el vector resultante es de la mitad del número de muestras de la señal en cambio utilizar la TW, a lo sumo 7 ó 9 datos se tendrían (esto depende de la frecuencia de muestreo de la señal y del tamaño de la señal a analizar).

Para determinar cuál patrón es adecuado o no, se someten los 3 obtenidos a una estrategia de clasificación automática conocida como Máquinas de Soporte Vectorial – MSV, la cual permitirá decidir la selección del mejor patrón. En el Capítulo 5, se presenta la estrategia de clasificación mencionada.

5. ESTRATEGIA DE CLASIFICACIÓN: MÁQUINAS DE SOPORTE VECTORIAL

En este capítulo se presenta el estado del arte en la clasificación de perturbaciones de la calidad de la energía eléctrica (*power quality*). Se resalta la importancia de las técnicas de inteligencia artificial más utilizadas en la investigación, especialmente en el uso de la máquina de soporte vectorial. Luego se hace una descripción de esta herramienta matemática y se presentan los resultados de simulación utilizando una herramienta computacional diseñada para tal fin. Los elementos a clasificar son los patrones obtenidos en la estrategia de identificación (Capítulo 4).

5.1. ESTADO DEL ARTE EN LA CLASIFICACIÓN DE PERTURBACIONES DE LA CALIDAD DE LA ENERGÍA

Las técnicas de inteligencia artificial han tenido un gran auge en la solución de problemas de clasificación de datos o patrones. Las técnicas de clasificación conocidas de mayor aplicabilidad son: las redes neuronales artificiales, lógica *fuzzy* o lógica borrosa, algoritmos genéticos, los sistemas expertos basados en reglas, la técnica de decisión de Bayes, el análisis discriminante cuadrático (QDA), el análisis discriminante lineal (LDA), los árboles de decisión y las máquinas de soporte vectorial (MSV), entre otras.

En la actualidad, la utilización de una técnica de inteligencia artificial se encuentra muy ligada a la naturaleza del problema a resolver. Es por esto, que resulta difícil decidir o generalizar cuál es la mejor técnica entre las ya mencionadas cuando se abordan distintos problemas con la misma técnica. A continuación se presentan algunos trabajos donde se emplean diferentes técnicas de clasificación enfocadas al estudio de perturbaciones que afectan la calidad de la energía eléctrica.

En [Daponte, 04] el esquema de clasificación se basa en una Red *Wavelet* (WNs). Es una red feedforward en cuya primera capa la función de activación es remplazada por una función *Wavelet* madre. El algoritmo de entrenamiento de *backpropagation*, modifica no sólo los pesos de la neurona y los umbrales, sino también los parámetros escala y traslación de los nodos *Wavelet*. La estrategia de identificación se basa en la descomposición en sub-bandas de frecuencia utilizando la transformada *Wavelet* discreta. Se realiza el proceso de descomposición y reconstrucción con lo cual es más fácil extraer características como duración de la perturbación, valor pico a pico, tiempo de subida, etc.

[Chilukuri, 04] propone una técnica de detección, clasificación y cuantificación basada en el reconocimiento de patrones tiempo-frecuencia de perturbaciones de la calidad de la energía. Utiliza la transformada de Fourier de tiempo corto (transformada S) para extraer características tiempo-frecuencia. Estas características sirven de patrón para la clasificación (en total son 14 características). Finalmente, un sistema simple basado en reglas es utilizado para la clasificación de los patrones obtenidos. También los autores han propuesto recientemente un sistema experto que combina la transformada S con lógica *fuzzy*. Los porcentajes de acierto son del 98,2% en promedio para perturbaciones en presencia de ruido como se presenta la Tabla 24.

Tabla 24 Resultados de la clasificación de Perturbaciones de la calidad de la energía obtenidas en [Chilukuri, 04].

Power Quality Event	Correct	Wrong	% Success
Voltage Sag	39	1	97.5
Voltage Swell	38	2	95.0
Voltage Interruption	40	0	100
Notch	40	0	100
Impulse Transient	20	0	100
Oscillatory Transient	60	0	100
Harmonic	25	2	92
Flicker	60	0	100
Normal + Noise	9	1	90
Total	340	6	98.20

Fuente: [Chilukuri, 04]

Clasificadores como las redes neuronales son empleadas en trabajos como [Barrera & Cormane, 03], tomando como entrada características de las señales de tensión y corriente para el análisis de armónicos. Las redes también se utilizan como clasificador en [Kezunovic & Liao, 00], [Wang, 01], [Liu, 02] [Dilokratana, 03], [Vega, 04], [Lin, 05], con patrones de entrada obtenidos a partir de la transformada *Wavelet*.

En trabajos recientes como [Gou-Sheng & Jing, 05] la transformada *Wavelet* y las máquinas de vectores de soporte - *fuzzy*, son utilizadas para la detección y clasificación de perturbaciones de la calidad. Se analizan perturbaciones como: sags, swell, interrupciones, transitorios oscilatorios y de tipo impulso, flicker, armónicos y muescas de tensión. La transformada de *Fourier* y la transformada *Wavelet* son utilizadas para eliminar ruido y descomponer las señales y obtener 8 características de las perturbaciones como patrones. Una máquina de vectores de soporte - *fuzzy* es diseñada y entrenada con las 8 características para tomar la decisión sobre el tipo de perturbación. Los

resultados presentados son satisfactorios, del 98% de acierto de la clasificación promedio y se pueden observar en la Tabla 25.

Tabla 25 Resultados de la clasificación de Perturbaciones de la calidad de la energía obtenidas en [Gou-Sheng & Jing, 05].

Type of PQ disturbances	Number of disturbances	Number of cases correctly identified	Number of cases fault identified	correct identification rate(%)
Sag	1000	984	16	
Swell	1000	990	10	
Interruption	1000	980	20	
Harmonic	1000	996	4	
Transient	1000	991	9	
Impulse	1000	974	26	
Flicker	1000	967	33	
Notch	1000	960	40	
Sum	8000	7842	158	98

Fuente: [Gou-Sheng & Jing, 05].

Por otro lado en [Janik & Lobos, 06], además de la detección e identificación utilizando la transformada *Wavelet*, emplea el espacio fasorial para extraer características de las perturbaciones que afectan la calidad de la energía como *sags*, *swells*, interrupciones, *flicker*, etc., que son utilizadas en el esquema de clasificación basado en la combinación de las redes neuronales y las máquinas de soporte vectorial, tomando como *kernel*, la función de base radial (RBF).

[Vega, Duarte & Ordóñez, 06] es un reciente trabajo que expone la problemática de la clasificación a perturbaciones de la calidad de la energía eléctrica. Se ataca el problema con diferentes técnicas de clasificación como RNAs (Perceptrón multicapa y *Kohonen*), Bayes y por último MSV. Los resultados se presentan en el numeral 5.4.

Después de la revisión algunos trabajos pertenecientes al estado del arte en la clasificación de perturbaciones. Se presenta una breve introducción a las máquinas de soporte y se presentan los resultados de la implementación utilizando como vectores de entrada los patrones obtenidos en el Capítulo 4.

5.2. METODOLOGÍA DEL PROCESO DE CLASIFICACIÓN

Para clasificar los grupos de patrones obtenidos en el capítulo anterior, se hace necesaria la implementación de un sistema de clasificación automática que permita, de manera precisa a partir de descriptores extraídos de una señal, determinar qué tipo de perturbación se ha presentado. Para esto se estudia la máquina de soporte vectorial como alternativa en la búsqueda de un clasificador óptimo para los patrones extraídos de las perturbaciones en estudio que afectan la calidad de la energía.

El proceso de clasificación se puede describir como se presenta en la Figura 50.

Figura 50 Proceso de clasificación de descriptores utilizando MSV



Fuente: [Campos & Suárez, 07]

En la Figura 50 se muestra la entrada correspondiente a los patrones o descriptores obtenidos en el Capítulo 4, a continuación el modelo de la MSV y el proceso de clasificación, el cual es descrito en las secciones siguientes de este capítulo y por último la salida correspondiente al tipo de evento. En este caso la máquina permite clasificar dos tipos de eventos identificados con las etiquetas 1 o -1.

La metodología desarrollada en este capítulo está estructurada de la siguiente forma:

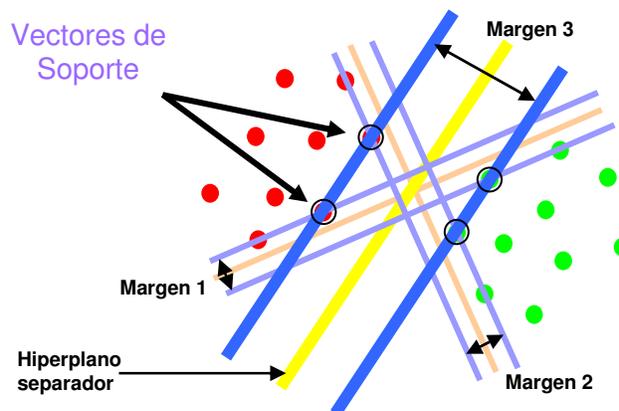
1. Inicialmente se hace una descripción teórica de las ecuaciones que hacen parte del principio de funcionamiento las Máquinas de Soporte Vectorial – MSV biclasificadoras, es decir que sólo clasifican 2 clases.
2. Se define también el parámetro de penalización y se presentan las MSV no lineales, utilizadas cuando no es posible separar las clases linealmente. Para esto, es necesario presentar el conjunto de funciones kernel que realizan esta separación.
3. Para la clasificación de 3 clases o más, se plantea un esquema de multclasificación compuesto por métodos de descomposición y reconstrucción. Este último implica el uso de esquemas de votación.

4. Se plantea también el esquema de validación cruzada y búsqueda en malla, necesarios en el entrenamiento de las MSV para calcular el parámetro de penalización C y los parámetros del kernel adecuados para encontrar el mejor modelo MSV.
5. Finalmente se presentan los resultados de simulación clasificando los patrones obtenidos en el Capítulo 4.

5.3. MÁQUINAS DE SOPORTE VECTORIAL

Las Máquinas de Soporte Vectorial (MSV), en los últimos años, han dado buenos resultados en la clasificación y reconocimiento de patrones en general. Su potencialidad supera a otras técnicas empleadas como las redes neuronales artificiales (RNAs), los árboles de clasificación (CART), las técnicas bayesianas, etc, [Vapnik, 95]. Por ejemplo, a diferencia del método bayesiano, las MSV no requieren ningún tipo de hipótesis sobre la densidad de probabilidad de los datos. Frente a las RNAs ofrecen la ventaja de reducir la cantidad de parámetros que es necesario especificar; es decir, lo que se espera que haga un usuario de las MSV es escalar los datos de entrenamiento y validación, considerar el *kernel* adecuado (puede ser la función de base radial, la polinomial, la gaussiana, por ejemplo) y encontrar los valores adecuados de sus parámetros (C y σ). Para entender su funcionamiento considérese un grupo de datos distribuidos en dos clases, así entonces, una MSV lineal busca un hiperplano de tal manera que la mayor cantidad de puntos de la misma clase queden al mismo lado, mientras que se maximiza la distancia (margen) de tales clases al hiperplano [Henao, 04]. De acuerdo con [Vapnik, 95], este hiperplano minimiza el riesgo de clasificaciones erróneas en el grupo de datos tomado para realizar el proceso de validación, ya que el margen o distancia se ha maximizado (Ver Figura 51).

Figura 51 Separación de vectores mediante hiperplanos.



Fuente: [Morales & Gómez, 05]

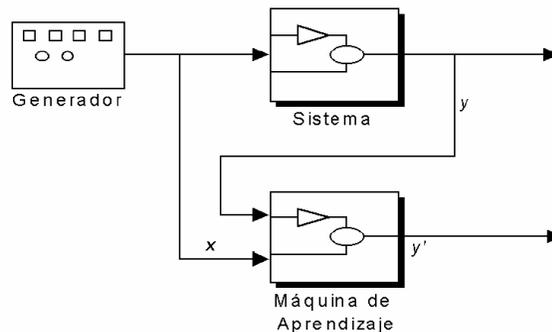
Esta técnica de inteligencia artificial aprende a través de ejemplos. Se entiende por aprendizaje a partir de ejemplos como el proceso de estimar una dependencia desconocida entrada-salida de un sistema utilizando un número limitado de observaciones [Burges, 98].

El modelo en general de un proceso de aprendizaje a partir de ejemplos se desarrolla sobre tres componentes [Angulo, 01]:

1. Un vector de entrada X
2. Un sistema que retorna un valor de salida, $y \in Y$, para todo vector de entrada X
3. Una máquina de aprendizaje

La máquina de aprendizaje observa los pares que constituyen el conjunto de entrenamiento (vectores de entrada y su respectiva clasificación - o etiqueta de clase-), para construir a partir de ellos, durante el período de entrenamiento, algún operador que sirva de clasificador capaz de distinguir entre las distintas clases de entradas producidas por el generador. En la Figura 52 puede apreciarse este proceso.

Figura 52 Modelo general de un proceso de aprendizaje a partir de ejemplos



Fuente: [Angulo, 01].

Matemáticamente es posible explicar el aprendizaje de las máquinas considerando n datos de entrenamiento de N dimensiones, \bar{x}_i , con su respectiva etiqueta \bar{y}_i , donde $\bar{x}_i \in \mathfrak{X}^N$ y $\bar{y}_i \in \{+1, -1\}$ (Figura 50). Es decir, cada clase tiene una etiqueta que puede ser +1 ó -1 (para el caso de biclasificación), con las cuales se busca estimar una función f tal que para una entrada en \mathfrak{X}^N produzca una salida en $\{\pm 1\}$.

En adelante se detallan las ecuaciones que hacen parte del funcionamiento de la técnica de inteligencia artificial máquinas de soporte vectorial, a partir de diferentes publicaciones como son: [Burges, 98], [Schölkopf & Smola, 02], [Vapnik, 95], [Cherkassky, 98] y tesis de grado: [Campos & Suárez, 07] y [Morales & Gómez, 05].

¿Cómo se realiza el proceso de separación de las clases? para el conjunto de datos de la Figura 51, existe un único hiperplano óptimo de separación OSH (de sus siglas en inglés *Optimal Separating Hyperplane*), de forma que la distancia entre el hiperplano óptimo y el patrón de entrenamiento más cercano sea máxima, con la intención de forzar la generalización de la máquina de aprendizaje y se expresa de la siguiente forma:

$$g(\vec{x}_i) = (\vec{w} \cdot \vec{x}_i) + b = 0 \quad (9)$$

Se proponen dos hiperplanos paralelos a la ecuación (9) que contienen los puntos más cercanos al OSH (Hiperplanos en color azul en la Figura 51).

Definiendo como $\frac{1}{\|\vec{w}\|}$ la distancia perpendicular entre el punto más cercano al OSH, y a partir del OSH, se obtienen las ecuaciones de dichos hiperplanos paralelos:

$$P_{+1} : (\vec{w} \cdot \vec{x}_i) + b = +1 \quad (10)$$

$$P_{-1} : (\vec{w} \cdot \vec{x}_i) + b = -1 \quad (11)$$

Siendo el margen la distancia perpendicular entre (10) y (11):

$$\begin{aligned} [(\vec{w} \cdot \vec{x}_{+1}) + b] - [(\vec{w} \cdot \vec{x}_{-1}) + b] &= +1 - (-1) \\ \vec{w} \cdot (\vec{x}_{+1} - \vec{x}_{-1}) &= 2 \\ \frac{\vec{w}}{\|\vec{w}\|} \cdot (\vec{x}_{+1} - \vec{x}_{-1}) &= \frac{2}{\|\vec{w}\|} \end{aligned} \quad (12)$$

y la distancia del OSH al origen:

$$(\vec{w} \cdot \vec{x}_i) + b = 0$$

$$\vec{x}_i = 0$$

$$\frac{(\vec{w} \cdot \vec{x}_i) + b}{\|\vec{w}\|} = \frac{b}{\|\vec{w}\|} \quad (13)$$

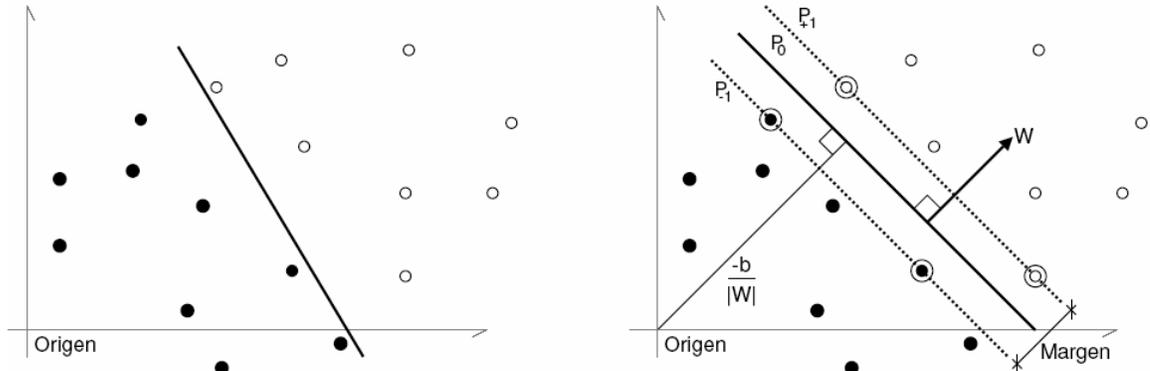
En ese orden de ideas, las ecuaciones (10) y (11) deben cumplir:

$$(\vec{w} \cdot \vec{x}_i) + b \geq +1 \text{ para } y_i = +1 \quad (14)$$

$$(\vec{w} \cdot \vec{x}_i) + b \leq -1 \text{ para } y_i = -1 \quad (15)$$

Para ejemplificar este proceso en dos dimensiones, en la Figura 53 es posible apreciar los márgenes y etiquetas ya mencionadas. Los hiperplanos pueden ser vistos como rectas que separan el conjunto de datos y cada clase posee una etiqueta. En el Anexo B se encuentra un ejemplo numérico que representa el proceso de separación lineal de dos clases mediante vectores de soporte.

Figura 53 Hiperplanos de separación. Margen de separación mayor en la derecha, separa mejor las clases [Burges, 98].



Además, debe existir una función de decisión que permita especificar la clase a la cual pertenece cada nuevo dato evaluado en la ecuación del OSH (9):

$$f_{w,b}(\vec{x}_i) = \text{sign}[g(\vec{x}_i)] = \text{sign}[(\vec{w} \cdot \vec{x}_i) + b] \quad (16)$$

Combinando (14) y (15) resulta:

$$y_i (\vec{w} \cdot \vec{x}_i + b) \geq 1 \quad (17)$$

Si existe un hiperplano que satisfaga (17), significa que los datos son linealmente separables.

