

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY

CAMPUS MONTERREY

DIVISION DE MECATRONICA Y TECNOLOGIAS DE INFORMACION

PROGRAMA DE GRUADOS



TECNOLÓGICO
DE MONTERREY

DIAGNOSTICO DE FALLAS EN REDES ELECTRICAS
UTILIZANDO TRANSFORMADA DE HILBERT
Y CLASIFICADORES DIFUSOS

T E S I S

PRESENTADA COMO REQUISITO PARCIAL PARA
OBTENER EL GRADO ACADEMICO DE:
MAESTRIA EN CIENCIAS EN AUTOMATIZACION

P O R :

DIANA VICTORIA TORRES LOZANO

MONTERREY, N. L.


DICIEMBRE DE 2010

**INSTITUTO TECNOLÓGICO Y DE ESTUDIOS
SUPERIORES DE MONTERREY**

CAMPUS MONTERREY

DIVISION DE MECATRONICA Y TECNOLOGIAS DE INFORMACION

PROGRAMA DE GRADUADOS



**TECNOLÓGICO
DE MONTERREY**

DIAGNOSTICO DE FALLAS EN REDES ELECTRICAS
UTILIZANDO TRANSFORMADA DE HILBERT
Y CLASIFICADORES DIFUSOS

T E S I S

PRESENTADA COMO REQUISITO PARCIAL PARA
OBTENER EL GRADO ACADEMICO DE:
MAESTRIA EN CIENCIAS EN AUTOMATIZACION

POR:

DIANA VICTORIA TORRES LOZANO

MONTERREY, N. L.

DICIEMBRE DE 2010

Instituto Tecnológico y de Estudios Superiores de Monterrey

Campus Monterrey

División de Mecatrónica y Tecnologías de la Información

Programa de Graduados

Maestría en Ciencias en Automatización

Tesis

**Diagnóstico de Fallas en Redes Eléctricas utilizando
Transformada de Hilbert y Clasificadores Difusos**

por

Diana Victoria Torres Lozano

798252

Monterrey, N.L., Diciembre 2010

Dedico esta tesis a mis padres Federico y Julia

A mis hermanas Martha y Lina

A mi novio Cesar Villamil

por su apoyo económico, moral, por ser la inspiración para continuar,

por toda la paciencia que han tenido durante este tiempo,

por brindarme tanto cariño, por ser excelentes guías,

y por esa gran compañía a pesar de la distancia.

AGRADECIMIENTOS

Agradezco al Instituto Tecnológico y de Estudios Superiores de Monterrey ITESM, por todas las herramientas provistas. Un agradecimiento especial a mi asesor el Dr. Luis Eduardo Garza Castañón ya que sin su interés, soporte y colaboración, esta tesis no hubiese sido posible. Del mismo modo un agradecimiento especial al Dr. Rubén Morales y al Dr. Francisco Palomera por sus comentarios que ayudaron a enriquecer este trabajo.

Un agradecimiento al Ingeniero y candidato a doctor, Ivan Aldaya por toda su colaboración y tiempo dedicados, al Dr. Federico Torres por su apoyo en la elaboración de este trabajo.

A mis amigos, Violeta, Israel, Roberto, Hector, Fernando y Fernando, Vicente, Paola, Andrés, Jenny por su ayuda y compañía durante este tiempo.