Para encontrar el OSH se debe maximizar el margen (12), teniendo en cuenta la restricción (17), equivalente a resolver el siguiente problema:

$$\underset{w,b}{\text{mín}} \frac{1}{2} (\vec{w} \cdot \vec{w}) \quad (18)$$

$$\text{Sujeto a } y_i (\vec{w} \cdot \vec{x}_i + b) \geq 1, \forall i \quad (19)$$

La ecuación (18) es la función objetivo, y junto con (19) corresponde a un problema de optimización cuadrático con restricciones, el cual es resuelto mediante el método de los multiplicadores de Lagrange.

Para esta clase de problemas con restricciones, se introducen los multiplicadores de Lagrange $\alpha_i \geq 0$ (uno por cada restricción). Para las

restricciones de la forma $R_i \geq 0$, cada restricción es multiplicada por α_i (un multiplicador de Lagrange positivo) y se restan de la función objetivo, para así formar la función de Lagrange [Burges, 98]:

$$L(\bar{w}, b, \bar{\alpha}) = \frac{1}{2} \|\bar{w}\|^2 - \sum_{i=1}^n \alpha_i [y_i (\bar{w} \cdot \bar{x}_i + b) - 1] \quad (20)$$

La función de Lagrange (20) debe ser minimizada con respecto a las variables primarias w y b , y maximizada sobre los α_i (en otras palabras encontrar el punto de silla) [Schölkopf & Smola, 02]. Para el caso de $y_i (\bar{w} \cdot \bar{x}_i + b) - 1 > 0$, el correspondiente α_i debe ser cero, debido a que este es el valor de α_i es el que maximiza (20), los $\alpha_i \neq 0$ son para el caso en que $y_i (\bar{w} \cdot \bar{x}_i + b) - 1 = 0$ (estos son los patrones de entrenamiento que quedan sobre los planos paralelos expresados por (10) y (11) al OSH). Este último enunciado corresponde a las condiciones de *Karush-Kuhn-Tucker* (condiciones complementarias de optimización) [Kuhn & Tucker, 51]:

$$\alpha_i [y_i (\bar{w} \cdot \bar{x}_i + b) - 1] = 0 \quad \forall i \quad (21)$$

$$\frac{\partial}{\partial w} L(\bar{w}, b, \bar{\alpha}) = 0 \quad \Rightarrow \quad \bar{w} = \sum_{i=1}^n \alpha_i y_i \bar{x}_i \quad (22)$$

$$\frac{\partial}{\partial b} L(\bar{w}, b, \bar{\alpha}) = 0 \quad \Rightarrow \quad \sum_{i=1}^n \alpha_i y_i = 0 \quad (23)$$

La solución de \bar{w} en (22) queda en función de un subconjunto de patrones de entrenamiento, aquellos cuyo multiplicador de Lagrange es diferente de cero, es decir, el soporte de \bar{w} está en los patrones de entrenamiento más cercanos al OSH. De aquí el nombre de Máquinas de Soporte Vectorial.

Reemplazando (22) y (23) en (20), se eliminan las variables primarias \bar{w} y b llegando así al problema de *optimización dual de Wolfe*, el cual es el problema que se resuelve en la práctica:

$$\max_{\alpha} \left[\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\bar{x}_i \cdot \bar{x}_j) \right] \quad (24)$$

$$\text{Sujeto a } \alpha_i \geq 0, \quad \forall i \quad \text{y} \quad \sum_{i=1}^n \alpha_i y_i = 0 \quad (25)$$

Este problema puede ser resuelto con métodos de programación cuadrática estándar [Burges, 98]. En este trabajo se emplea el método de optimización SMO (sus siglas en inglés *Sequential Minimal Optimization*) que es el más utilizado debido a su efectividad computacional, el cual descompone el problema de optimización en tareas mucho más pequeñas, en orden a reducir el tamaño de las operaciones matriciales, es decir, requerimientos de memoria y procesador [Heno, 04]

Una vez obtenido el vector $\vec{\alpha}$ se pueden obtener los parámetros \vec{w} y b con (22) y (21) respectivamente:

$$\vec{w} = \sum_{i=1}^n \alpha_i y_i \vec{x}_i \quad (26)$$

$$b = y_i - \vec{w} \cdot \vec{x}_i \quad (27)$$

Ahora la ecuación del OSH y la función de decisión pueden ser escritas como:

$$g(\vec{x}) = \sum_{i=1}^n [\alpha_i y_i (\vec{x}_i \cdot \vec{x})] + b \quad (28)$$

$$f(\vec{x}) = \text{sign} \left(\sum_{i=1}^n [\alpha_i y_i (\vec{x}_i \cdot \vec{x})] + b \right) \quad (29)$$

5.3.1. Parámetro de penalización – tolerancia al ruido en una MSV

La existencia de datos erróneos, ruido o alto solapamiento entre las clases de los datos de entrenamiento, afectan directamente la ubicación del hiperplano clasificador óptimo. Debido a esto, es necesario buscar el mejor hiperplano clasificador que pueda tolerar el ruido en los datos de entrenamiento, permitiendo la posibilidad de violación de la restricción (19). Por lo anterior, [Cortes & Vapnik, 95] introducen las variables de relajación ξ_i (*slack*) basándose en el trabajo de [Bennett & Mangasarian, 92], esto se ve representado en la Figura 54 y se describe en las ecuaciones (30) y (31) [Morales & Gómez, 05].

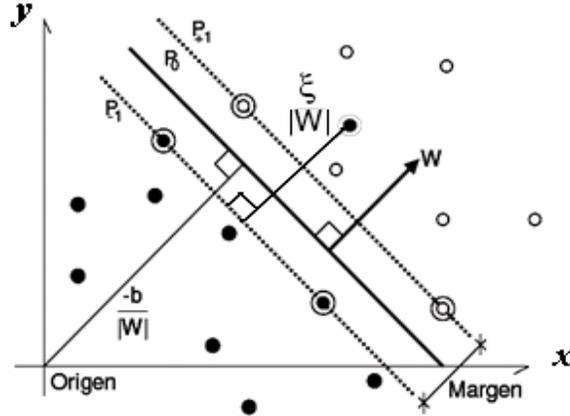
A partir de la condición:

$$\xi_i \geq 0, \quad \forall_i \quad (30)$$

Se formula una nueva restricción:

$$y_i(\bar{w} \cdot \bar{x}_i + b) \geq 1 - \xi_i, \quad \forall_i \quad (31)$$

Figura 54 Hiperplanos de separación utilizando variables de relajación.



Fuente: [Burges, 98]

A partir de la nueva condición, se calcula y se obtiene un nuevo clasificador que generaliza bien; controlando tanto su capacidad de clasificación (con $\|\bar{w}\|$), como el límite superior del número de errores de entrenamiento ($\sum_{i=1}^n \xi_i$). Para obtener el hiperplano clasificador óptimo con un margen débil es necesario minimizar la función:

$$\min_w \left[\frac{1}{2} (\bar{w} \cdot \bar{w}) + C \sum_{i=1}^n \xi_i \right] \quad (32)$$

$$\text{Sujeto a } y_i(\bar{w} \cdot \bar{x}_i + b) \geq 1 - \xi_i, \quad \forall_i \quad (33)$$

El usuario elige a priori el parámetro C, el valor de este parámetro es proporcional a la penalización, es decir, cuanto más grande sea el valor de C, mayor es la penalización a los errores. Si se emplean los multiplicadores de Lagrange, este problema se transforma en:

$$\max_{\alpha} \left[\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (\bar{x}_i \cdot \bar{x}_j) \right] \quad (34)$$

$$\text{Sujeto a } 0 \leq \alpha_i \leq C, \quad \forall_i \quad \text{y} \quad \sum_{i=1}^n \alpha_i y_i = 0 \quad (35)$$

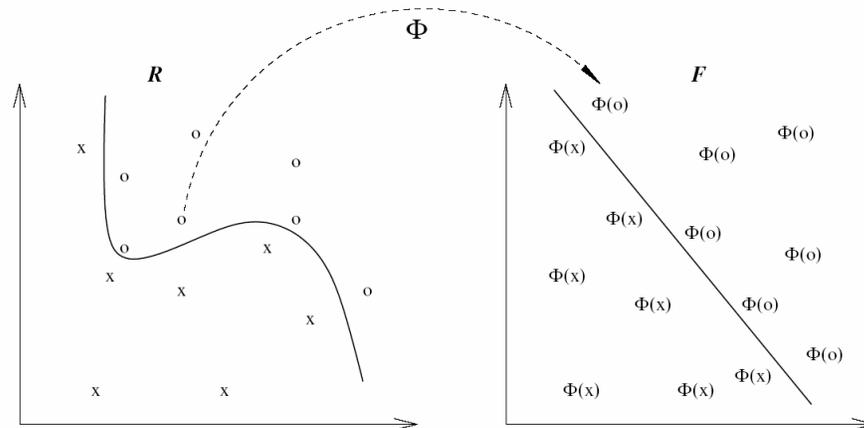
La solución da como resultado (22). El hiperplano separador solución puede ser escrito como en (30)(28) y la función de decisión como (29).

Hasta el momento el problema de clasificación se ha resuelto de forma lineal por medio de un hiperplano separador. En el instante en que las clases a clasificar presenten un comportamiento de separación no lineal, es necesario recurrir a otros métodos par conseguir la separación de dichas clases. A continuación se describe el método se separación no lineal.

5.3.2. MSVs NO LINEALES

Cuando los datos no son linealmente separables, se procede a utilizar transformaciones a un espacio de orden mayor donde si es posible hacer la separación lineal por medio de hiperplanos. Esta transformación se realiza con una función Kernel (Φ) [Vapnik, 95], la cual realiza la clasificación lineal sobre vectores transformados a un espacio de dimensión superior conocido como espacio característico F (mapea los datos de entrada $\vec{x}_i \in \mathfrak{R}^N$ de un espacio a otro), es decir, separa las clases mediante un hiperplano en el espacio transformado (ver Figura 55).

Figura 55 Transformación de espacio para la separación lineal utilizando la función kernel.



Fuente: [Shawe & Cristianini, 00]

La construcción de una MSV no lineal, necesita de una función kernel para la transformación a otro espacio. Las funciones kernels más utilizadas son:

Kernel Polinomial:

$$k(\vec{x}, \vec{y}) = ((\vec{x} \cdot \vec{y}) + c)^d \text{ para } c > 0 \quad (36)$$

Función de base radial (RBF):

$$k(\vec{x}, \vec{y}) = e^{\left(-\frac{|\vec{x} - \vec{y}|^2}{2\sigma^2} \right)^d} \quad (37)$$

Sigmoide:

$$k(\vec{x}, \vec{y}) = \tanh(k(\vec{x} \cdot \vec{y}) + \theta) \quad (38)$$

En este trabajo se utiliza el *kernel* RBF por su buen desempeño según estudio realizado por [Campos & Suárez, 07] a diferentes tipos de patrones, incluyendo los obtenidos en [Vega, 04] para patrones de perturbaciones de la calidad de la energía eléctrica obtenidos a partir de la transformada *wavelet* y por los resultados obtenidos en el numeral 5.4.

Hasta el momento sólo se ha mencionado el problema de clasificación de dos clases, cuando existe un número mayor, es necesario emplear métodos que permitan desarrollar esta labor a partir de la biclasificación como se explica a continuación.

5.3.3. Multiclasificación utilizando SVM

El problema tratado hasta ahora, se basa en la biclasificación, es decir, las clases sólo pueden tener la etiqueta ± 1 . En la realidad la mayoría de los problemas a resolver, poseen un número superior a dos clases ($y_i \in \{1, \dots, l\}$, $l > 2$). En la multiclasificación con máquinas de vectores de soporte se admiten dos tipos de arquitectura para resolver este problema: las máquinas multiclasificadoras y las máquinas biclasificadoras generalizadas.

5.3.3.1. Máquinas multiclasificadoras

Esta máquina está constituida por una función clasificadora global que considera todas las posibles clases a la vez. Este tipo de solución requiere gran cantidad de procesamiento computacional, en la actualidad no se han presentado técnicas que mejoren la robustez del sistema, ni un estudio teórico sobre la cota de error [Angulo, 01].

5.3.3.2. Máquinas biclasificadoras generalizadas.

Este tipo de máquina utiliza un conjunto de funciones biclasificadoras para construir una función clasificadora global. Para esto emplea técnicas de descomposición y de reconstrucción que permiten a las MSV biclasificadoras manejar problemas de multiclasificación con mayor simplicidad y/o menor tiempo de respuesta que una MSV generalizada de multiclasificación [Morales & Gómez, 05].

En el estudio se utilizaron las máquinas biclasificadoras generalizadas por su simplicidad y velocidad de cómputo. Por lo tanto se hace necesaria la presentación de los métodos de descomposición y de reconstrucción necesarios para la multiclasificación.

5.3.4. Métodos de descomposición estándares

El esquema de descomposición estándar está constituido por m máquinas biclasificadoras en paralelo, que son entrenadas y modificadas durante el proceso de aprendizaje, obteniéndose al final una matriz de descomposición. Algunos de estos elementos pertenecientes a determinada clase, tendrán asignados valores positivos en las salidas, otros por el contrario tendrán salidas con valores negativos, y puede darse el caso que los restantes elementos no sean tenidos en cuenta en dicho clasificador. A continuación se presentan tres métodos de descomposición muy conocidos [Morales & Gómez, 05].

5.3.4.1. Uno contra el resto:

Conocido como 1-v-r (de su sigla en inglés *one-versus-rest*). Este esquema se basa en la idea de que si existe un grupo de n datos de entrenamiento donde existen l clases ($l > 2$), se puede tener un grupo de m clasificadores binarios (donde $m = l$), cada uno entrenado para separar una clase del resto de clases existentes ($l - 1$). La descomposición se realiza de la siguiente manera: existe un grupo de datos (n_j) que pertenecen a la j -ésima clase ($j \in \{1 \dots l\}$), a los cuales se les dará una etiqueta positiva ($t_j = +1$) y al resto de datos ($n_r = n - n_j$) se les dará una etiqueta negativa ($t_r = -1$) para el entrenamiento de la i -ésima MSV. Así se crea una matriz de descomposición (D_{1-v-r}) de m filas y l columnas:

$$D_{i,j} = \begin{cases} +1 & \text{si } n_h \in n_j \\ -1 & \text{si } n_h \in n_r \end{cases} \quad (39)$$

Por ejemplo, una máquina de clasificación multiclase (1-v-r) con $l = 5$, se obtiene $m = 5$. Entonces la correspondiente matriz de descomposición es la siguiente:

$$D_{1-v-r} = \begin{pmatrix} +1 & -1 & -1 & -1 & -1 \\ -1 & +1 & -1 & -1 & -1 \\ -1 & -1 & +1 & -1 & -1 \\ -1 & -1 & -1 & +1 & -1 \\ -1 & -1 & -1 & -1 & +1 \end{pmatrix} \quad (40)$$

En [Cortes & Vapnik, 95] y [Vapnik, 95] se propone esta arquitectura. El tiempo de entrenamiento es proporcional al número de clases y debido a que el entrenamiento de cada biclasificador se realiza con todo conjunto de datos de entrenamiento, su costo computacional es alto [Morales & Gómez, 05].

5.3.4.2. Uno contra uno:

Es conocido como OVO ó 1-v-1 (del inglés *one-versus-one*), se realiza implementando $m = \frac{l(l-1)}{2}$ clasificadores binarios. Luego, el entrenamiento de la i -ésima MSV se realiza con sólo 2 de las l ($l > 2$) clases existentes en el grupo de n datos de entrenamiento, otorgándole etiqueta positiva ($t_j = +1$) a los datos (n_j) que pertenecen al subgrupo de datos de la clase j ($j \in \{1, \dots, l\}$), y etiqueta negativa ($t_p = -1$) a los datos (n_p) que pertenecen al subgrupo de datos de la clase p ($p \in \{1, \dots, l\}$ y $p \neq j$). Los demás datos ($n_r = n - n_j - n_p$) no se utilizan en el entrenamiento de la i -ésima MSV, por lo tanto, son etiquetados con cero ($t_r = 0$), creándose la matriz de descomposición (D_{1-v-1}), [Martínez W & Martínez A, 02].

$$D_{i,j} = \begin{cases} +1 & \text{si } n_h \in n_j \\ -1 & \text{si } n_h \in n_p \\ 0 & \text{si } n_h \in n_r \end{cases} \quad (41)$$

Por ejemplo, para una máquina de clasificación multiclase (1-v-1) con $l = 5$, se obtiene $m = 10$. Entonces la correspondiente matriz de descomposición es la siguiente:

$$D_{1-v-1} = \begin{pmatrix} +1 & -1 & 0 & 0 & 0 \\ +1 & 0 & -1 & 0 & 0 \\ +1 & 0 & 0 & -1 & 0 \\ +1 & 0 & 0 & 0 & -1 \\ 0 & +1 & -1 & 0 & 0 \\ 0 & +1 & 0 & -1 & 0 \\ 0 & +1 & 0 & 0 & -1 \\ 0 & 0 & +1 & -1 & 0 \\ 0 & 0 & +1 & 0 & -1 \\ 0 & 0 & 0 & +1 & -1 \end{pmatrix} \quad (42)$$

5.3.4.3. Arquitectura de descomposición ECOC:

La técnica ECOC (de sus siglas en inglés *Error Correcting Output Codes*) utiliza la codificación estándar para obtener robustez contra fallas en las máquinas biclasificadoras [Dietterich & Bakiri, 95]. Se ha denominado codificación

estándar a cada una de las posibles particiones de todo el conjunto de clases $Y_i \in \{1, \dots, l\}$, en problemas de biclasificación, que asignan etiquetas positivas $t_p = +1$ a los patrones de entrenamiento n_j de un cierto subconjunto de clases Y_j , y etiquetas negativas $t_p = -1$ a los patrones de entrenamiento n_r representantes del resto de clases Y_r . La de descomposición generada por [Morales & Gómez, 05]:

$$D_{i,j} = \begin{cases} +1 & \text{si } n_h \in n_j \\ -1 & \text{si } n_h \in n_r \end{cases} \quad (43)$$

debe ser tan diferente como sea posible en términos de la distancia Hamming para añadir redundancia, en este caso $m = 2^{l-1} - 1$. Por ejemplo, para una máquina de clasificación multiclase (ECOC) con $l = 4$, se obtiene $m = 7$. Entonces la correspondiente matriz de descomposición es la siguiente:

$$D_{ECOC} = \begin{pmatrix} +1 & -1 & -1 & -1 \\ +1 & -1 & -1 & +1 \\ +1 & -1 & +1 & -1 \\ +1 & -1 & +1 & +1 \\ +1 & +1 & -1 & -1 \\ +1 & +1 & -1 & +1 \\ +1 & +1 & +1 & -1 \end{pmatrix} \quad (44)$$

5.3.5. Métodos de reconstrucción

Cada máquina biclasificadora entrenada emite una respuesta en forma numérica $z^i = g_i(\vec{x})$ a una entrada \vec{x} . La información más importante en esta respuesta, en principio, se encuentra en el signo $s^i = f_i(\vec{x}) = \text{sign}(g_i(\vec{x}))$ que adopta la función de decisión. En la determinación de la respuesta final facilitada por el método de reconstrucción de la máquina de aprendizaje multiclase han de ser tomados en consideración los siguientes elementos [Morales & Gómez, 05]:

- Las predicciones numéricas parciales de los nodos de dicotomía, $z^i = g_i(\vec{x})$.
- El signo de las predicciones numéricas, $s^i = f_i(\vec{x}) = \text{sign}(g_i(\vec{x}))$.
- Un elemento intérprete de las predicciones numéricas y binarias, $\Theta(z^i, s^i)$, con el fin de asignar o no, una o varias clases como posible respuesta de clasificación a una entrada \vec{x} .

- Un elemento $\Psi(\Theta(z^1, s^1), \dots, \Theta(z^m, s^m))$ de combinación de las predicciones, que tenga o pueda tener en consideración las predicciones numéricas, sus signos y/o la clase o clases asignadas.

Esquemas de votación: son la forma de reconstrucción más habitual. Se tiene en consideración sólo el signo de las predicciones de todas las máquinas biclasificadoras. Estos signos son interpretados en función de las clases implicadas en las máquinas biclasificadoras utilizadas en el esquema de descomposición.

1. i-ésimo 1-v-r máquina biclasificadora

$$\Theta(s^i) = \begin{cases} y_i & si & s^i = +1 \\ 0 & si & s^i = -1 \end{cases} \quad (45)$$

2. i-ésimo 1-v-1 máquina biclasificador

$$\Theta(s^i) = \begin{cases} y_i & si & s^i = +1 \\ y_p & si & s^i = -1 \end{cases} \quad (46)$$

3. i-ésimo ECOC máquina biclasificadora

$$\Theta(s^i) = \begin{cases} Y_i & si & s^i = +1 \\ Y_r & si & s^i = -1 \end{cases} \quad (47)$$

Tras la interpretación de las predicciones, el elemento de combinación realiza un recuento del número de clases votadas, acción de la que toma el nombre de esquema de reconstrucción, que posee diferentes variantes. Se definen a continuación algunas de estas posibilidades para las arquitecturas de descomposición:

- × **Votación por unanimidad:** se determina como respuesta aquella única clase que haya obtenido todos los votos posibles en las predicciones.
- × **Votación por mayoría absoluta:** se determina como respuesta final aquella única clase que haya obtenido más de la mitad de los votos posibles.
- × **Votación por mayoría simple:** se determina como respuesta final aquella única clase que haya obtenido más votos que el resto de clases.

Finalmente para entrenar el modelo a utilizar para la clasificación, es necesario emplear un método para seleccionar los mejores parámetros C y sigma para el kernel RBF. Para esto se emplea el método de validación cruzada, que permite por medio de iteraciones obtener los mejores valores requeridos a partir de pruebas con descriptores específicos. Por supuesto hay que definir también el

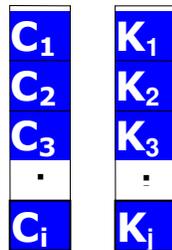
método de descomposición y de reconstrucción para el entrenamiento de la MSV.

5.3.6. Validación Cruzada en la MSV

La validación cruzada es una técnica que se utiliza para tratar problemas iterativos repartiendo la muestra en dos sistemas de datos, uno se utiliza para construir el modelo, y el otro para probarlo. Esta técnica incorporada en el entrenamiento de la MSV, se utiliza para seleccionar los mejores parámetros (parámetros del *kernel* y de penalización C) de la MSV para un grupo específico de datos [Martínez W & Martínez A, 02].

El procedimiento que se explica a continuación se realiza para cada pareja de parámetros (estas parejas se forman con todas las combinaciones posibles de los parámetros del *kernel* y C), (ver Figura 56).

Figura 56 Representación de las parejas de parámetros del kernel y del C



Numero de combinaciones: $i*j$

Fuente: [Campos & Suárez, 07]

Los datos de entrenamiento se dividen en N grupos (o partes) de forma aleatoria, se escoge el primer grupo como grupo de validación y con las restantes partes se forma el grupo de entrenamiento, como se muestra en la Figura 57.

Figura 57 Conformación de grupos o partes.

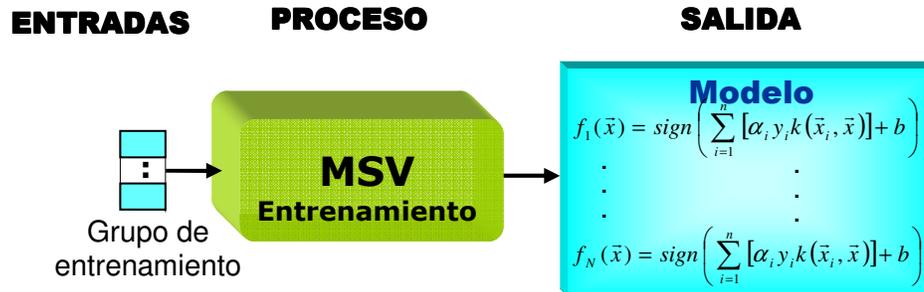


Fuente: [Campos & Suárez, 07]

Con el grupo de entrenamiento se entrena la primera máquina obteniéndose un modelo, véase la Figura 58. Con este modelo se clasifica el grupo de validación, esta clasificación se compara con las verdaderas etiquetas que le corresponden a estos datos, hallándose un resultado de exactitud a la que se llamará exactitud 1,

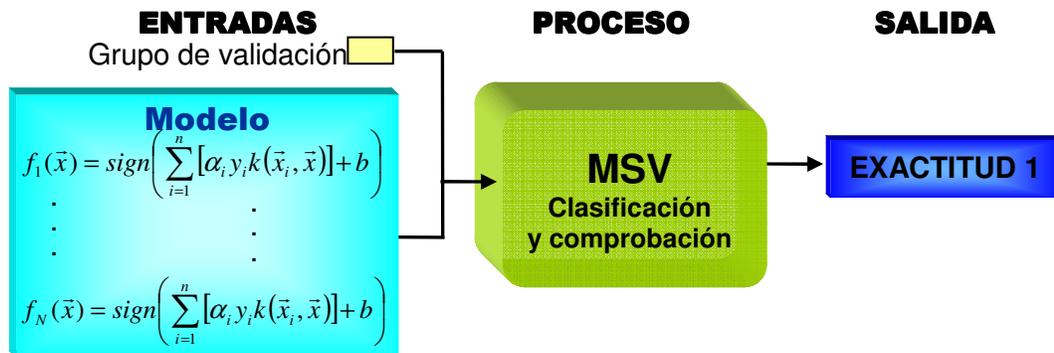
(ver Figura 59).

Figura 58 Entrenamiento con el primer grupo de datos



Fuente: [Campos & Suárez, 07]

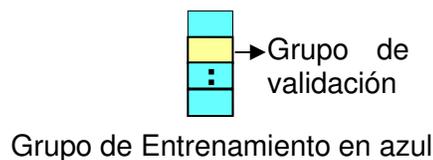
Figura 59 Clasificación y exactitud utilizando el grupo de validación



Fuente: [Campos & Suárez, 07]

Seguidamente se selecciona el segundo grupo como grupo de prueba y los restantes datos serán ahora grupo de entrenamiento (ver Figura 60) con los cuales se entrena otra máquina. Con el nuevo modelo obtenido se clasifica el grupo de validación, hallando la exactitud la cual será llamada exactitud 2. Este procedimiento se realiza con los N grupos.

Figura 60 Formación de los segundos grupos (entrenamiento y validación)

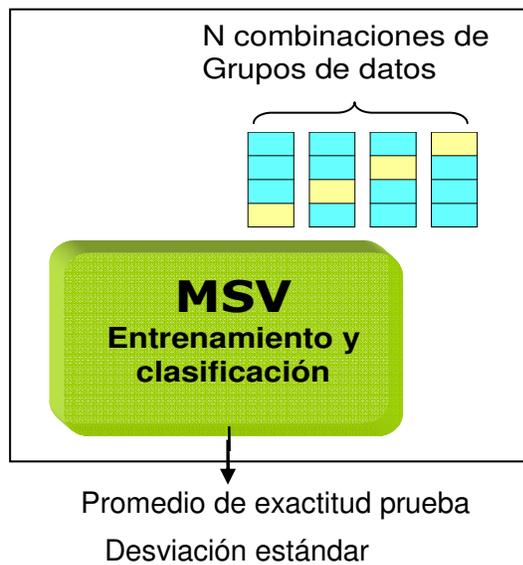


Fuente: [Campos & Suárez, 07]

Finalmente se tienen N resultados de exactitud a los cuales se les calcula su promedio y su desviación estándar como se indica en la Figura 61. Estos dos valores son los que servirán posteriormente para comparar entre si los resultados obtenidos para cada pareja de parámetros.

Después de la validación se tendrán tantos valores promedio de exactitud y desviación estándar como pares de parámetros que se haya entrenado, los parámetros que correspondan a la mayor exactitud serán los mejores y si hay un empate se desempata con la menor desviación estándar, esto se hace para garantizar que la pareja de parámetros escogidos sea estable, de persistir el empate se optará por escoger la máquina con el mayor valor de C, ya que éste indica una mayor penalización a los errores.

Figura 61 Resultados de la primera pareja de parámetros



Fuente: [Campos & Suárez, 07]

A continuación se hace una explicación ejemplificada de la validación cruzada en la MSV.

- **Ejemplo de validación cruzada**

En este ejemplo se mostrará la forma de utilizar la validación cruzada para resolver un problema simbólico:

Se desea encontrar la mejor pareja de parámetros para una clase específica de datos, se cuenta con 500 muestras y se busca probar 3 parámetros (uno del kernel y dos de C) estos serán llamados $K = (k_1)$ y $C = (c_1, c_2)$, los datos se dividirán en 5 grupos (G_1, G_2, G_3, G_4 y G_5).

De esta forma se tendrán dos parejas de parámetros (k_1, c_1) y (k_1, c_2) , los 5

grupos tendrán 100 datos cada uno, por lo cual quedaran 400 datos de entrenamiento y 100 de validación.

Para la iteración 1

Para (k1, c1)		exactitud de prueba
Máquina 1	Se entrena con (G2, G3, G4 y G5) se prueba con (G1)	0,8
Máquina 2	Se entrena con (G1, G3, G4 y G5) se prueba con (G2)	0,8
Máquina 3	Se entrena con (G1, G2, G4 y G5) se prueba con (G3)	0,9
Máquina 4	Se entrena con (G1, G2, G3 y G5) se prueba con (G4)	0,5
Máquina 5	Se entrena con (G1, G2, G3 y G4) se prueba con (G5)	0,7

Exactitud promedio 0,74
Desviación estándar 0,157

Ahora para la iteración 2

Para (k1, c2)		exactitud de prueba
Máquina 6	Se entrena con (G2, G3, G4 y G5) se prueba con (G1)	0,7
Máquina 7	Se entrena con (G1, G3, G4 y G5) se prueba con (G2)	0,4
Máquina 8	Se entrena con (G1, G2, G4 y G5) se prueba con (G3)	0,9
Máquina 9	Se entrena con (G1, G2, G3 y G5) se prueba con (G4)	0,5
Máquina 10	Se entrena con (G1, G2, G3 y G4) se prueba con (G5)	0,7

Exactitud promedio 0,64
Desviación estándar 0,194

Como se puede apreciar el número de máquinas entrenadas es igual a la cantidad de parámetros del kernel (K) multiplicada por los parámetros de penalización C y por el número de partes, en este caso $1 \times 2 \times 5 = 10$.

Los resultados muestran a la pareja (k1, c1) como los mejores parámetros. Si se hubiese presentado un empate, se decidiría por la menor desviación en este caso 0,157 de la iteración 1. De persistir el empate se selecciona el mayor valor de C.

Pruebas realizadas en [Campos & Suárez, 07] muestran que el número de partes o grupos en que se dividen los datos determina en gran parte la calidad del resultado, un análisis simple determina que si se escogen demasiados grupos, el grupo de prueba quedará proporcionalmente con muy pocos datos, por lo que su validación no será suficientemente confiable. En el caso contrario, si se escogen pocos grupos los datos de entrenamiento serán insuficientes para hacer una buena predicción. Por esto se recomienda que el número de partes para realizar la validación cruzada sea 4 o 5, es decir, con un 20 a 25% de los datos para prueba y el restante 75 a 80% para entrenamiento.

A continuación se presentan los resultados de las simulaciones realizadas.

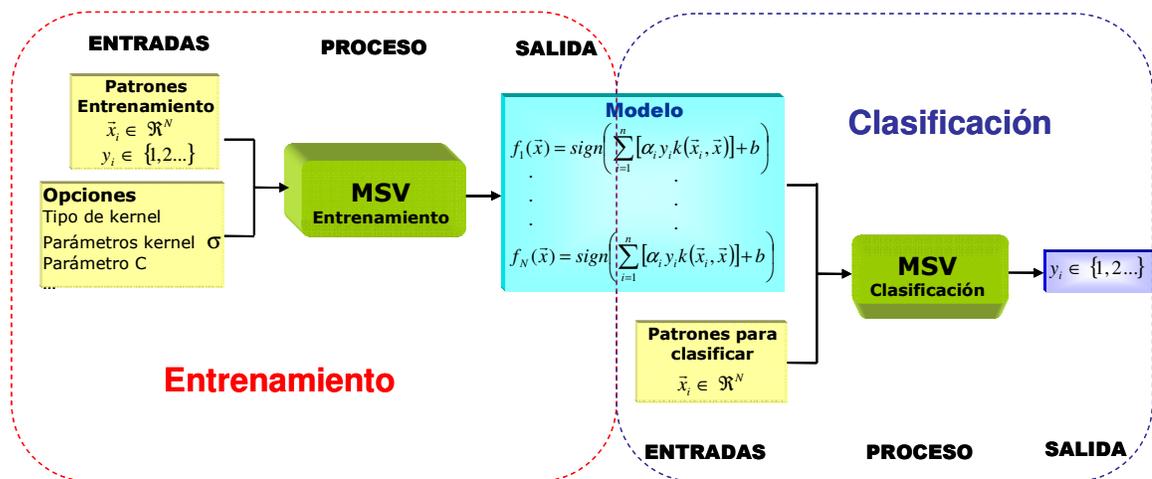
5.4. RESULTADOS DE SIMULACIÓN UTILIZANDO MSV

En esta sección se presentan los valores de los parámetros utilizados en las simulaciones y los resultados que se obtienen al clasificar perturbaciones de la calidad de la energía a partir de patrones extraídos con la técnica de identificación del Capítulo 4. En el Anexo C se presenta el resultado de la clasificación de un grupo de patrones obtenidos en [Vega, 04] con diferentes herramientas de clasificación, siendo la técnica MSV la más efectiva.

Para generar un modelo capaz de clasificar patrones de forma automática es necesario tener en cuenta los parámetros que hacen parte de la MSV, los tipos de datos de entrada y la forma como se evalúa la máquina para encontrar su óptimo rendimiento (exactitud para clasificar).

En la Figura 62 , se presenta el esquema utilizado para entrenamiento y clasificación de la MSV. Los datos utilizados en las simulaciones de este proceso se describe a continuación.

Figura 62 Entrenamiento y clasificación de la MSV



Fuente: [Campos & Suárez, 07]

Entrenamiento: en la etapa de entrenamiento se quiere encontrar el mejor modelo que clasifique correctamente un nuevo conjunto de datos. Para ello, se debe seleccionar el conjunto de datos a analizar, un tipo de función *kernel*, el método de descomposición y el método de optimización. Luego se procede a encontrar los respectivos parámetros de *kernel* y el valor del parámetro de penalización C adecuado mediante el esquema de validación cruzada.

Primero se eligen o adquieren los patrones a clasificar, para nuestro caso particular son los 3 grupos de patrones obtenidos en el Capítulo 4. Cada grupo consta de 2500 de patrones con 500 para cada perturbación y por supuesto

cada uno con su dimensión (número de descriptores) como se presenta en la Tabla 26. Las perturbaciones serán llamadas en este capítulo como clases y son:

- ✓ La clase 1, corresponde a los huecos de tensión (*sags*)
- ✓ La clase 2, corresponde a las elevaciones de tensión (*swells*)
- ✓ La clase 3, corresponde a los transitorios oscilatorios
- ✓ La clase 4, corresponde a las fluctuaciones de tensión (*flicker*)
- ✓ La clase 5, corresponde a los armónicos

Tabla 26 Características de los patrones obtenidos en el Capítulo 4.

Tipo de patrón	Cantidad total	Cantidad / Clase	Dimensión	Características
Patrón 1	2500	500	7	Diferencias de la energía de coeficientes <i>Wavelet</i>
Patrón 2	2500	500	8	Energía de la perturbación a partir de coeficientes <i>Wavelet</i> y valor eficaz
Patrón 3	2500	500	9	Cálculo de la energía de la señal diferencia y valor eficaz

Fuente: Elaborada por el autor.

A partir del trabajo realizado en [Campos & Suárez, 07] (trabajo de pre-grado asociado a esta investigación) y utilizando la herramienta computacional para el entrenamiento y clasificación de patrones desarrollada por estos autores (MSV toolbox1.0), se obtienen los siguientes parámetros a partir de pruebas realizadas a los 3 grupos patrones obtenidos en el Capítulo 4.