Diana Victoria Torres Lozano

Instituto Tecnológico y de Estudios Superiores de Monterrey

Diciembre 2010

INDICE

1. CAPITULO 1	1
INTRODUCCION	1
1.1. Motivación y Generalidades.....	1
1.2. La Propuesta.....	2
1.2.1. El Objetivo.....	2
1.2.2. Estrategia Conceptual.....	3
1.3. Contribución de la Tesis.....	3
1.4. Organización de la Tesis.....	3
2. CAPITULO 2	5
FUNDAMENTOS	5
2.1. Transformada de Hilbert.....	5
2.1.1. Propiedades de la Transformada de Hilbert.....	7
2.1.1.1. Propiedad 1.....	7
2.1.1.2. Propiedad 2.....	8
2.1.1.3. Propiedad 3.....	8
2.1.1.4. Propiedad 4.....	9
2.2. Lógica difusa en reconocimiento de patrones.....	9
2.2.1. Teorema de Fuzzy c-Means.....	10
2.2.2. Validación de Agrupaciones.....	10
2.2.3. Generalización de Fuzzy c-Means.....	11
2.3. Otros conceptos básicos.....	12
2.3.1. Coordenadas esféricas.....	12
2.3.2. Breve introducción a la teoría de la varianza.....	13
3. CAPITULO 3	14
ESTADO DEL ARTE	14
3.1. Casos de aplicación Hilbert.....	14
3.2. Casos de aplicación de detección de fallas en redes eléctricas.....	16
4. CAPÍTULO 4:	18
DESARROLLO DEL ALGORITMO	18
4.1. Descripción de la red eléctrica de comprobación.....	18
4.1.1. Selección del parámetro a analizar.....	20
4.2. Aplicación de la transformada de Hilbert y su análisis en frecuencia.....	24
4.2.1. Análisis para un solo nodo con falla.....	24
4.2.1.1. Clasificación de las fallas mediante Fuzzy c-Means.....	33
4.2.1.2. Análisis para 2 Nodos con distinto tipo falla.....	35
4.2.1.3. Análisis para un escenario completo.....	38
4.2.1.4. Descripción del Diagrama de flujo.....	40
4.2.1.5. Clasificación Jerárquica de las Fallas.....	44
4.2.1.6. Tipos de fallas y su ubicación.....	47
5. CAPITULO 5	55
Hilbert - Varianza y la Transformada Onduleta	55

5.1.	Algoritmo Hilbert - Varianza	55
5.2.	Aplicación de la Transformada Onduleta (Wavelet).....	58
6.	CAPITULO 6.....	65
	PRUEBAS Y RESULTADOS	65
6.1.	Clase, Tipo, Nodo y Tiempo (Primera Parte)	65
6.2.	Comprobación de tipos de fallas (Segunda Parte)	74
6.3.	Comprobación de los Tiempos estimados (Tercera Parte)	77
6.4.	Pruebas con Ruido (Cuarta parte)	79
7.	CAPITULO 7.....	82
	CONCLUSIONES Y TRABAJO FUTURO	82
7.1.	Ventajas	82
7.2.	Limitaciones.....	83
7.3.	Trabajo futuro.....	83
	REFERENCIAS	85
	APENDICES	88
Apéndice A:	Parámetros de la Red IEEE.....	89
Apéndice B:	Tablas de escenarios simulados.....	92
Apéndice C:	Descripción de los archivos de datos de la REC	96
Apéndice D:	Código para el análisis de Onduleta	99
Apéndice E:	Código del algoritmo Hilbert –Fuzzy c Means.....	101
Apéndice F:	Efectos del ruido sobre una señal.....	105

Lista de Figuras

Figura 1. Respuesta en fase del sistema transformador de Hilbert	6
Figura 2. Sistema de coordenadas cartesianas y su relación con las coordenadas esféricas	12
Figura 3. Distribución de la red eléctrica	19
Figura 4. Señal original sin falla 3 líneas de Nodo 2	21
Figura 5. Señal original sin falla 3 líneas de Nodo 2 tiempo entre 1 y 100.....	21
Figura 6. Tres fases del nodo 3 con fallas entre línea A y línea B.....	22
Figura 7. Variación en la amplitud de la señal cuando se presenta la falla línea-línea	22
Figura 8. Cambio en la línea de las líneas que presentan fallas en el instante en que estas se presentan	22
Figura 9. Líneas A,B y Cs del nodo 3 con fallas línea A a tierra y línea B a tierra.....	23
Figura 10. La amplitud de las líneas en falla es igual a cero durante la presencia de la falla	23
Figura 11. La fase de las líneas en falla se pierde por completo.....	23
Figura 12. Gráfica de la obtención de los ángulos de fase	25
Figura 13. Gráfica de las fases	26
Figura 14. Señales de las fases con y sin falla. Gráfica (a), línea o fase sin falla. Gráfica (b), línea o fase con falla.....	27
Figura 15. Señales de las fases con falla. Señal (a)sin filtro, (b) con filtro	27
Figura 16. Angulo de diferencia.....	28
Figura 17. Angulo de diferencia Nodo 5.....	29
Figura 18. Derivada de la diferencia de ángulo.....	29
Figura 19. Derivada de la diferencia para los 24 nodos	30
Figura 20. Derivada de la diferencia para el Nodo 3	31
Figura 21. Derivada de la diferencia de ángulo sin los transitorios	31
Figura 22. Derivada de la diferencia de ángulo en el primer octante.....	32
Figura 23. Aplicación de fcm a la derivada del desfase de los datos	33
Figura 24. Diagrama de flujo para agrupación fuzzy de un solo nodo con falla.....	34
Figura 25. Agrupación de datos para dos nodos con falla.....	35
Figura 26. Agrupación Fuzzy c-means de dos nodos con tipo de falla línea a línea.....	36
Figura 27. Agrupación Fuzzy c-means de dos nodos con tipo de falla línea a tierra.....	37
Figura 28. Agrupación Fuzzy c-Means de dos nodos con tipo de falla línea a tierra, vista 3D desde diferente ángulo.....	37
Figura 29. Agrupación Fuzzy c-means para todos los casos del escenario	38
Figura 30. Derivada de diferencia sin transitorios para todos los datos del escenario	39
Figura 31. Derivada de las líneas con falla a tierra.....	39
Figura 32. Diagrama de flujo del Algoritmo para un escenario completo.....	40
Figura 33. Gráfica de la extracción de la fase de cada senoidal de los 24 nodos	41
Figura 34. Vector de ángulos de la señal de los 24 nodos.....	42
Figura 35. A la izquierda se encuentran los vectores de ángulo sin filtrar a la derecha se ha aplicado el filtro de promedio móvil	42
Figura 36. Resultado de la diferencia de fases	43
Figura 37. Derivada de la fase en 2D con respecto al tiempo y 3D con respecto a las tres fases	43
Figura 38. Agrupación Fuzzy de la derivada de la fase	44
Figura 39. Representación de fallas a tierra indicando tiempo y nodo en que se presenta	45
Figura 40. Derivada de la diferencia del ángulo de cobertura antes (izq) y después (der) de hacer el agrupamiento por fcm	45
Figura 41. Representación de fallas línea- línea indicando tiempo y nodo en que se presentan.....	46
Figura 42. Representación conjunta de las fallas .El color indica el tipo de falla: Rojo, fallas línea – tierra. Verde falla línea – línea. También ubica el nodo y tiempo de la falla.....	46

Figura 43. Representación grafica de la posición de las fallas en un plano tridimensional.....	48
Figura 44. Manera de ubicar las fallas en las líneas.....	49
Figura 45. Localización de la falla A-C en el plano esférico	50
Figura 46. Localización de la falla B-C en el plano esférico.....	50
Figura 47. Localización de la falla A-B en el plano esférico	51
Figura 48. Resultado del algoritmo Hilbert Fuzzy c-Means.....	51
Figura 49. Diagrama De flujo del algoritmo Hibertl Fuzzy c-Means	53
Figura 50. Diagrama a Bloques del Algoritmo Hilbert – Fuzzy c-Means.....	53
Figura 51. Gráfica de la diferencia de los ángulos.....	55
Figura 52. Gráfica la diferencia de ángulo de cobertura después de la aplicación del filtro de promedio móvil.	56
Figura 53. Representación de la varianza en los 24 nodos 3 líneas	56
Figura 54. Representación de la varianza en los 24 nodos Líneas A-B	57
Figura 55. Representación de las varianzas en todos los casos	57
Figura 56. Transformada onduleta para señal con falla de fase A y B a tierra Nodo 3	59
Figura 57. Transformada onduleta para señal con falla de fase A y B a tierra nodo 3	60
Figura 58. Transformada onduleta para señal sin fallas nodo 3.....	61
Figura 59. Transformada onduleta para señal con falla de línea a línea.....	62
Figura 60. Salida de la onduleta para Falla en nodo 3 y 19.....	63
Figura 61. Salida de la onduleta para Falla en nodo 3	63
Figura 62. Salida de la onduleta para Falla en nodos 2, 3, 7 y 24.....	64
Figura 63. Escenario Datos4F4-9-23-13 con radio $\rho 18$ con error en detección de fallas línea a línea	73
Figura 64. Escenario Datos4F4-9-23-13 con radio $\rho 6$ con error en detección de fallas línea a línea	73
Figura 65. Tiempo de la falla original Vs Tiempo estimado de la falla en el escenario Test 4	78
Figura 66. Tiempo de la falla original Vs Tiempo estimado de la falla en el escenario Test 10	79
Figura 67. Efectos del ruido en diferentes porcentajes sobre una señal	81