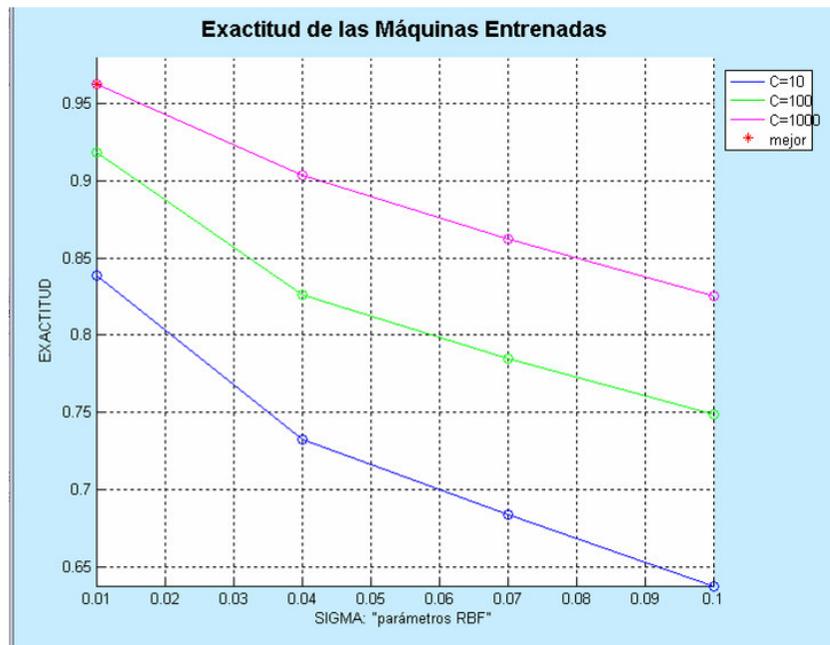
Con cada grupo de patrones se le realizó el siguiente procedimiento y se obtuvieron los resultados que se presentan a continuación:

1. El grupo de patrones se divide en dos grupos: un grupo de entrenamiento y otro de validación. Esto con el fin de entrenar la máquina y calcular los porcentajes de exactitud de la misma.
2. Para realizar el entrenamiento es necesario dividir el grupo de datos de entrenamiento en 5 partes para utilizar la técnica de validación cruzada, como se explicó en la sección anterior, y se procede con la búsqueda en malla, para lo cual se definen los rangos de valores del parámetro C (de 2 hasta 2^{30}) y el parámetro kernel σ (10^{-3} hasta 1). Estas pruebas fueron desarrolladas en [Campos & Suárez, 07]. La función kernel RBF fue la de mejor desempeño para este tipo de patrones.

- El método de optimización elegido fue el SMO (Optimización secuencial mínima) por su sencillez y por arrojar buenos resultados en las pruebas realizadas en [Campos & Suárez, 07]. De igual forma el método de descomposición más adecuado fue el OVO (uno contra uno). En la Tabla 27 están resumidas las anteriores características.

En la Figura 63 se representa un ejemplo de la búsqueda en malla utilizando la validación cruzada, siendo la mejor exactitud de entrenamiento 95,1%, parámetro $C = 1000$ y $\sigma = 0,01$.

Figura 63 Exactitud de entrenamiento de una MSV



Fuente: Realizada por el autor

La Figura 63 es realizada con el módulo de "validación cruzada" de la MSVtoolbox1.0. Es necesario resaltar este aporte del trabajo realizado en [Campos & Suárez, 07], ya que esta gráfica facilita la búsqueda del parámetro C y del parámetro σ .

Tabla 27 Características de los parámetros utilizados en el entrenamiento y validación.

Datos Entrenamiento	Datos validación	Partes	Clases	Función kernel	Intervalo σ	Intervalo C	Método optimización	Tole-rancia	Método descompo.
500	500	5	5	RBF	$[10^{-3} - 1]$	$[2^{-230}]$	SMO	0,001	OVO

Fuente: elaborada por el autor.

De las pruebas realizadas con la herramienta desarrollada por [Campos & Suárez, 07] se obtuvieron diferentes modelos de MSV con los siguientes parámetros C y σ , error de validación y número de vectores de soporte utilizados, como se presentan en la Tabla 28.

Tabla 28 Modelos de MSV obtenidos para diferentes valores de parámetros C y σ utilizando los tres grupos de patrones.

Modelo	Grupo de Patrón	Parámetro σ	Parámetro C	Exactitud de entrenamiento	Vectores de Soporte
Modelo 1	Patrón 1	0,03	17	72%	399
	Patrón 2	0,03	17	100%	122
	Patrón 3	0,03	17	81%	311
Modelo 2	Patrón 1	0,03	1024	90%	222
	Patrón 2	0,03	1024	100%	122
	Patrón 3	0,03	1024	95%	160
Modelo 3	Patrón 1	0,5	2048	61%	370
	Patrón 2	0,5	2048	100%	41
	Patrón 3	0,5	2048	76%	303
Modelo 4	Patrón 1	0,7071	2^{22}	93%	164
	Patrón 2	0,7071	2^{22}	100%	35
	Patrón 3	0,7071	2^{22}	98%	76

Fuente: Elaborada por el autor.

A partir de la Tabla 28 se tiene que la mayor exactitud de entrenamiento se obtiene con el patrón 2 con un 100%. Se puede proponer el mejor modelo como el 4 si se tiene en cuenta el menor número de vectores de soporte.

A continuación se presenta en la Tabla 29, Tabla 30 y Tabla 31 los resultados obtenidos de la validación de las MSV con 500 perturbaciones (100 para cada clase) y 1500 perturbaciones utilizadas para la prueba de los patrones 1, 2 y 3 respectivamente.

Tabla 29 Porcentajes de acierto para validación (500 perturbaciones) y para prueba (1500 perturbaciones) utilizando el patrón 1.

Perturbación	Modelo 1		Modelo 2		Modelo 3		Modelo 4	
	Valida.	Prueba	Valida.	Prueba	Valida.	Prueba	Valida.	Prueba
<i>Sag</i>	68	63	86	87	36	38	86	85
<i>Swell</i>	81	74	82	80	80	80	96	97
Trans	24	21	68	66	17	17	78	76
<i>Flicker</i>	100	100	99	100	100	100	100	100
Armónico	69	68	58	90	64	95	59	100

Fuente: Elaborada por el autor.

Tabla 30 Porcentajes de acierto para validación (500 perturbaciones) y para prueba (1500 perturbaciones) utilizando el patrón 2.

Perturbación	Modelo 1		Modelo 2		Modelo 3		Modelo 4	
	Valida.	Prueba	Valida.	Prueba	Valida.	Prueba	Valida.	Prueba
<i>Sag</i>	100	99	100	100	100	99	100	100
<i>Swell</i>	99	96	98	96	98	97	99	98
Trans	100	99	100	99	100	100	100	100
<i>Flicker</i>	100	100	100	100	100	100	100	100
Armónico	100	34	100	33	100	100	100	100

Tabla 31 Porcentajes de acierto para validación (500 perturbaciones) y para prueba (1500 perturbaciones) utilizando el patrón 3.

Perturbación	Modelo 1		Modelo 2		Modelo 3		Modelo 4	
	Valida.	Prueba	Valida.	Prueba	Valida.	Prueba	Valida.	Prueba
<i>Sag</i>	92	91	94	93	90	88	96	96
<i>Swell</i>	82	84	92	96	80	81	94	95
Trans	35	33	83	83	23	22	93	94
<i>Flicker</i>	100	100	100	100	100	100	100	100
Armónico	67	100	72	100	67	100	74	100

Fuente: elaborada por el autor.

Efectivamente el patrón 2 presenta el mayor porcentaje de acierto junto con el mejor modelo que es el 4 (con parámetro $C=0,707$ y Parámetro $\sigma=2^{22}$), a partir de las pruebas realizadas para 500 y 1500 perturbaciones (Tabla 30).

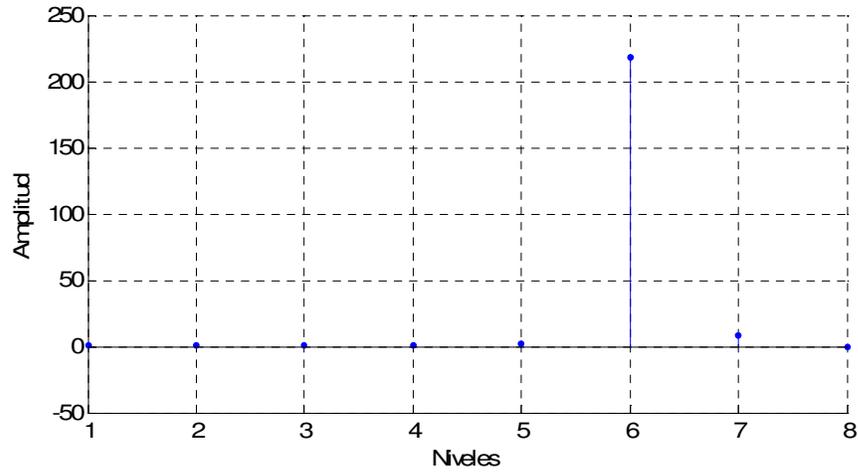
En la prueba controlada realizada a los datos de validación (500 perturbaciones) del patrón 2 utilizando el modelo 4, se tiene que el elemento mal clasificado es *swell*, el cual fue confundido por un transitorio como se presenta en la Tabla 32 y la representación del patrón en la Figura 64.

Tabla 32 Clasificación de las cantidades de patrones según su correspondencia, en la prueba controlada para 500 datos.

	Sag	Swell	Transitorio	Flicker	Armónico
Sag	100	0	0	0	0
Swell	0	99	1	0	0
Transitorio	0	0	100	0	0
Flicker	0	0	0	100	0
Armónico	0	0	0	0	100

Fuente: elaborada por el autor.

Figura 64 Patrón swell mal clasificado



Fuente: elaborada por el autor.

Tabla 33 Clasificación de las cantidades de patrones según su correspondencia, en la prueba controlada para 1500 perturbacones.

	Sag	Swell	Transitorio	Flicker	Armónico
Sag	300	0	0	0	0
Swell	3	295	2	0	0
Transitorio	0	0	300	0	0
Flicker	0	0	0	300	0
Armónico	0	0	0	0	300

Fuente: elaborada por el autor.

En presencia de ruido el comportamiento del patrón 2 con el modelo 4 (utilizando 1500 perturbaciones de prueba) para SNR de 20, 40 y 60 decibeles es presentado en la Tabla 34.

Tabla 34 Porcentajes de acierto para 1500 perturbaciones de prueba utilizando el patrón 2 y el modelo 4 en presencia de ruido con SNR de 20,40 y 60 decibeles.

Perturbación	Modelo 4		
	SNR 20dB	SNR 40dB	SNR 60dB
Sag	99	100	100
Swell	95	98	98
Transitorio	95	100	100
Flicker	100	100	100
Armónico	71	100	100

Fuente: elaborada por el autor.

Es de notar que la clasificación del patrón 2 es inmune al ruido cuando la SNR es de 40 y 60 decibeles utilizando el modelo 4. Para una SNR de 20 dB el porcentaje de acierto disminuye considerablemente en un 29% para el armónico. Por el contrario el *flicker* mantiene el porcentaje de acierto y el resto de perturbaciones disminuyen entre un 1% y un 5% de su porcentaje de acierto.

5.5. CONSIDERACIONES FINALES

Se ha presentado en este capítulo el estado del arte en la clasificación, principalmente en lo relacionado con perturbaciones de la calidad de la energía. Se ha presentado también la información necesaria para entender el funcionamiento de la técnica de clasificación Máquina de soporte Vectorial, donde se detallan las ecuaciones, parámetros y principales características de la misma.

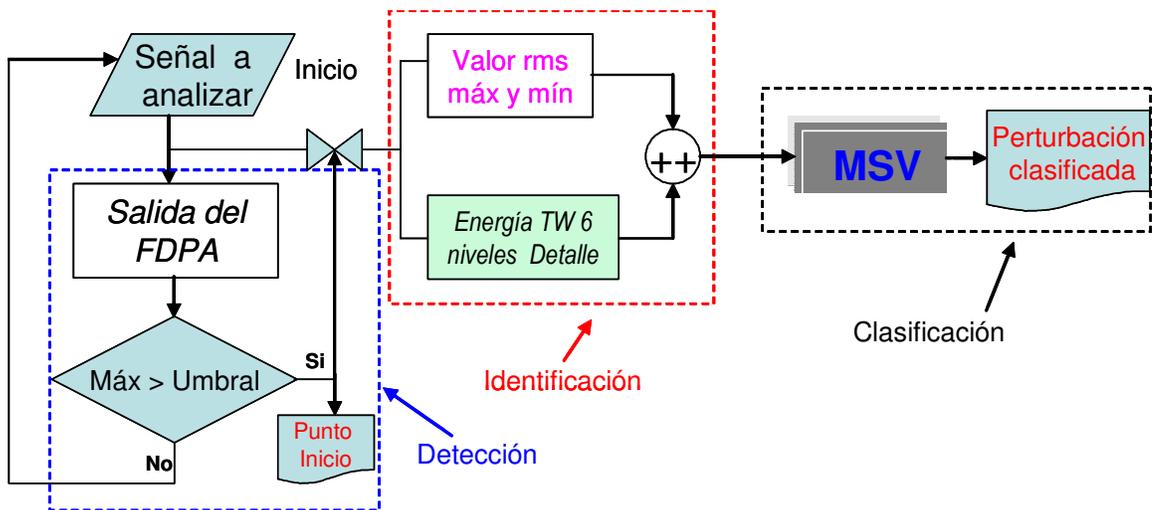
A partir de simulaciones utilizando la herramienta computacional MSVtoolbox1.0 desarrollada por [Campos & Suárez, 07], se obtuvieron diferentes parámetros de penalización C y de kernel σ adecuados, con los cuales fue posible generar un modelo MSV capaz de clasificar con un porcentaje de acierto del 100% para todas las perturbaciones excepto una (swell con 98%) para el conjunto de perturbaciones utilizadas en la prueba. También fue posible a partir de estas simulaciones definir cuál de los tres tipos de patrones propuestos en el Capítulo 4 es adecuado para identificar mejor las perturbaciones analizadas en esta investigación (Patrón 2).

Como producto final está la herramienta de clasificación MSVtoolbox1.0 que hace parte de esta investigación y fue desarrollada por [Campos & Suárez, 07] principalmente para clasificar perturbaciones de la calidad de la energía. Esta herramienta tiene la posibilidad de realizar búsquedas de los parámetros de la MSV, de crear un modelo MSV y de clasificar otros tipos de patrones diferentes a los ya mencionados.

6. IMPLEMENTACIÓN DE LA ESTRATEGIA DE DETECCIÓN, IDENTIFICACIÓN Y CLASIFICACIÓN DE PERTURBACIONES

En este capítulo se concatenan las anteriores tres técnicas utilizadas para la detección, identificación y clasificación de perturbaciones que afectan la calidad de la energía. En la Figura 65 se describe en un diagrama de bloques el funcionamiento de la estrategia conjunta.

Figura 65 Esquema de la estrategia de detección, identificación y clasificación.



Fuente: elaborada por el autor.

A continuación se explica en detalle el funcionamiento de los bloques que hacen parte de la estrategia conjunta.

- ✓ **Señal a analizar:** contiene 8 ciclos de señal (posible perturbación) que van a ser procesados.
- ✓ **Salida del FDPA:** Este bloque calcula la convolución entre la posible perturbación y la respuesta al impulso del filtro de descomposición pasa-altas asociado a la función *wavelet* bior 3.9.
- ✓ **Máx > umbral:** Calcula el valor máximo de la magnitud de la salida de FDPA y lo compara con el umbral establecido. Si la respuesta es no, vuelve al inicio y toma otra señal a analizar. Si la respuesta es si, significa que efectivamente existe una perturbación y permite que la señal a analizar, pase al siguiente bloque (identificación).
- ✓ **Energía TW 6 niveles Detalle:** Este bloque calcula la transformada *Wavelet* hasta 8 niveles de descomposición de detalle. Luego se calcula la energía de los coeficientes de detalle obtenidos. El resultado es un vector de 6 posiciones.

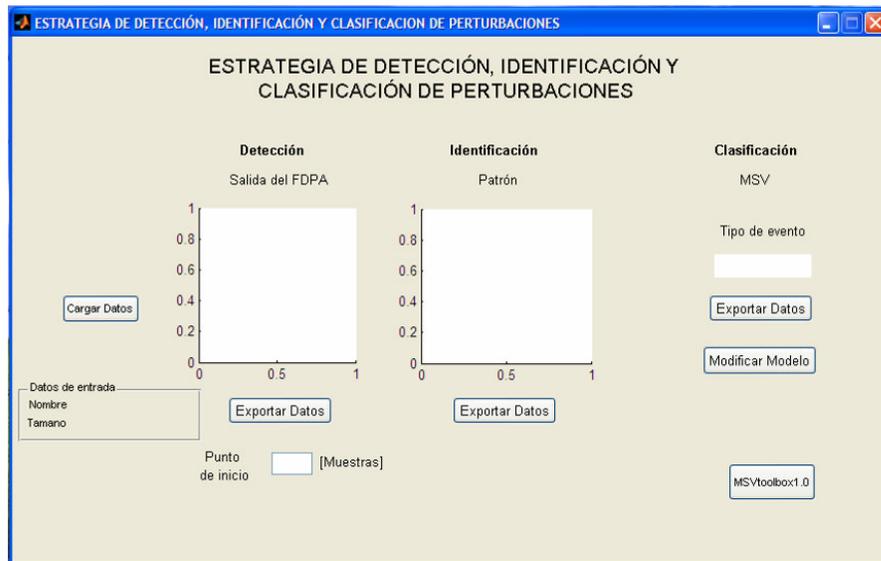
- ✓ **Valor rms máx y mín:** Son los valores RMS máx y RMS mín obtenidos en la sección 4.2 y son:
 1. RMS máx, la diferencia entre el valor RMS máximo obtenido de la perturbación y el valor RMS promedio del pre-evento.
 2. RMS mín, la diferencia entre el valor RMS mínimo obtenido de la perturbación y el valor RMS promedio del pre-evento (RMS mín).

Ambos elementos son multiplicados por el valor máximo del vector de energías resultante de los 6 niveles de descomposición.

- ✓ **El símbolo $\oplus\oplus$:** realiza la concatenación del vector de 6 posiciones proveniente del bloque "Energía TW 6 niveles Detalle" con los dos valores que arroja el bloque "Valor rms máx y mín". El resultado es un vector patrón de 8 elementos.
- ✓ **MSV:** este bloque evalúa el vector patrón de 8 elementos a partir de un modelo de multclasificación previamente seleccionado y como resultado arroja un número entre 1 y 5 correspondiente a una perturbación.
- ✓ **Perturbación clasificada:** este bloque relaciona el valor numérico obtenido en la clasificación con el nombre de la perturbación.

La estrategia conjunta se ha implementado como una herramienta computacional que opera de forma sencilla. En la Figura 66 se presenta la interfaz de la aplicación software. En ella se encuentran las siguientes partes:

Figura 66 Herramienta computacional: estrategia de detección, identificación y clasificación.



Fuente: elaborada por el autor.

- 1. Botón Cargar Datos:** Por medio de este botón se carga el archivo *.mat que contiene una matriz de dimensión NxM (N filas y M columnas) donde la primera columna es el vector de tiempo y el resto son las señales a analizar.
- 2. Datos de entrada:** en este panel se imprimen el nombre del archivo seleccionado y el tamaño del vector.
- 3. Salida del FDPA:** Aquí se grafica la salida del FDPA de la primera señal del conjunto de datos a analizar. El botón "Exportar Datos" permite exportar la matriz obtenida (en formato .mat) a partir de cada una de las salidas del FDPA para cada señal.
- 4. Punto de Inicio:** se imprime el valor en muestras del instante donde inicia la perturbación en muestras.
- 5. Patrón:** En esta gráfica se observan las características del patrón de la perturbación procesada. De igual forma existe un botón "Exportar Datos" que cumple la misma función para todas las matrices obtenidas.
- 6. Tipo de evento:** En esta casilla se muestra el resultado de la clasificación, indicando el tipo de evento ocurrido.
- 7. MSV:** Este botón enlaza la interfaz gráfica denominada MSV Toolbox1.0, desarrollada para esta investigación por [Campos & Suárez, 07]. Esta herramienta computacional permite mediante tres módulos distintos. El primero realizar la validación cruzada para obtener los valores de los parámetros C y σ . El segundo calcula el modelo que contiene las máquinas biclasificadoras y sus parámetros y el último módulo permite hacer la clasificación con datos nuevos utilizando el modelo obtenido previamente.

Esta sencilla interfaz permite hacer pruebas de detección, identificación y clasificación de señales con perturbación a partir de los parámetros y modelos obtenidos en esta investigación, pero es posible modificar el modelo de la MSV utilizando la herramienta MSVToolbox1.0 desarrollada por [Campos & Suárez, 07] (Botón MSV) y que se encuentra activa en esta interfaz, para que sea posible el entrenamiento y evaluación con otros parámetros seleccionados por el usuario. El botón "modificar modelo" permite cargar el modelo obtenido con la MSVToolbox1.0.

7. RESULTADOS, CONCLUSIONES Y TRABAJOS FUTUROS

7.1. RESULTADOS

En este trabajo de investigación se desarrollaron e implementaron metodologías tanto para la detección, la identificación y para la clasificación de perturbaciones de la calidad de la energía.

La metodología de detección de perturbaciones de este trabajo está basada en una propuesta que realiza operaciones con filtros asociados a una función *wavelet*. Se propone una técnica para determinar la función *wavelet* adecuada para tal fin, considerando la pendiente de la magnitud de la respuesta en frecuencia del filtro en la zona de transición. La detección y localización de perturbaciones se basa en la comparación entre un umbral y el valor máximo de la magnitud de la salida del filtro de descomposición pasa-altas (FDPA) asociado a la función *wavelet*. Se han determinado valores iniciales para este umbral y se ha simulado el efecto de ruido blanco en la localización de perturbaciones utilizando la técnica propuesta.

Debido a que el comienzo y final de las perturbaciones implican cambios abruptos de amplitud asociados con componentes de alta frecuencia; se ha propuesto que la detección de perturbaciones se puede realizar a partir de la salida del FDPA asociado a una función *wavelet* (función Bior3.9). Esta propuesta permite realizar la localización en tiempo de igual forma que la secuencia de detalles del primer nivel de descomposición (utilizada en numerosos trabajos relacionados con la detección), requiriendo la salida del FDPA un menor número de cálculos, debido a que sólo se trata de una operación de convolución.

La selección de la función *wavelet* para la detección se realizó utilizando una figura de mérito para evaluar la selectividad del FDPA, considerando también la longitud de la respuesta al impulso de este filtro. La mejor selectividad se ha determinado como el mayor valor de la pendiente de la zona de transición de la magnitud de la respuesta en frecuencia del FDPA asociado a dicha función. Los resultados obtenidos al evaluar 32 funciones pertenecientes a 4 familias *wavelet*, presentan a la función *wavelet* Bior3.9 con el mayor valor de pendiente en la zona de transición y con la menor longitud de su respuesta al impulso (4 muestras). Esta función supera a funciones *wavelet* como la daubechies 4 (con respuesta al impulso de 8 muestras) la cual es utilizada en varios artículos de diversos investigadores.

Los resultados arrojados por las simulaciones realizadas en la estrategia de detección, presentan porcentajes de acierto mayores al 80% principalmente para perturbaciones sag, swell y transitorio si es considerada la presencia de

ruido con SNR de hasta 40 decibeles y si se consideran errores de detección menores o iguales a 5%. Para ambientes ruidosos con SNR menores a 40 dB, los fenómenos flicker y armónico no presentan buena localización en tiempo a menos que las amplitudes sean suficientemente fuertes (Porcentajes de acierto menores al 30%). De igual forma la perturbación transitorio tiene buena localización dependiendo de las magnitudes del evento, pues se consideraron en la prueba magnitudes del orden de 0,1 en pu (valor pequeño para un evento que normalmente tiene magnitudes del orden de 2 en pu).

En la estrategia de identificación se planteó una metodología para la obtención de descriptores adecuados que permiten una alta diferenciación entre cada uno de los patrones correspondientes a las perturbaciones de la calidad de la energía (esto permite garantizar una adecuada clasificación con un menor rango de incertidumbre). Debido a que cada perturbación tiene información en determinados niveles de energía o rangos de frecuencia, es posible diferenciar una perturbación de otra utilizando el cálculo de la energía de los coeficientes *wavelet* por nivel de descomposición de detalle y utilizando también el cálculo del valor eficaz (valor RMS) el cual permite diferenciar perturbaciones que presentan significativos cambios de amplitud. Asimismo, se seleccionó la función *wavelet* adecuada (función *wavelet* Bior3.7 con mejor selectividad) a partir de una figura de mérito que consiste en calcular una relación entre las energías contenidas en cada nivel de acuerdo con el rango de frecuencia ideal que le corresponde.

Como cada perturbación posee información en rangos característicos de frecuencia, es posible caracterizar cada perturbación a partir de la energía contenida en los niveles de descomposición de detalles de la transformada *wavelet*. Con base en lo anterior se propusieron 3 tipos de patrones, donde el primero toma las diferencias de las energías calculadas en 7 niveles de descomposición tanto para una señal pre-evento como para la perturbación. La segunda propuesta consiste en calcular la energía de la perturbación hasta 6 niveles de descomposición junto con 2 valores RMS (valores RMS máx y mín) obtenidos a partir de la diferencia entre cálculo del valor eficaz del pre-evento y el correspondiente a la perturbación, ponderados estos dos valores por el valor máximo del vector de energías previamente calculado. Por último, el patrón 3, se construyó a partir del cálculo de la energía de los coeficientes, hasta 7 niveles, de la diferencia entre una señal pre-evento y la perturbación; junto con esto se consideraron, también, los mismos dos valores RMS calculados para el patrón 2.

La selección de la función *wavelet* adecuada para la identificación de patrones se ha realizado mediante un análisis en frecuencia (barrido en frecuencia) utilizando 800 señales senoidales generadas sintéticamente para calcular la energía de los coeficientes de detalle para 8 niveles de descomposición. A partir de estas energías, se calcula la relación de la suma de las energías de los intervalos de frecuencia donde idealmente la energía debe ser cero, con

respecto a la suma de las energías pertenecientes al intervalo ideal de frecuencia. Para cada función *wavelet*, se promedian 8 relaciones (1 por cada nivel de descomposición). La selección de la función *wavelet* con mayor selectividad en frecuencia se ha determinado por el menor valor del promedio de esta relación promedio, dado que el valor ideal de esta relación debe ser cero. Adicionalmente, se ha considerado la menor duración de la respuesta al impulso del filtro asociado a la función *wavelet*.

En las simulaciones realizadas con el cálculo de la relación de energías, se encontró que la función *wavelet* con mejor selectividad es la Bior6.8 con una respuesta al impulso de 11 muestras de duración. El valor de esta relación de energías para la función Bior6.8 es menor que el obtenido para las otras funciones *wavelet* con duraciones similares. La función *wavelet* Bior3.7 presenta buenas características de selectividad y tiene una duración de la respuesta al impulso del FDPA de 4 muestras. Supera inclusive a funciones *wavelet* con respuestas al impulso de 6 muestras de duración. A partir de ésta última se generaron los 3 tipos de patrones que identifican las perturbaciones.

La clasificación de perturbaciones de la calidad de la energía se ha realizado utilizando la herramienta matemática máquina de soporte vectorial-MSV para clasificar los patrones obtenidos a partir de tres estrategias de identificación basadas en transformada *Wavelet* y valor RMS. La validación cruzada y la búsqueda en malla han permitido calcular los valores adecuados del parámetro de penalización (C) y del parámetro (σ) del kernel función de base radial RBF. Los resultados de simulación utilizando MSV han permitido comprobar la efectividad de las tres estrategias de identificación propuestas.

Para realizar las simulaciones de entrenamiento y clasificación de las MSV se ha desarrollado una herramienta computacional capaz de integrar todas las fases que conforman una MSV orientada a la clasificación de perturbaciones de la calidad. Esta herramienta desarrollada por [Campos & Suárez, 07], como parte de un trabajo de grado asociado a esta investigación, permite gestionar e interpretar fácilmente la búsqueda de los parámetros del modelo de la máquina con la mejor precisión y la técnica de la "validación cruzada"; la cual permite disminuir el tamaño del grupo de datos de entrenamiento garantizando una buena precisión.

A partir de las simulaciones realizadas con la herramienta computacional se ha encontrado un modelo MSV con altos porcentajes de acierto para los patrones analizados. Los valores determinados del parámetro de penalización ($C = 2^{22}$) y del parámetro del kernel ($\sigma = 0,7071$) permitieron generar un modelo MSV con tan solo 35 vectores de soporte. Con este modelo se han clasificado con un porcentaje de acierto del 100% todas las perturbaciones, excepto la perturbación tipo *swell* (con 98% de acierto), utilizando el patrón propuesto en la identificación basado en la energía de la perturbación hasta 6 niveles de descomposición *wavelet* junto con 2 valores RMS (patrón 2). Estas pruebas de

simulación se realizaron utilizando 1500 señales diferentes a las utilizadas en los procesos de entrenamiento y validación.

Se ha evaluado el desempeño en ambientes con ruido del modelo MSV con mejores características. Este modelo ha presentado alta inmunidad al ruido en la clasificación de 1500 señales con relaciones señal a ruido de 60 y 40 decibeles. Para una SNR de 20 dB el porcentaje de acierto disminuyó hasta en un 29%, en el caso de la perturbación armónico. Para la perturbación *flicker* el porcentaje de acierto no disminuyó y para las demás perturbaciones el porcentaje de acierto disminuyó entre el 1% el 5%.

7.2. CONCLUSIONES

En este trabajo de investigación se propuso que la detección de perturbaciones se puede realizar a partir de la salida del FDPA asociado a la función *wavelet* Bior3.9. Siendo posible realizar la localización en tiempo de igual forma que la secuencia de detalles del primer nivel de descomposición pero con menor tiempo de cálculo.

A partir de los resultados obtenidos al evaluar 32 funciones pertenecientes a 4 familias *wavelet*, se concluye que la función *wavelet* Bior3.9 presenta la mayor selectividad en frecuencia con el mayor valor de pendiente en la zona de transición y con sólo 4 muestras en su respuesta al impulso. Superando a la función db4 (8 muestras) la cual según el estado del arte es muy utilizada por diversos investigadores para tal fin.

Si se desean implementar algoritmos de detección en tiempo real (en procesadores digitales) es deseable que la longitud de la respuesta al impulso del FDPA asociado a la función *wavelet* tenga la menor duración posible para realizar el cálculo con mayor rapidez. Esta propuesta de utilizar la salida del FDPA, es un aporte a la detección de perturbaciones y los resultados de las simulaciones realizadas permiten confirmar el buen desempeño de la metodología propuesta.

En las simulaciones realizadas, al considerar la presencia de ruido con SNR de hasta 40 decibeles y errores de detección $\leq 5\%$, las perturbaciones *sag*, *swell* y transitorio presentan porcentajes de acierto mayores al 80%. Por el contrario, las perturbaciones *flicker* y armónico no presentan buena localización en tiempo con porcentajes de acierto $< 30\%$. Esto indica que el *flicker* y el armónico presentan menor probabilidad de detección en ambientes ruidosos.

Se determinaron valores iniciales del umbral que permite decidir la existencia o no de la perturbación, esto con el fin de detectar el inicio de la perturbación a partir del valor máximo del cálculo de la magnitud de la salida obtenida al

convolucionar la perturbación con la respuesta al impulso del FDPA asociado a la función *wavelet* Bior3.9. No obstante, el umbral debe ajustarse de acuerdo a las características del sistema eléctrico que se esté monitorizando.

Se propusieron 3 tipos de patrones para el conjunto de perturbaciones en estudio en la estrategia de identificación. Estos patrones se obtienen a partir de del cálculo de la energía de los coeficientes *wavelet* por nivel de descomposición de detalle y el cálculo del valor RMS.

De los resultados obtenidos en las simulaciones, la función *wavelet* con mejor selectividad es la Bior6.8 con 11 muestras de duración (en su respuesta al impulso). La función *wavelet* Bior3.7 presenta buenas características de selectividad y tiene una duración de sólo 4 muestras. Esta última supera inclusive a funciones *wavelet* con 6 muestras de duración. A partir de ésta última se generaron los 3 tipos de patrones que identifican las perturbaciones.

Se estudió e implementó el clasificador máquina de soporte vectorial (MSV). El cual utiliza como entrada los patrones obtenidos en la estrategia de identificación. A partir de la validación cruzada y la búsqueda en malla fue posible calcular valores adecuados del parámetro de penalización (C) y del parámetro (σ) del kernel función de base radial RBF. Los resultados de simulación utilizando MSV permitieron seleccionar el segundo patrón como mejor.

Se desarrolló e implementó una herramienta computacional capaz de integrar todas las fases que conforman una MSV orientada a la clasificación de perturbaciones de la calidad. Esta herramienta desarrollada por [Campos & Suárez, 07] (trabajo de grado asociado a esta investigación) permite gestionar e interpretar de manera fácil y eficiente la búsqueda de los parámetros del modelo de la máquina para realizar las simulaciones de entrenamiento y clasificación.

Se encontró un modelo MSV (con $C=2^{22}$, $\sigma=0,7071$ y 35 vectores de soporte) capaz de clasificar con un porcentaje de acierto del 100% todas las perturbaciones, excepto la perturbación tipo *swell* que tiene 98% de acierto utilizando el segundo patrón propuesto y 1500 señales para clasificar.

Se evaluó el desempeño del modelo MSV con mejores características en ambientes con ruido. El modelo presentó alta inmunidad al ruido para $SNR \geq 40$ dB y para una SNR de 20 dB el porcentaje de acierto disminuyó hasta en un 29% para armónico y para las demás perturbaciones entre el 1% el 5%. Esto permiten considerar que la perturbación armónico puede presentar problemas de clasificación en ambientes ruidos.

Como producto final de esta investigación, se ha implementado la estrategia de detección, identificación y clasificación de perturbaciones. Ésta permite de manera sencilla hacer pruebas de detección, identificación y clasificación con

grupos de señales con perturbación, utilizando los parámetros y modelos obtenidos en esta investigación. Es posible modificar el modelo MSV y utilizar la herramienta de clasificación MSVtoolbox1.0 para generar el modelo deseado.

7.3. TRABAJOS FUTUROS

A partir de los resultados obtenidos en este trabajo de investigación, se propone mejorar el algoritmo de detección, teniendo en cuenta que los umbrales calculados son un punto de partida, es necesario ajustar el valor del umbral según el sistema eléctrico a monitorizar. Para la selección de dicho umbral es necesario adaptar el algoritmo a situaciones reales, es decir, utilizando señales reales para sintonizar el valor del umbral de detección.

En este trabajo se presentaron 3 tipos de patrones, dos de los cuales presentan muy buen desempeño para identificar y diferenciar las 5 perturbaciones que se estudiaron en esta investigación, de acuerdo con los resultados obtenidos en las simulaciones utilizando el método de clasificación. Es necesario realizar un estudio más profundo a partir de la estrategia de identificación utilizando señales reales con el fin de establecer las variaciones de los patrones propuestos.

El método de clasificación MSV utilizado en este trabajo permite clasificar con un porcentaje de acierto cercano al 100% para las perturbaciones utilizadas en las pruebas. Si se utilizan señales reales y los patrones sufren alguna modificación, es necesario adaptar el modelo obtenido a esta nueva situación y por ende es necesario realizar nuevas búsquedas de los parámetros de la MSV. Se propone optimizar esta estrategia de clasificación de tal forma que sea posible mejorar el modelo a medida que ingresen nuevos datos en la MSV.

A partir de la estrategia de detección, identificación y clasificación de perturbaciones, se propone el mejoramiento de los algoritmos y la implementación de esta estrategia en un sistema hardware que permita conocer el comportamiento del sistema eléctrico (construcción de equipos de monitorización y medición).

8. REFERENCIAS BIBLIOGRÁFICAS

[NTC 5000, 02] Norma Técnica Colombiana 5000: "Calidad de la potencia eléctrica (CPE). Definiciones y términos fundamentales", Instituto Colombiano de Normas Técnicas (ICONTEC), 2002.

[CREG 024, 05] Comisión de Regulación de Energía y Gas – CREG, "Resolución CREG 024 de Mayo 2005", Comisión de Regulación de Energía y Gas – CREG, Santa Fé de Bogotá, Mayo de 2005.

[Lin, 05] Lin, C.-H. Tsao, M.-C. "Power quality detection with classification enhancible wavelet-probabilistic network in a power system" Generation, Transmission and Distribution, IEEE Proceedings- 4 Nov. 2005 Volume: 152 , Issue: 6 On page(s): 969 – 976.

[Duque, 05] Duque, C.A. Ribeiro, M.V. Ramos, F.R. Szczupak, J. "Power quality event detection based on the divide and conquer principle and innovation concept" Power Delivery, IEEE Transactions on. Oct. 2005, Volume: 20 , Issue: 4 On page(s): 2361 – 2369.

[Vapnik, 95] Vladimir Vapnik, "The nature or statistical Learning Theory" Springer, NY., 1995. ISBN 0-387-94559-8.

[IEEE 1159, 95] IEEE Std 1159-1995, CEI 61000-4-7 Compatibilidad Electromagnética (CEM)

[Ordóñez, 02] Ordóñez, G. "Seminario: Calidad del Suministro de Energía Eléctrica", Universidad Industrial de Santander, Bucaramanga. 2002.

[García, 00] García Q. Edwin "Armónicos: "Aplicación de la Transformada Wavelet para el análisis de transitorios electromagnéticos" Tesis Pregrado UIS (2000). Pp109.

[Chui, 97] Chui, Charles K., "Wavelets: a mathematical tool for signal analysis", SIAM, Philadelphia, (1997). Pp. 210.