Lista de Tablas

Tabla 1. Tipos de Fallas.....	18
Tabla 2 Tipo de fallas a tierra.....	48
Tabla 3. Ubicación y tipo de falla a tierra en la red.....	49
Tabla 4. Diferentes valores de los coeficientes en las pruebas realizadas para diferentes tipos de falla en el nodo 3.....	61
Tabla 5. Eficiencia para Escenarios con una sola falla utilizando el algoritmo Hibert – Fuzzy c-Means.....	66
Tabla 6. Eficiencia para Escenarios con una sola falla utilizando el algoritmo Hilbert – Varianza.....	66
Tabla 7. Eficiencia para Escenarios con dos fallas utilizando el algoritmo Hibert – Fuzzy c-Means.....	67
Tabla 8. Eficiencia para Escenarios con dos fallas utilizando el algoritmo Hilbert – Varianza.....	67
Tabla 9. Eficiencia para Escenarios con tres fallas utilizando el algoritmo Hibert – Fuzzy c-Means.....	68
Tabla 10. Eficiencia para Escenarios con tres fallas utilizando el algoritmo Hilbert – Varianza.....	68
Tabla 11. Eficiencia para Escenarios con cuatro fallas utilizando el algoritmo Hibert – Fuzzy c-Means.....	69
Tabla 12. Eficiencia para Escenarios con cuatro fallas utilizando el algoritmo Hilbert – Varianza.....	69
Tabla 13. Eficiencia para Escenarios con cinco fallas utilizando el algoritmo Hibert – Fuzzy c-Means.....	70
Tabla 14. Eficiencia para Escenarios con cinco fallas utilizando el algoritmo Hilbert – Varianza.....	70
Tabla 15. Eficiencia para Escenarios con diferente número de fallas utilizando el algoritmo Hibert – Fuzzy c-Means.....	71
Tabla 16. Eficiencia para Escenarios con diferente número de fallas utilizando el algoritmo Hilbert – Varianza.....	72
Tabla 17. Comprobación del tipo de falla detectada.....	74
Tabla 18. Porcentaje de eficiencia por tipo de falla para el modelo RBH.....	75
Tabla 19. Porcentaje de eficiencia por tipo de falla para el modelo Hilbert- Fuzzy c-Means escenarios de la Tabla.....	75
Tabla 20. Porcentaje de eficiencia por tipo de falla para el modelo Hilbert- Varianza escenarios Tabla.....	76
Tabla 21. Porcentaje de de eficiencia dependiendo del número de fallas.....	76
Tabla 22. Promedio de tiempos de estimado de inicio de falla.....	77
Tabla 23. Tiempo estimado de inicio de fallas para diferentes escenarios.....	78
Tabla 24. Resultado de las pruebas con adición de ruido en los datos para el algoritmo Hilbert Fuzzy c-Means.....	80
Tabla 25. Convenciones usadas en la tabla de resultados de las pruebas con ruido.....	80
Tabla 26. Resultado de las pruebas con adición de ruido en los datos para el algoritmo Hilbert Varianza.....	80

RESUMEN

En la medida en que el ingenio humano avanza, se crean nuevas máquinas y sistemas tales como los aviones, los autos, los trenes, los hospitales con todo su equipamiento, sistemas de distribución y producción de agua, sistemas de comunicaciones, sistema de producción industrial, sistemas de distribución de energía entre muchos otros. La dependencia humana hacia los servicios que brindan estos inventos aumenta, ya que éstos proporcionan grandes ventajas para el mejoramiento del estilo y calidad de vida. Hoy en día, no es posible concebir la falta de alguno de estos servicios sin que sea reemplazado por otro más eficiente; pues una situación contraria representa un retroceso para la humanidad.

Se requiere de la intervención de la energía eléctrica para que las máquinas operen, los sistemas puedan llevar sus servicios hasta el usuario final etc. En el momento en que se produzca una falla dentro de la red y se carezca de este vital elemento, todos los procesos y servicios estarán destinados a sufrir un retraso hasta que se recupere nuevamente el servicio eléctrico. Si se toma el caso de una planta de producción, un paro en el suministro de energía eléctrica implica que se dejen de fabricar miles de piezas durante el tiempo que dure la falla; esto conlleva al incumplimiento hacia el cliente y a una sanción para la planta de producción. Estas sanciones de tipo económico suelen tener costos elevados, que pueden ser evitados o disminuidos si se tienen las herramientas adecuadas para hacerlo. Una manera de reducir los tiempos improductivos y sus consecuencias, es a través de una rápida y acertada detección del tipo de falla y el lugar donde se produce, para darle rápida atención.

Por las razones anteriores ha surgido como propuesta de investigación, para obtener el título de Maestría en Ciencias con especialidad en Automatización, la realización del proyecto titulado “Diagnóstico de Fallas en Redes eléctricas utilizando Transformada de Hilbert y Clasificadores Difusos” buscando de esta forma hacer un aporte a la búsqueda del mejoramiento continuo hacia la industria de la producción y la industria de prestación de servicios.