[Daubichies, 92] Daubechies, Ingrid. "Ten Lectures on Wavelets", Philadelphia: SIAM. (1992). Pp. 357.

[Gold & Morgan, 00] Gold, Ben y Morgan, Nelson. "Speech and Audio Signal Processing", John Wiley & Sons, USA, 2000.

[Flores, 02] Rafael A. Flores, Member, IEEE "State of the Art in the Classification of Power Quality Events" 10th International Conference in Harmonics and Quality of Power, Brazil, Oct 2002 Pp. 4. Available in: <http://www.s2.chalmers.se/research/signal/index.php?user=flores> 2002

[Barrera & Cormane, 03] Barrera, Victor ; Cormane, Jorge "Predicción de corrientes armónicas en ventanas de carga residenciales, mediante modelos neuronales artificiales". Tesis de grado Pp 164, Universidad Industrial de Santander, Bucaramanga 2003.

[Abe, 02] Abe, Shiegeo "Análisis of Support Vector Machines" IEEE 2002. Pp. 89-98.

[Kim, 02] Kim, H.; Pang, S.; Kim, D.; Bang, S. "Pattern classification using support vector machine ensemble". IEEE 2002 Pp. 160-163.

[Duarte, 04] Duarte, César A. "Técnicas de Procesamiento de Señales para la Monitorización de la Calidad de la Energía Eléctrica" Tesis Maestría, Pág.140. Universidad Industrial de Santander, Bucaramanga, 2004.

[Mathworks, 02] "User's Guide Wavelet Toolbox". Mathworks. 2002.

[Heydt & Galli, 97] Heydt, G.T. ; Galli, A.W. " Transient Power Quality Problem Analized using Wavelet ", IEEE Transactions on Power Delivery, Vol. 12, No. 2, April 1997. Page(s): 908 -915.

[Poison, 99] Poison, O. ; Rioual P. ; Meunier, M. " New Signal Processing Tool Applied to Power Quality Analysis ", IEEE Transactions on Power Delivery, Vol. 14, No. 2, April 1999. Page(s): 561 -915.

[Kezunovic & Liao, 00] Mladen Kezunovic and Yuan Liao, "A Novel Software Implementation Concept for Power Quality Study", 2000. Available in: <http://eent1.tamu.edu/people/bkezunov.html>

[Shyh-Jier, 99] Shyh-Jier, H. ; Chen-Tao, H. ; Ching-Lien, H. "Application of Morlet Wavelet to Supervise Power System Disturbances", IEEE Transactions on Power Delivery, Vol. 14, No. 1, January 1999. Page(s): 235 -243.

[Daponte, 04] Daponte, P.; Di Penta, M.; Mercurio, G. "TransientMeter a distributed measurement system for power quality monitoring 04" Power Delivery, IEEE Transactions on. Volume 19, No 2 April 2004 Pág: 456 - 463.

[Liu, 02] Liu, Z.; He, Z; Qian Q. "Research on Feedforward Neural Network, Wavelet Transformation, Wavelet Networks and Their Relations" Proceedings of the 2nd international Workshop on Autonomous Decentralized system. Pp. 277-281. 2002.

- [Kim, 02] Kim, H.; Pang, S.; Kim, D.; Bang, S. "Pattern classification using support vector machine ensemble". IEEE 2002 Pp. 160-163.
- [Zang, 04] Zang, Li; Zhou, W.; Jiao, L. "Wavelet Support Vector Machine" IEEE Transactions on System, man and cybernetics. Vol.34 No1 Feb. 2004 Pp 34-39.
- [Vega, 04] Vega, Valdomiro "Aplicación de la Transformada *Wavelet* Discreta (DWT) en la Detección e Identificación de Eventos de la Calidad de la Energía Eléctrica" Tesis de grado Pp. 123 Universidad Industrial de Santander, Bucaramanga 2004. Director, César Antonico Duarte Gualdrón y codirector, Gabriel Ordóñez Plata.
- [Angulo, 01] Angulo, Cecilio. "Aprendizaje con máquinas núcleo en entornos de multiclasificación" Tesis Doctoral, Universitat Politècnica de Catalunya. Vilanova i la Geltrú, Abril 2001.
- [Campos & Suárez, 07] Campos, Estela ; Suárez, Ángel G. "Clasificación Automática de Perturbaciones de Señales de Tensión o Corriente Utilizando Máquinas De Soporte Vectorial (MSV)". Tesis de grado Pp. 114 Universidad Industrial de Santander, Bucaramanga 2007. Director, Valdomiro Vega García; codirector, César Antonico Duarte Gualdrón.
- [Kuhn & Tucker, 51] Kuhn, H. W. y Tucker, A. W. "Nonlinear programming. Proc. 2nd Berkeley Symposium on Mathematical Statistics and Probabilistics", pages:481_492, 1951. University of California Press.
- [Cortes & Vapnik, 95] Cortes, C. y Vapnik, V. "Support vector - networks. Machine Learning", Vol. 20 Número 3, septiembre 1995, pp:273 - 297 (25) Editorial Springer.
- [Dietterich & Bakiri, 95] Dietterich, T. G. y Bakiri, G. "Solving multiclass learning problems via error-correcting output codes". Journal of Artificial Intelligence Research, 2:263_286, 1995.
- [Martínez W & Martínez A, 02], Martínez, W. ; Martínez, A. "computational statistics handbook with MATLAB", Chapman & hall / CRC, 231-239, 2002.

9. BIBLIOGRAFÍA

9.1. LIBROS

[Angulo, 01] Angulo, Cecilio. "Aprendizaje con máquinas núcleo en entornos de multiclasificación" Tesis Doctoral, Universitat Politècnica de Catalunya. Vilanova i la Geltrú, Abril 2001.

[Arrillaga, 00] J. Arrillaga, N.R. Watson, S. Chen, "Power quality assessment", John Wiley & Sons Ltd, 2000. Pp. 300.

[Burges, 98] Christopher Burges (1998). A tutorial on support vector machines for pattern recognition. *Data Mining And Knowledge Discovery*, 1998, Pp. 121-167.

[Shawe & Cristianini, 00] Shawe-Taylor, John and Cristianini, Nello. "Support Vector Machines and other kernel-based learning methods", Cambridge University Press, 2000.

[Barrera & Cormane, 03] Barrera, Victor ; Cormane, Jorge "Predicción de corrientes armónicas en ventanas de carga residenciales, mediante modelos neuronales artificiales". Tesis de grado Pp 164, Universidad Industrial de Santander, Bucaramanga 2003.

[Campos & Suárez] Campos, Estela ; Suárez, Ángel G. "Clasificación Automática de Perturbaciones de Señales de Tensión o Corriente Utilizando Máquinas De Soporte Vectorial (MSV)". Tesis de grado Pp. 114 Universidad Industrial de Santander, Bucaramanga 2007. Director, Valdomiro Vega García; codirector, César Antonico Duarte Gualdrón.

[Chui, 97] Chui, Charles K., "Wavelets: a mathematical tool for signal analysis", SIAM, Philadelphia, (1997). Pp. 210.

[Cherkassky, 98] Cherkassky, V. and Mulier, F. "Learning from data: concepts, theory, and methods". John Wiley and Sons, New York. 1998

[Cortes & Vapnik, 95] Cortes, C. y Vapnik, V. "Support vector - networks. Machine Learning", Vol. 20 Número 3, septiembre 1995, pp:273 - 297 (25) Editorial Springer.

[Daubichies, 92] Daubechies, Ingrid. "Ten Lectures on Wavelets", Philadelphia: SIAM. (1992). Pp. 357.

[Delgado & Romero, 03] Delgado, José ; Romero, José. "Flicker en Baja Tensión: Caracterización Y Análisis" Tesis de grado Pp 150 Universidad Industrial de Santander, Bucaramanga 2003.

[Duarte, 04] Duarte, César A. "Técnicas de Procesamiento de Señales para la Monitorización de la Calidad de la Energía Eléctrica" Tesis Maestría, Pág.140. Universidad Industrial de Santander, Bucaramanga, 2004.

[García, 00] García Q. Edwin "Armónicos: "Aplicación de la Transformada Wavelet para el análisis de transitorios electromagnéticos" Tesis Pregrado UIS (2000). Pp109.

[Haikin, 99] Haikin, Simon. "Neural Network. A comprehensive foundation". Prentice Hall, 1999. Pp.320.

[Heno, 04] Ricardo Heno, "Selección de Hiperplanos en Máquinas de soporte vectorial" Tesis Maestría Universidad Nacional de Colombia sede Manizales. Manizales mayo de 2004 Pp. 91.

[Kuhn & Tucker, 51] Kuhn, H. W. y Tucker, A. W. "Nonlinear programming. Proc. 2nd Berkeley Symposium on Mathematical Statistics and Probabilistics", pages:481_492, 1951. University of California Press.

[Mathworks, 99] "User's Guide neural Network Toolbox". Mathworks. 1999.

[Mathworks, 02] "User's Guide Wavelet Toolbox". Mathworks. 2002.

[Mallat, 99] Mallat Stéphane, "A Wavelet Tour of Signal Processing" Academic Press, 2º edition. 1.999. P.p. 241.

[Martínez W & Martínez A, 02], Martínez, W. ; Martínez, A. "computational statistics handbook with MATLAB", Chapman & hall / CRC, 231-239, 2002.

[Morales & Gómez, 05] Morales, German; Gomez, Álvaro. "Estudio e implementación de una herramienta basada en máquinas de soporte vectorial aplicada a la localización de fallas en sistemas de distribución", proyecto de grado. Universidad Industrial de Santander, 2005.

[Oppenheim, 98] Alan V. Oppenheim & Alan S. Willsky, "Señales y Sistemas", Editorial Prentice Hall, Segunda Edición (1998). Pp.956.

[Oppenheim & Schafer, 00] Oppenheim, Alan y Schafer, Ronald. "Tratamiento de señales en tiempo discreto". Segunda edición, Prentice Hall, Madrid, 2000. Pp. 873.

[Poularikas, 00] Poularikas, Alexander D. "The transforms and applications handbook" CRC Press 2° edition 2000.

[Bollen, 00] Bollen, M. "Understanding Power Quality Problems: Voltajes Sags and Interruptions". IEEE PRESS. 2000.

[Rodríguez & Uribe, 03] Rodríguez, Juan; Uribe, Olga. "Propuesta de Norma Técnica Colombiana de Medición de Armónicos". Tesis de grado. Dirigida por Gabriel Ordóñez Plata. Pp. 184, Universidad Industrial de Santander, Bucaramanga 2003.

[Styvaktakis, 02] Styvaktakis, Emmanouil., "Automating power quality analysis", Thesis for the degree of Doctor of Philosophy, Chalmers University of Technology, Sweden, 2002.

[Vega, 04] Vega, Valdomiro "Aplicación de la Transformada *Wavelet* Discreta (DWT) en la Detección e Identificación de Eventos de la Calidad de la Energía Eléctrica" Tesis de grado Pp. 123 Universidad Industrial de Santander, Bucaramanga 2004. Director, César Antonico Duarte Gualdrón ; codirector, Gabriel Ordóñez Plata.

9.2. NORMAS NACIONALES E INTERNACIONALES

[CREG 024, 05] Comisión de Regulación de Energía y Gas – CREG, "Resolución CREG 024 de Mayo 2005", Comisión de Regulación de Energía y Gas – CREG, Santa Fé de Bogotá, Mayo de 2005.

[IEEE 1159, 95] IEEE Std 1159-1995, CEI 61000-4-7 Compatibilidad Electromagnética (CEM)

[IEC 61000-4-30, 03] INTERNATIONAL ELECTROTECHNICAL COMMISSION. IEC 61 000-4-30. "Electromagnetic compatibility (EMC)-Part 4-30: Testing and measurements techniques- Power quality measurements methods". 89 p., Geneve, Switzerland, 2003.

[NTC 5000, 02] Norma Técnica Colombiana 5000: "Calidad de la potencia eléctrica (CPE). Definiciones y términos fundamentales", Instituto Colombiano de Normas Técnicas (ICONTEC), 2002.

[NTC-IEC 61000-1-1, 00] Norma Técnica Colombiana – IEC 61000-1-1: "Compatibilidad electromagnética. Parte I: Generalidades. Sección I: Aplicación e interpretación de definiciones y términos fundamentales", Instituto Colombiano de Normas Técnicas (ICONTEC), 2000.

9.3. ARTÍCULOS IEEE

[Abe, 02] Abe, Shiegeo "Analysis of Support Vector Machines" IEEE 2002. Pp. 89-98.

[Chen, 02] Chen Xiangxun "Wavelet-based detection, localization, quantification and classification of short duration power quality disturbances" Power Engineering Society Winter Meeting, 2002. IEEE Volume 2, 27-31 Jan. 2002 Page(s):931 - 936 vol.2

[Chilukuri, 04] Chilukuri, M.V. ; Dash, P.K. ; Basu, K.P. "Time-frequency based pattern recognition technique for detection and classification of power quality disturbances" Multimedia Univ., Cyberjaya, Malaysia. TENCON 2004. 2004 IEEE Region 10 Conference. 21-24 Nov. 2004 On page(s): 260 - 263 Vol. 3.

[Chowdhury, 91] Chowdhury, F.N. ; Christensen, J.P. ; Aravena, J.L.; Louisiana State Univ., Baton Rouge, LA, USA; "Power system fault detection and state estimation using Kalman filter with hypothesis testing" Power Delivery, IEEE Transactions on, Volume: 6 , Issue: 3 On page(s): 1025 - 1030 , July 1991.

[Daponte, 04] Daponte, P.; Di Penta, M.; Mercurio, G. "TransientMeter a distributed measurement system for power quality monitoring" Power Delivery, IEEE Transactions on. Volume 19, No 2 April 2004 Pág: 456 – 463.

[Dilokratan, 03] Dilokratanatrakool, C. ; Na Ayudhya, P.N. ; Chayavanich, T. Prapanavarat, C. "Automatic detection-localization of fault point on waveform and classification of power quality disturbance waveshape fault using wavelet and neural network" Dept. of Electr. Eng., King Mongkut's Univ. of Technol., Bangkok, Thailand. Robotics, Intelligent Systems and Signal Processing, 2003. Proceedings. 2003 IEEE International Conference on 8-13 Oct. 2003 On page(s): 142 - 147 vol.1

[Dwivedi & Singh, 06] Dwivedi, U.D.; Singh, S.N. "A robust energy features estimation for detection and classification of power quality disturbances" Power India Conference, 2006 IEEE, Dept. of Electr. Eng., Indian Inst. of Technol., Kanpur, India, On page(s): 7 pp. 10-12 April 2006.

[Gaouda, 99] Gaouda, A, ; Chikhani, A. "Power quality detection and classification using wavelet-multiresolution signal decomposition " Power Systems, IEEE Transactions on Published: Oct 1.999 Volume: 14 4 , Page(s): 1469 – 1476.

[Gaouda, 00] Gaouda, A, ; Chikhani, A. "Wavelet-based intelligent system for monitoring non-stationary disturbances" Electric Utility Deregulation and

Restructuring and Power Technologies, 2000. Proceedings. DRPT 2000. International Conference on Published: 2000 , Page(s): 84 -89 .

[Gaouda, 01] Gaouda, A.M.; El-Saadany, E.F.; Salama, M.M.A.; Sood, V.K.; Chikhani, A.Y. "Monitoring HVDC systems using wavelet multi-resolution analysis "Power Systems, IEEE Transactions on Published: Nov. 2001 Volume: 16 4 , Page(s): 662 -670 .

[Gaouda, 02] Gaouda, A.M.; Kanoun, S.H.; Salama, M.A.; Chikhani, A.Y. " Wavelet-based signal processing for disturbance classification and measurement" Generation, Transmission and Distribution, IEE Proceedings-Published: May 2002 Volume: 149 3 , Page(s): 310 -318

[Gou-Sheng & Jing, 05] Guo-Sheng Hu ; Jing Xie ; Feng-Feng Zhu. "Classification of power quality disturbances using wavelet and fuzzy support vector machines" Electr. Power Sch., South China Univ. of Technol., Guangzhou, China. Machine Learning and Cybernetics, 2005. Proceedings of 2005 International Conference on.18-21 Aug. 2005. On page(s): 3981 - 3984 Vol. 7.

[Heydt & Galli, 97] Heydt, G.T. ; Galli, A.W. " Transient Power Quality Problem Analyzed using Wavelet ", IEEE Transactions on Power Delivery, Vol. 12, No. 2, April 1997. Page(s): 908 -915.

[Janik & Lobos, 06] Janik, P.; Lobos, T. "Automated classification of power-quality disturbances using SVM and RBF networks" Dept. of Electr. Eng., Wroclaw Univ. of Technol., Poland. Power Delivery, IEEE Transactions on, Volume: 21 , Issue: 3 On page(s): 1663 - 1669, July 2006.

[Karimi et al, 00] Karimi, Masoud; Mokthari, Hossein; Iravani, Reza. "Wavelet based on line disturbance detection for power quality applications". IEEE Transactions on Power Delivery, vol. 17,No. 1, January 2002.

[Kim, 02] Kim, H.; Pang, S.; Kim, D.; Bang, S. "Pattern classification using support vector machine ensemble". IEEE 2002 Pp. 160-163.

[Liu, 02] Liu, Z.; He, Z; Qian Q. "Research on Feedforward Neural Network, Wavelet Transformation, Wavelet Networks and Their Relations" Proceedings of the 2nd international Workshop on Autonomous Decentralized system. Pp. 277-281. 2002.

[Poison, 99] Poison, O. ; Rioual P. ; Meunier, M. " New Signal Processing Tool Applied to Power Quality Analysis ", IEEE Transactions on Power Delivery, Vol. 14, No. 2, April 1999. Page(s): 561 -915.

[Shyh-Jier, 99] Shyh-Jier, H. ; Chen-Tao, H. ; Ching-Lien, H. "Application of Morlet Wavelet to Supervise Power System Disturbances", IEEE Transactions on Power Delivery, Vol. 14, No. 1, January 1999. Page(s): 235 –243.

[Vega, Duarte & Ordóñez, 06] Vega G., Valdomiro; Duarte G., César A.; Ordóñez P., Gabriel "Automatic Power Quality Disturbances Detection and Classification Based on Discrete Wavelet Transform and Artificial Intelligence" Transmission and Distribution Conference and exposition, PES IEEE 2006 Caracas, Venezuela, ISBN: 1-4244-0288-3, IEEE Catalog Number: 06EX1340C Library of Congress: 2006921895. 2006. Agosto 2006.

[Santoso & Hoffman, 96] Santoso, Surya; Hoffman, Peter. "Power quality assessment via Wavelet transform analysis". IEEE Transactions on Power Delivery, vol. 11, No. 2, April 1996.

[Wang, 01] Min Wang Ochenkowski, P. Mamishev, A. "Classification of power quality disturbances using time-frequency ambiguity plane and neural networks" Dept. of Electr. Eng., Washington Univ., Seattle, WA, USA. Power Engineering Society Summer Meeting, 2001. IEEE. 15-19 July 2001 On page(s): 1246 - 1251 vol.2.

[Xiangxun, 02] Xiangxun, Cheng. "Wavelet based detection, localization, quantification and classification of short duration power quality disturbances". IEEE Power Engineering Society Winter Meeting, 2002, Vol. 2, 2002.

[Zang, 04] Zang, Li; Zhou, W.; Jiao, L. "Wavelet Support Vector Machine" IEEE Transactions on System, man and cybernetics. Vol.34 No1 Feb. 2004 Pp 34-39.

[Zheng et al, 99] Zheng, Tongxin; Makran, Elham; Girgis, Adly. "Power system transient and harmonic studies using wavelet transform". IEEE Transactions on Power Delivery, vol. 14, No 4, October 1999.

9.4. ARTÍCULOS INTERNET

[Björn & Sweldens] Björn, Jawerth; Wim, Sweldens, Department of Mathematics, University of South Carolina, Columbia "An Overview Of Wavelet Based Multiresolution Analysis" 2002.

Available in: <http://cm.bell-labs.com/who/wim/papers/overview.pdf>

[Debnath, 01] K. Debnath , M. Negnevitsky , K. Ho, C. Jun School of Engineering University of Tasmania "Recognition of Power Quality Disturbances" 2001 Available in:

http://www.itee.uq.edu.au/~aupec/aupec01/038%20Debnath_AUPEC01paper%20revised.pdf

[Flores, 02] Rafael A. Flores, Member, IEEE "State of the Art in the Classification of Power Quality Events" 10th International Conference in Harmonics and Quality of Power, Brazil, Oct 2002 Pp. 4. Available in: <http://www.s2.chalmers.se/research/signal/index.php?user=flores 2002>

[Hong,99] Cheng Hong, Loh Poh Chiang, S. Elangovan National University of Singapore "Wavelet packets analysis and artificial intelligence based adaptive fault diagnosis" 2002 Pp. 6 Available in: <http://www.itee.uq.edu.au/~aupec/aupec99/hong99.pdf>

[Kezunovic & Liao, 00] Mladen Kezunovic and Yuan Liao, "A Novel Software Implementation Concept for Power Quality Study", 2000. Available in: <http://eent1.tamu.edu/people/bkezunov.html>

[Resende, 01] Resende J.W.,Chaves M.L.R. Penna, C."Identification of power quality disturbances using the MATLAB wavelet transform toolbox". Universidade Federal de Uberlandia (MG)-Brazil. Pp. 8 2001 Available in: <http://www.ipst.org/TechPapers/2001/IPST01Paper110.pdf>

9.5. OTRAS REFERENCIAS

[Dietterich & Bakiri, 95] Dietterich, T. G. y Bakiri, G. "Solving multiclass learning problems via error-correcting output codes". Journal of Artificial Intelligence Research, 2:263_286, 1995.

[Muñoz, 05] Muñoz, P. Ibargüen, F. López, J. "Reconocimiento de Caracteres Manuscritos Usando Máquinas de Vectores de Soporte", X Simposio de tratamiento de señales, imágenes y visión artificial. Universidad del Valle, Santiago de Cali, Septiembre 14-16 de 2005.

[Mora & Colomer, 03] Mora, J. Colomer, J. "Voltage Sag Characterization and Classification for Diagnosis in Electric Power Quality Domain", Research Report, Department of Electronics, Computer Science and Automatic Control – Group eXiT, University of Girona, España – 2003

[Ordóñez, 02] Ordóñez, G. "Seminario: Calidad del Suministro de Energía Eléctrica", Universidad Industrial de Santander, Bucaramanga. 2002.

[Vapnik, 95] Vladimir Vapnik, "The nature or statistical Learning Theory" Springer, NY., 1995. ISBN 0-387-94559-8.

[Schölkopf & Smola, 02] Bernhard Schölkopf, Alex Smola. "Learning with Kernels Support Vector Machines, Regularization, Optimization and Beyond". The MIT Press, 2002, Cambridge.

ANEXOS

ANEXO A. TABLAS DE PORCENTAJES DE ACIERTOS EN LA DETECCIÓN PARA FUNCIONES *WAVELETS* EN PRESENCIA DE RUIDO.

A.1. Resultados de porcentajes de acierto para la Función Symlet

Tabla 35 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el sag.

		SNR 20 dB		SNR 40 dB		SNR 60 dB		
		MagV%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini p 272 sin fase	95	0,297	10,16	0,0341	63,28	0,02245	0,78	
	90	0,297	10,16	0,053	0,781	0,04515	0,78	
	50	0,297	10,16	0,2346	0,781	0,22671	0,78	
	10	0,47	0,781	0,4162	0,781	0,40827	0,78	
Ini p 304 sin fase	95	0,297	35,16	0,0341	88,28	0,01998	0,78	
	90	0,297	35,16	0,0468	0,781	0,03923	0,78	
	50	0,297	35,16	0,2008	0,781	0,19323	0,78	
	10	0,297	35,16	0,3548	0,781	0,34722	0,78	
Ini p 272 fase pi/4	95	0,469	0,781	0,4153	0,781	0,40737	0,78	
	90	0,471	0,781	0,4177	0,781	0,40981	0,78	
	50	0,491	0,781	0,4372	0,781	0,4293	0,78	
	10	0,51	0,781	0,4567	0,781	0,44879	0,78	
Ini p 304 fase pi/4	95	0,297	35,16	0,1702	0,781	0,17781	0,78	
	90	0,297	35,16	0,1406	0,781	0,14815	0,78	
	50	0,297	35,16	0,0967	0,781	0,08913	0,78	
	10	0,297	35,16	0,334	0,781	0,3264	0,78	

Tabla 36 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el swell.

		SNR 20 dB		SNR 40 dB		SNR 60 dB		
		MagV%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini p 272 sin fase	105	0,297	10,16	0,0341	63,28	0,02294	0,78	
	110	0,297	10,16	0,0391	0	0,04563	0,78	
	150	0,297	10,16	0,2193	0,781	0,22719	0,78	
	180	0,353	0	0,3555	0,781	0,36336	0,78	
Ini p 304 sin fase	105	0,297	35,16	0,0341	88,28	0,01852	0,78	
	110	0,297	35,16	0,0341	88,28	0,03777	0,78	
	150	0,297	35,16	0,1842	0,781	0,19176	0,78	
	180	0,364	0,781	0,2997	0,781	0,30726	0,78	
fase pi/4	105	0,464	0,781	0,4104	0,781	0,4025	0,78	
	110	0,461	0,781	0,4079	0,781	0,40006	0,78	

Ini p 304 fase pi/4	150	0,442	0,781	0,3884	0,781	0,38057	0,78
	180	0,427	0,781	0,3738	0,781	0,36595	0,78
	105	0,297	35,16	0,2295	0,781	0,23713	0,78
	110	0,323	0,781	0,2592	0,781	0,26678	0,78
	150	0,561	0,781	0,4965	0,781	0,50406	0,78
	180	0,739	0,781	0,6744	0,781	0,68202	0,78

Tabla 37 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el Transitorio.

		SNR 20 dB			SNR 40 dB		SNR 60 dB	
	Mag V	Frec Hz	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini pos 272	0,1 pu	300	0,297	10,16	0,0376	0	0,04261	0,78
		1000	0,297	10,16	0,0438	0	0,04687	0,78
		3000	0,371	7,813	0,1401	7,813	0,1339	3,91
	0,5 pu	300	0,297	10,16	0,2042	0,781	0,21211	0,78
		1000	0,297	10,16	0,2255	0,781	0,23337	0,78
		3000	0,905	7,813	0,6734	7,813	0,66642	7,81
	4 pu	300	1,634	0,781	1,6873	0,781	1,69518	0,78
		1000	1,804	0,781	1,8574	0,781	1,86524	0,78
		3000	5,571	7,813	5,3401	7,813	5,3331	7,81
Ini pos 304	0,1 pu	300	0,297	35,16	0,0507	0,781	0,04311	0,78
		1000	0,297	35,16	0,0549	0,781	0,04736	0,78
		3000	0,367	4,688	0,1333	3,906	0,13368	7,81
	0,5 pu	300	0,297	35,16	0,2202	0,781	0,2126	0,78
		1000	0,297	35,16	0,2414	0,781	0,23386	0,78
		3000	0,883	4,688	0,6631	3,906	0,66702	7,81
	4 pu	300	1,639	0,781	1,7032	0,781	1,69567	0,78
		1000	1,809	0,781	1,8733	0,781	1,86573	0,78
		3000	5,406	3,906	5,3059	7,813	5,3337	7,81

Tabla 38 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el Flicker.

		SNR 20 dB			SNR 40 dB		SNR 60 dB	
	Mag V	Frec Hz	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini pos 272	0,1 pu	8	0,297	10,16	0,0341	63,28	0,00315	172
		15	0,297	10,16	0,0341	63,28	0,00315	172
		24	0,297	10,16	0,0341	63,28	0,00315	172
	0,5 pu	8	0,297	10,16	0,0341	63,28	0,00315	172
		15	0,297	10,16	0,0341	63,28	0,00315	172
		24	0,297	10,16	0,0341	63,28	0,00315	172

Ini pos 304	5 pu	8	0,297	10,16	0,0341	63,28	0,00424	0,78
		15	0,297	10,16	0,0341	63,28	0,0221	0,78
		24	0,297	10,16	0,0341	63,28	0,01298	0,78
	0.1 pu	8	0,297	35,16	0,0341	88,28	0,00315	197
		15	0,297	35,16	0,0341	88,28	0,00315	197
		24	0,297	35,16	0,0341	88,28	0,00315	197
	0,5 pu	8	0,297	35,16	0,0341	88,28	0,00315	197
		15	0,297	35,16	0,0341	88,28	0,00315	197
		24	0,297	35,16	0,0341	88,28	0,00315	197
	5 pu	8	0,297	35,16	0,0341	88,28	0,00837	0,78
		15	0,297	35,16	0,0341	88,28	0,01696	0,78
		24	0,297	35,16	0,0341	88,28	0,01737	0,78

Tabla 39 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el Armónico.

	Magnitud del armónico %			SNR 20 dB		SNR 40 dB		SNR 60 dB	
	3er	5to	7mo	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Fase cero	0,9	0,7	0,4	0,297	10,16	0,0341	63,28	0,00414	0,78
	7	0,7	0,4	0,297	10,16	0,0341	63,28	0,01739	0,78
	0,9	4	0,4	0,297	10,16	0,0341	63,28	0,01727	0,78
	7	4	0,4	0,297	10,16	0,0384	0,781	0,03053	0,78
	0,9	0,7	2	0,297	10,16	0,0341	63,28	0,00315	172
	7	0,7	2	0,297	10,16	0,0341	63,28	0,01595	0,78
	0,9	4	2	0,297	10,16	0,0341	63,28	0,01583	0,78
	7	4	2	0,297	10,16	0,037	0,781	0,02908	0,78
Fase 180 3er armónico	0,9	0,7	0,4	0,297	10,16	0,0341	63,28	0,00315	172
	7	0,7	0,4	0,297	10,16	0,0341	63,28	0,01303	0,78
	0,9	4	0,4	0,297	10,16	0,0341	63,28	0,01336	0,78
	7	4	0,4	0,297	10,16	0,0341	63,28	0,00315	172
	0,9	0,7	2	0,297	10,16	0,0341	63,28	0,00315	172
	7	0,7	2	0,297	10,16	0,0341	63,28	0,01471	0
	0,9	4	2	0,297	10,16	0,0341	63,28	0,01192	0,78
	7	4	2	0,297	10,16	0,0341	63,28	0,00416	0

A.2. Resultados de porcentajes de acierto para la Función Db

Tabla 40 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el sag.

		SNR 20 dB		SNR 40 dB		SNR 60 dB	
	MagV%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini p 272 sin fase	95	0,336	142,2	0,0266	119,5	0,02182	3,91
	90	0,336	142,2	0,0402	3,906	0,04416	3,91
	50	0,336	142,2	0,2189	3,906	0,22287	3,91
	10	0,399	3,906	0,3976	3,906	0,40158	3,91
Ini p 304 sin fase	95	0,336	117,2	0,0266	144,5	0,01866	3,91
	90	0,336	117,2	0,0388	3,906	0,03795	3,91
	50	0,336	117,2	0,1932	3,906	0,19227	3,91
	10	0,468	3,906	0,3475	3,906	0,3466	3,91
Ini p 272 fase pi/4	95	0,402	3,906	0,4013	3,906	0,40531	3,91
	90	0,404	3,906	0,4035	3,906	0,40747	3,91
	50	0,422	3,906	0,4207	3,906	0,42471	3,91
	10	0,439	3,906	0,438	3,906	0,44195	3,91
Ini p 304 fase pi/4	95	0,336	117,2	0,1732	3,906	0,17411	3,91
	90	0,336	117,2	0,1438	3,906	0,14468	3,91
	50	0,336	117,2	0,0917	3,906	0,09082	3,91
	10	0,448	3,906	0,3272	3,906	0,32631	3,91

Tabla 41 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el swell.

		SNR 20 dB		SNR 40 dB		SNR 60 dB	
	MagV%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini p 272 sin fase	105	0,336	142,2	0,0268	3,906	0,02285	3,91
	110	0,336	142,2	0,0492	3,906	0,04519	3,91
	150	0,336	142,2	0,2279	3,906	0,2239	3,91
	180	0,361	3,906	0,3619	3,906	0,35794	3,91
Ini p 304 sin fase	105	0,336	117,2	0,0266	144,5	0,01992	3,91
	110	0,336	117,2	0,0383	3,906	0,03921	3,91
	150	0,336	117,2	0,1926	3,906	0,19354	3,91
	180	0,336	117,2	0,3084	3,906	0,30928	3,91
Ini p 272 fase pi/4	105	0,398	3,906	0,397	3,906	0,401	3,91
	110	0,396	3,906	0,3949	3,906	0,39884	3,91
	150	0,379	3,906	0,3776	3,906	0,3816	3,91
	180	0,366	3,906	0,3647	3,906	0,36867	3,91
Ini p 304 fase pi/4	105	0,336	117,2	0,2321	3,906	0,23299	3,91
	110	0,336	117,2	0,2615	3,906	0,26242	3,91
	150	0,376	3,906	0,497	3,906	0,49791	3,91
	180	0,553	3,906	0,6736	3,906	0,67453	3,91

Tabla 42 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el Transitorio.

		SNR 20 dB			SNR 40 dB		SNR 60 dB	
Mag V	Frec Hz	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%	
Ini pos 272	0,1 pu	300	0,336	142,2	0,0466	3,906	0,04266	3,91
		1000	0,336	142,2	0,0504	3,906	0,04648	3,91
		3000	0,377	142,2	0,1475	0,781	0,14303	0,78
	0,5 pu	300	0,336	142,2	0,2152	3,906	0,21125	3,91
		1000	0,34	142,2	0,2343	3,906	0,23033	3,91
		3000	0,725	6,25	0,7148	0,781	0,71037	0,78
	4 pu	300	1,689	3,906	1,6904	3,906	1,68641	3,91
		1000	1,842	3,906	1,843	3,906	1,83903	3,91
		3000	5,643	0,781	5,679	0,781	5,67454	0,78
Ini pos 304	0,1 pu	300	0,336	117,2	0,0424	3,906	0,04152	3,91
		1000	0,335	117,2	0,0462	3,906	0,04533	3,91
		3000	0,33	92,19	0,162	0,781	0,14108	0,78
	0,5 pu	300	0,336	117,2	0,211	3,906	0,2101	3,91
		1000	0,351	3,906	0,2301	3,906	0,22918	3,91
		3000	0,697	28,13	0,7293	0,781	0,70841	0,78
	4 pu	300	1,807	3,906	1,6862	3,906	1,68527	3,91
		1000	1,96	3,906	1,8388	3,906	1,83788	3,91
		3000	5,629	0,781	5,6935	0,781	5,67259	0,78

Tabla 43 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el Flicker.

		SNR 20 dB			SNR 40 dB		SNR 60 dB	
Mag V	Frec Hz	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%	
Ini pos 272	0,1 pu	8	0,336	142,2	0,0266	119,5	0,00378	43,8
		15	0,336	142,2	0,0266	119,5	0,00378	43,8
		24	0,336	142,2	0,0266	119,5	0,00378	43,8
	0,5 pu	8	0,336	142,2	0,0266	119,5	0,00378	43,8
		15	0,336	142,2	0,0266	119,5	0,00378	43,8
		24	0,336	142,2	0,0266	119,5	0,00378	43,8
	5 pu	8	0,336	142,2	0,0266	119,5	0,00392	3,91
		15	0,336	142,2	0,0266	119,5	0,02147	3,91
		24	0,336	142,2	0,0266	119,5	0,01312	3,91
Ini pos 304	0,1 pu	8	0,336	117,2	0,0266	144,5	0,00378	68,8
		15	0,336	117,2	0,0266	144,5	0,00378	68,8
		24	0,336	117,2	0,0266	144,5	0,00378	68,8
	0,5 pu	8	0,336	117,2	0,0266	144,5	0,00378	68,8
		15	0,336	117,2	0,0266	144,5	0,00378	68,8
		24	0,336	117,2	0,0266	144,5	0,00378	68,8

	24	0,336	117,2	0,0266	144,5	0,00378	68,8
5 pu	8	0,336	117,2	0,0266	144,5	0,00704	3,91
	15	0,336	117,2	0,0266	144,5	0,0156	3,91
	24	0,336	117,2	0,0266	144,5	0,0188	3,91

Tabla 44 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el Armónico.