Este tema de detección de fallas ha sido abordado anteriormente con métodos tales como Redes de Petri, Métodos de Regresión y Redes Bayesianas Híbridas. Aunque en este último trabajo se han obtenido buenos resultados, se pretende en el presente proyecto mejorar aún más los resultados y proporcionar información del instante que se presentó la falla.

Las contribuciones principales de este trabajo son:

- Generar un nuevo algoritmo basado en el uso de la transformada de Hilbert para la extracción de los parámetros de los datos a analizar, apoyando estos resultados con métodos de clasificación difusa.
- Expandir el conocimiento de herramientas para el análisis de señales lineales y no estacionarias, que permitan conocer su comportamiento de manera clara y precisa, para la detección de fallas.

1. CAPITULO 1

INTRODUCCION

1.1. Motivación y Generalidades

Las redes de energía eléctrica se comenzaron a construir desde hace un poco más de 100 años, y desde ese momento la humanidad ha tenido ventajas inimaginables comparadas con las que tuvieron quienes no contaron con este gran privilegio. En la actualidad, las redes eléctricas llegan a millones de usuarios alrededor del mundo. Se han convertido en elementos de vital importancia para la existencia humana. Las encontramos en los hogares, hospitales, centros comerciales, fábricas y en todos los sitios donde existen procesos industriales.

A pesar de contar con tantos años de historia, gran cantidad de aplicaciones y muchos avances, las redes eléctricas hoy en día son vulnerables al ambiente que las rodea; esto hace que su funcionamiento no sea cien por ciento confiable, es decir, que se presenten fallas durante su actividad. Desde este punto de vista, nace el interés de buscar técnicas que contribuyan al mejoramiento de la fiabilidad del servicio.

Debido a la gran complejidad en la estructura de las actuales redes eléctricas, que crecen de acuerdo con el crecimiento de la población y de su industria, el hecho de detectar una falla y ubicar donde es realmente generada, ha sido una labor bastante estudiada. Las fallas producidas en un sistema físico, tienen grandes consecuencias negativas para la seguridad de los trabajadores, el crecimiento de la industria, implicaciones económicas, alteraciones y daños en equipos, y por supuesto, cuando se presenta a gran escala, las consecuencias también pueden ser sociales, como es el caso que se presenta en la actualidad, (2010), en países como Venezuela cuyo servicio se ve continuamente interrumpido debido a fallas dentro de la red debido a problemas de vida útil de los componentes sin rápida atención lo cual afecta en gran medida a los pobladores.

Cuando se habla de una falla eléctrica ésta puede ser producida por:

- Condiciones ambientales,
- Modo de instalación de la red,
- Vida útil de los componentes que la integran,
- Otros.

En el ámbito eléctrico, estas causas han llevado a clasificar las fallas en dos grandes grupos:

- Fallas simétricas
- Fallas asimétricas.

En principio, todas las redes eléctricas son del tipo trifásicas. Las fallas simétricas involucran las tres fases del sistema y son relativamente fáciles de evaluar y representan cerca del 5% de los casos de fallas.

Las fallas asimétricas involucran:

- Algún tipo de desbalance en las corrientes de carga
- Fallas entre líneas y tierra.
- Fallas de línea a línea.

Los problemas entre las líneas y a tierra representan cerca del 70% de las fallas, y los problemas entre líneas el 25 % [7] [24]. Ambos tipos de fallas son la materia de estudio en el presente proyecto.

Lo que se pretende con el planteamiento de este trabajo, es desarrollar un algoritmo de detección y diagnóstico de fallas basado en técnicas de transformada de Hilbert y Clasificadores Difusos para las redes eléctricas industriales. Se tomará un caso de estudio específico, el cual se menciona más adelante. Uno de los retos a superar consiste en lograr el acertado manejo de los datos, ya que una red contiene enorme cantidad de variables. Adicional a esto, presenta efectos en cascada que hacen que se presenten causas ficticias de fallas, es decir, que la red proporciona información cierta y pseudo- información.

1.2. La Propuesta

1.2.1. El Objetivo

El objetivo general del presente trabajo es desarrollar un algoritmo efectivo para la detección y diagnóstico de fallas en una red eléctrica industrial. Dichas fallas pueden ser simétricas o asimétricas y podrán presentarse de manera simple o múltiple con un máximo de 5 fallas simultáneas en la red.