	Magnitud del armónico %			SNR 20 dB		SNR 40 dB		SNR 60 dB	
	3er	5to	7mo	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Fase cero	0,9	0,7	0,4	0,336	142,2	0,0266	119,5	0,00378	43,8
	7	0,7	0,4	0,336	142,2	0,0266	119,5	0,01747	3,91
	0,9	4	0,4	0,336	142,2	0,0266	119,5	0,01649	3,91
	7	4	0,4	0,336	142,2	0,0266	119,5	0,03021	3,91
	0,9	0,7	2	0,336	142,2	0,0266	119,5	0,00378	43,8
	7	0,7	2	0,336	142,2	0,0266	119,5	0,0156	3,91
	0,9	4	2	0,336	142,2	0,0266	119,5	0,01462	3,91
	7	4	2	0,336	142,2	0,0266	119,5	0,02834	3,91
Fase 180 3er armónico	0,9	0,7	0,4	0,336	142,2	0,0266	119,5	0,00378	43,8
	7	0,7	0,4	0,336	142,2	0,0266	119,5	0,01403	3,91
	0,9	4	0,4	0,336	142,2	0,0266	119,5	0,01244	3,91
	7	4	0,4	0,336	142,2	0,0266	119,5	0,00378	43,8
	0,9	0,7	2	0,336	142,2	0,0266	119,5	0,00378	43,8
	7	0,7	2	0,336	142,2	0,0266	119,5	0,01589	3,91
	0,9	4	2	0,336	142,2	0,0266	119,5	0,01057	3,91
	7	4	2	0,336	142,2	0,0266	119,5	0,00378	43,8

A.3. Resultados de porcentajes de acierto para la Función Coif

Tabla 45 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el sag.

	MagV%	SNR 20 dB		SNR 40 dB		SNR 60 dB	
		MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini p 272 sin fase	95	0,351	191,4	0,0366	9,375	0,02142	3,13
	90	0,351	191,4	0,0446	3,906	0,04265	3,13
	50	0,351	191,4	0,2082	3,125	0,21249	3,13
	10	0,385	3,125	0,3781	3,125	0,38232	3,13
Ini p 304 sin fase	95	0,351	216,4	0,0366	15,63	0,01949	3,91
	90	0,351	216,4	0,0422	3,125	0,03732	3,91
	50	0,351	216,4	0,1859	3,125	0,18004	3,91
	10	0,351	216,4	0,3296	3,125	0,32329	3,13

Ini p 272 fase pi/4	95	0,383	3,125	0,3766	3,906	0,38083	3,13
	90	0,386	3,125	0,3789	3,125	0,38314	3,13
	50	0,404	3,125	0,3974	3,125	0,40165	3,13
	10	0,423	3,125	0,4159	3,125	0,42016	3,13
Ini p 304 fase pi/4	95	0,351	216,4	0,161	3,125	0,16728	3,13
	90	0,351	216,4	0,1333	3,125	0,13957	3,13
	50	0,351	216,4	0,0884	3,125	0,08918	3,91
	10	0,351	216,4	0,3101	3,125	0,30458	3,91

Tabla 46 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPAs asociado a la función *wavelet* 3.9 en presencia de ruido para el swell.

		SNR 20 dB		SNR 40 dB		SNR 60 dB		
		MagV%	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini p 272 sin fase	105	0,351	191,4	0,0366	9,375	0,02144	3,91	
	110	0,351	191,4	0,0465	3,125	0,04227	3,13	
	150	0,351	191,4	0,2164	3,125	0,2121	3,13	
	180	0,351	191,4	0,3437	3,125	0,33948	3,13	
Ini p 304 sin fase	105	0,351	216,4	0,0366	15,63	0,01791	3,13	
	110	0,351	216,4	0,0366	15,63	0,03587	3,13	
	150	0,351	216,4	0,1778	3,906	0,17953	3,13	
	180	0,351	216,4	0,2848	3,906	0,28727	3,13	
Ini p 272 fase pi/4	105	0,379	3,125	0,3732	3,906	0,3762	3,13	
	110	0,376	3,125	0,3716	3,906	0,37388	3,13	
	150	0,358	3,125	0,358	3,906	0,35538	3,13	
	180	0,351	191,4	0,3478	3,906	0,34249	3,91	
Ini p 304 fase pi/4	105	0,351	216,4	0,2164	3,125	0,2227	3,13	
	110	0,351	216,4	0,2441	3,125	0,25041	3,13	
	150	0,465	3,125	0,4658	3,125	0,47208	3,13	
	180	0,631	3,125	0,6321	3,125	0,63834	3,13	

Tabla 47 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPAs asociado a la función *wavelet* 3.9 en presencia de ruido para el Transitorio.

		SNR 20 dB		SNR 40 dB		SNR 60 dB			
		Mag V	Frec Hz	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
Ini pos 272	0,1 pu	300	0,351	191,4	0,0436	3,125	0,03989	3,91	
		1000	0,351	191,4	0,0452	3,125	0,04657	3,91	
		3000	0,351	191,4	0,1487	3,906	0,13352	3,91	
	0,5 pu	300	0,351	191,4	0,2016	3,125	0,19738	3,13	
		1000	0,351	191,4	0,2228	3,906	0,22807	3,91	
		3000	0,741	0	0,6803	3,906	0,6651	3,91	
	4 pu	300	1,578	3,125	1,5846	3,125	1,58036	3,13	
		1000	1,825	3,906	1,8109	3,906	1,8162	3,91	

		3000	5,261	0	5,3316	3,906	5,31644	3,91
Ini pos 304	0,1 pu	300	0,351	216,4	0,0458	3,125	0,04033	3,91
		1000	0,351	216,4	0,0474	3,125	0,04702	3,91
		3000	0,385	11,72	0,1384	3,906	0,13054	3,91
	0,5 pu	300	0,351	216,4	0,2039	3,125	0,19762	3,13
		1000	0,351	216,4	0,2275	3,906	0,22852	3,91
		3000	0,835	3,906	0,67	3,906	0,66212	3,91
	4 pu	300	1,588	3,125	1,5869	3,125	1,5806	3,13
		1000	1,839	3,906	1,8156	3,906	1,81665	3,91
		3000	5,487	3,906	5,3213	3,906	5,31346	3,91

Tabla 48 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el Flicker.

		SNR 20 dB		SNR 40 dB		SNR 60 dB		
Mag V	Frec Hz	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%	
Ini pos 272	0,1 pu	8	0,351	191,4	0,0366	9,375	0,00297	185
		15	0,351	191,4	0,0366	9,375	0,00297	185
		24	0,351	191,4	0,0366	9,375	0,00297	185
	0,5 pu	8	0,351	191,4	0,0366	9,375	0,00297	185
		15	0,351	191,4	0,0366	9,375	0,00297	185
		24	0,351	191,4	0,0366	9,375	0,00297	185
	5 pu	8	0,351	191,4	0,0366	9,375	0,00438	3,13
		15	0,351	191,4	0,0366	9,375	0,02109	3,13
		24	0,351	191,4	0,0366	9,375	0,01269	3,91
Ini pos 304	0,1 pu	8	0,351	216,4	0,0366	15,63	0,00297	210
		15	0,351	216,4	0,0366	15,63	0,00297	210
		24	0,351	216,4	0,0366	15,63	0,00297	210
	0,5 pu	8	0,351	216,4	0,0366	15,63	0,00297	210
		15	0,351	216,4	0,0366	15,63	0,00315	3,91
		24	0,351	216,4	0,0366	15,63	0,00297	210
	5 pu	8	0,351	216,4	0,0366	15,63	0,00876	3,91
		15	0,351	216,4	0,0366	15,63	0,01664	3,91
		24	0,351	216,4	0,0366	15,63	0,01683	3,13

Tabla 49 Análisis de la detección y umbral utilizando el valor máximo de la magnitud de la salida del FDPA asociado a la función *wavelet* 3.9 en presencia de ruido para el Armónico.

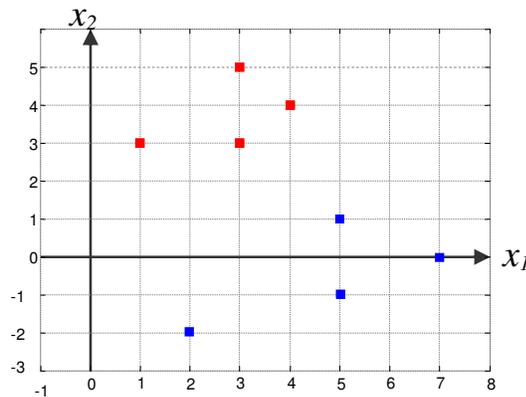
		Magnitud del armónico %			SNR 20 dB		SNR 40 dB		SNR 60 dB	
Fase cero		3er	5to	7mo	MáxSal	ErS%	MáxSal	ErS%	MáxSal	ErS%
	0,9	0,7	0,4		0,351	191,4	0,0366	9,375	0,00429	3,13
	7	0,7	0,4		0,351	191,4	0,0366	9,375	0,01659	3,13

	0,9	4	0,4	0,351	191,4	0,0366	9,375	0,01658	3,13
	7	4	0,4	0,351	191,4	0,0366	9,375	0,02888	3,13
	0,9	0,7	2	0,351	191,4	0,0366	9,375	0,003	3,13
	7	0,7	2	0,351	191,4	0,0366	9,375	0,0153	3,13
	0,9	4	2	0,351	191,4	0,0366	9,375	0,01529	3,13
	7	4	2	0,351	191,4	0,0366	9,375	0,02759	3,13
Fase 180 3er armónico	0,9	0,7	0,4	0,351	191,4	0,0366	9,375	0,00297	185
	7	0,7	0,4	0,351	191,4	0,0366	9,375	0,0144	3,91
	0,9	4	0,4	0,351	191,4	0,0366	9,375	0,01295	3,13
	7	4	0,4	0,351	191,4	0,0366	9,375	0,00302	3,91
	0,9	0,7	2	0,351	191,4	0,0366	9,375	0,0034	3,91
	7	0,7	2	0,351	191,4	0,0366	9,375	0,01654	3,91
	0,9	4	2	0,351	191,4	0,0366	9,375	0,01166	3,13
	7	4	2	0,351	191,4	0,0366	9,375	0,00517	3,91

ANEXO B. EJEMPLO DE CLASIFICACIÓN UTILIZANDO UNA MSV PARA DOS CLASES

Sea el conjunto de datos: $(1,3)$, $(3,3)$, $(3,5)$, $(4,4)$ pertenecientes a una clase y el conjunto de datos $(2,-2)$, $(5,-1)$, $(5,1)$ y $(7,0)$ pertenecientes a otra. En la Figura B.1 se muestra la ubicación de estos puntos en el plano cartesiano

Figura 67 Gráfica del ejemplo de separación de dos clases de los datos para el entrenamiento



- Se debe realizar es la asignación de una etiqueta a cada clase; por ejemplo, para los datos rojos la etiqueta $+1$ y para los datos azules -1 , como se muestra en la Figura 67:

Tabla 50 Datos con etiqueta.

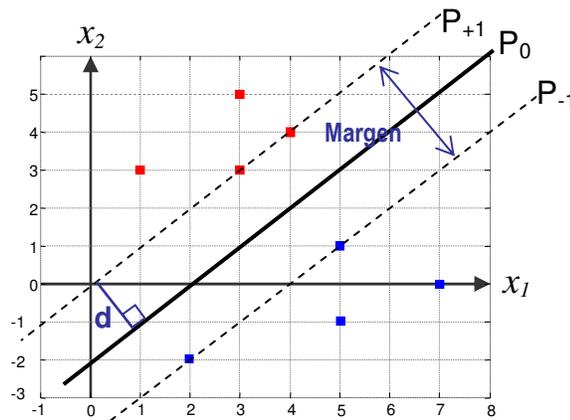
\vec{x}_i		\vec{y}_i
1	3	1
3	3	1
3	5	1
4	4	1
2	-2	-1
5	-1	-1
5	1	-1
7	0	-1

- Entrenamiento de la MSV. El entrenamiento consiste en hallar una función que separe las dos clases. En este ejemplo, los datos están en dos dimensiones y son bien diferenciados, pudiéndose hallar el OSH de

forma gráfica como muestra la Figura 67, teniendo en cuenta que la distancia de los patrones de entrenamiento de cada clase al OSH debe ser máxima.

- Después de determinar el OSH, se generan dos líneas paralelas a éste y se desplazan hasta encontrarse con los primeros parámetros de entrenamiento. Cabe anotar que si es el mejor hiperplano, la distancia de los primeros patrones de entrenamiento a cada lado del plano debe ser la misma (ver Figura 67).

Figura 68 Gráfica del ejemplo de separación de dos clases por los planos clasificadores



Ahora se hallan las ecuaciones de estos planos:

$$P_0 : y = x - 2 \quad \text{reescribiendo :} \quad -x + y + 2 = 0 \quad (48)$$

$$P_{+1} : y = x \quad \text{reescribiendo :} \quad -x + y + 1 = +1 \quad (49)$$

$$P_{-1} : y = x - 4 \quad \text{reescribiendo :} \quad -x + y + 3 = -1 \quad (50)$$

La ecuación (48) es la ecuación del OSH pero ésta debe ser modificada para que \bar{w} y b cumplan con los requisitos de magnitud requeridos en las ecuaciones (51) y (52).

Expresando la ecuación (48) de la forma $P_0 : w \cdot x_i + b = 0$ se tiene:

$$[-1,1] \bullet \begin{bmatrix} x \\ y \end{bmatrix} + 2 = 0 \quad (51)$$

De (51) se tiene $\vec{w} = [-1,1]$ y $b = 2$.

A partir de la Figura 68 se obtiene gráficamente el valor del margen ($2\sqrt{2}$) y reemplazando en (51), se obtiene:

$$2\sqrt{2} = \frac{2}{\|\vec{w}\|} \quad (52)$$

$$\|\vec{w}\| = \frac{1}{\sqrt{2}}$$

Tomando la distancia perpendicular del OSH al origen ($d = \sqrt{2}$ Figura 68 y utilizando la ecuación (13) se tiene:

$$\frac{b}{\|\vec{w}\|} = \sqrt{2} \quad (53)$$

$$b = 1$$

Ahora se debe modificar la magnitud de \vec{w} para que cumpla con las condiciones exigidas.

Normalizando \vec{w} y multiplicando por la magnitud encontrada en (52) se tiene:

$$\vec{w} = \frac{1}{\sqrt{2}} \cdot \frac{1}{\sqrt{2}} \cdot [-1,1] \quad (54)$$

$$\vec{w} = \left[-\frac{1}{2}, \frac{1}{2} \right]$$

Reemplazando los nuevos valores de \vec{w} y b en (51) se obtiene la ecuación del OSH:

$$P_0 : \left(\left[\begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \bullet \begin{bmatrix} x \\ y \end{bmatrix} + 1 \right) = 0 \quad (55)$$

Nótese que la ecuación (48) y (55) representan el mismo plano, sólo que esta última ha sido escalada por la constante $\frac{1}{2}$.

Reescribiendo las ecuaciones (49) y (50) y multiplicándolas por la misma constante se tiene:

$$P_{+1}: -\frac{1}{2}x + \frac{1}{2}y + 1 = 1; P_{+1}: \left(\begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \bullet \begin{bmatrix} x \\ y \end{bmatrix} + 1 \right) = 1 \quad (56)$$

$$P_{-1}: -\frac{1}{2}x + \frac{1}{2}y + 1 = -1; P_{-1}: \left(\begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \bullet \begin{bmatrix} x \\ y \end{bmatrix} + 1 \right) = -1 \quad (57)$$

Las ecuaciones (55), (56) y (57) representan los planos paralelos buscados en el entrenamiento. De esta forma la función de decisión queda:

$$f_{w,b}(\vec{x}_i) = \text{signo} \left(\begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \bullet \begin{bmatrix} x \\ y \end{bmatrix} + 1 \right) \quad (58)$$

Una vez hallada la función de decisión la máquina ya está entrenada. Ahora es posible clasificar nuevos datos.

Para hacer una prueba con un punto cualquiera, por ejemplo (4,5):

$$f_{w,b}(\vec{x}_i) = \text{signo} \left(\begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \bullet \begin{bmatrix} 4 \\ 5 \end{bmatrix} + 1 \right) = \text{signo}(1.5) = +1 \quad (59)$$

Este dato lo ha clasificado con etiqueta +1, perteneciente a los datos rojos.

Otro punto a clasificar podría ser (4,0):

$$f_{w,b}(\vec{x}_i) = \text{signo} \left(\begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \bullet \begin{bmatrix} 4 \\ 0 \end{bmatrix} + 1 \right) = \text{signo}(-1) = -1 \quad (60)$$

Este dato se ha clasificado como -1, perteneciente a los datos azules.

ANEXO C. PORCENTAJES DE ACIERTO UTILIZANDO DIFERENTES MÉTODOS DE CLASIFICACIÓN

En [Vega, Duarte & Ordóñez, 06] se propone la clasificación de perturbaciones de la calidad de la energía eléctrica, más específicamente las perturbaciones estudiadas en este trabajo. En la Tabla 51 se presentan los porcentajes de acierto para 4 diferentes técnicas de clasificación: Las redes neuronales ratificales (RNAs) en este caso están la Perceptrón multicapa (sigla en inglés MPL multi-layer perceptron) y por otro lado la red *Kohonen* LVQ. También está la clasificación utilizando el teorema de Bayes y por último la clasificación utilizando las máquinas de soporte vectorial.

Cabe resaltar que la intención de este trabajo no es demostrar que una técnica es mejor que otra, si no la de presentar los resultados que se obtuvieron con ellas. Los parámetros de cada una de las técnicas se presentan a continuación.

Tabla 51 Características de las técnicas de clasificación.

Tipo de clasificación	Características principales
MPL	Función de desempeño Feedforward, función de activación tangente sigmoideal, 3 capas oculta y 1 de salida y [8 6 4 1] neuronas por capa.
Kohonen LVQ	Error máximo permitido 0,001. Número de iteraciones 800.
Bayes	Se aplica la regla de Bayes y se utiliza el misma distribución de probabilidad para cada una de las 5 clases, es decir, 20%.
SVM	Tipo de kernel RBF, parámetro del kernel $\sigma = 0,5$. Parámetro de penalización $C = 2\ 048$.

Tabla 52 Porcentajes de acierto para diferentes técnicas de clasificación con los patrones obtenidos en [Vega, Duarte & Ordóñez, 06].

Perturbaciones	Porcentaje de acierto MLP[%]	Porcentaje de acierto LVQ Kohonen [%]	Porcentaje de acierto BAYES [%]	Porcentaje de acierto SVM [%]
<i>Sag</i>	93	55	92	98
<i>Swell</i>	97	56	51	98
<i>Flicker</i>	86	90	85	100
Transitorio	79	60	0	73
Oscilatorio	95	50	0	100

Para este experimento se utilizaron 700 perturbaciones para entrenar y/o validar y 200 perturbaciones para las prueba de clasificación final. Los patrones utilizados para las pruebas fueron obtenidos a partir del cálculo de la energía de los coeficientes *wavelet*, utilizando el filtro Db4 y la ecuación de diferencias de energías (8), propuesta por [Resende, 01] y utilizada en [Vega, Duarte &

Ordóñez, 06]. De la Tabla 52, se puede observa que la técnica de clasificación MSV presenta buenos resultados ante los patrones utilizados en estas pruebas.