Los objetivos particulares a cumplir dentro de este trabajo de investigación son:

1. Búsqueda de una herramienta más eficiente, que las desarrolladas hasta el momento en la misma área (redes Bayesianas híbridas) para la detección y diagnóstico de fallas.
2. Conocer dónde, cual y cuando se presenta una falla dentro de la red eléctrica industrial en estudio.
3. Reconocimiento del comportamiento de los datos y clasificación de éstos para la identificación de las fallas.
4. Validación del método encontrado con los resultados obtenidos en el algoritmo desarrollado anteriormente de redes Bayesianas híbridas y el algoritmo alterno Hilbert – Varianza en cuanto a la efectividad del algoritmo en clase de falla, tipo de falla, nodo en que se encuentra la falla y tiempo estimado de inicio de falla.

1.2.2. Estrategia Conceptual

Dentro de los algoritmos para la detección y diagnóstico de fallas en redes eléctricas se han desarrollado algunos, utilizando redes neuronales, redes Bayesianas, teorías óptimas entre otros [7][28] los cuales han tenido resultados favorables pero no los mejores. Para el desarrollo de la presente investigación se hizo uso de análisis de señales, extrayendo de ellas uno de los parámetros que las componen y efectuando un posterior estudio de acuerdo a su resultado. Métodos similares han sido aplicados anteriormente a sistemas mucho menos complejos que la red eléctrica que se plantea; pero cuyo principio es lo suficientemente robusto para el caso en estudio. Se usa la transformada Hilbert para la extracción de los parámetros a analizar de la señal de origen, métodos matemáticos para su análisis y hasta este punto corresponderá el acondicionamiento de los datos, posteriormente se utilizará el algoritmo Fuzzy c-Means para la clasificación de los datos resultantes del acondicionamiento lo cual con lleva a la detección y diagnóstico de fallas.

1.3. Contribución de la Tesis

- Ampliar el uso de la Transformada de Hilbert como herramienta para la detección de fallas en sistemas complejos como lo es una red eléctrica industrial teniendo en cuenta los problemas adicionales que conlleva el tener un sistema en red como el manejo de mayor número de variables y fallas existentes en nodos aledaños a lo que tienen falla.
- Hacer uso extendido de la información proporcionada por el algoritmo Fuzzy c-Means para detectar la clase de falla, tipo de falla, nodo en que se presenta la falla y un parámetro adicional que no se había detectado en ninguna aplicación anterior que corresponde al tiempo estimado de inicio de falla.
- Avanzar en el estudio de la detección de fallas, para optimizar el funcionamiento de las redes eléctricas, y así lograr el mejoramiento de los servicios y la reducción de pérdidas por retrasos en el área industrial. Para ello, se tomarán en cuenta los resultados obtenidos en los estudios realizados anterior mente en la misma área pero con algoritmos diferentes que han basado su estudio en el análisis de parámetros diferentes al desarrollado en esta tesis.
- Mejorar la inmunidad al ruido durante el proceso de detección de fallas, mediante la búsqueda de un algoritmo que no sea sensible a la magnitud de la señal.

1.4. Organización de la Tesis

La organización de la presente tesis es como se indica a continuación:

En el capítulo 1 se hace la introducción al tema de las fallas en las redes eléctricas y porque es objeto de análisis para el desarrollo como tema de tesis; así mismo se plantean los objetivos a desarrollar a través del proyecto.

El capítulo 2 explica los fundamentos matemáticos y físicos sobre los cuales se basó el desarrollo del algoritmo utilizado.

El capítulo 3 indaga sobre las aplicaciones que han tenido los métodos utilizados en la detección de fallas en redes eléctricas.

El capítulo 4 explora el métodos de análisis de datos y describe, paso a paso, el desarrollo del algoritmo Hilbert – Fuzzy c-Means, hasta obtener los resultados finales.

El capítulo 5 describe brevemente otro de las métodos de clasificación de los datos, específicamente el método conocido como Hilbert-Varianza y se da una corta explicación de el método de transformada onduleta inicialmente explorado para el análisis de datos y porqué este método no fue finalmente utilizado.

El capítulo 6 hace un resumen de las pruebas realizadas con los algoritmos Hilbert-Fuzzy c-Means y Hilbert Varianza; además se comparan estos resultados con los obtenidos por un desarrollo anterior para detección de fallas en la misma red eléctrica conocido como RBH.

En el capítulo 7 se encuentran las conclusiones y trabajo futuro.

2. CAPITULO 2 FUNDAMENTOS

2.1. Transformada de Hilbert

El tema de la detección y diagnóstico de fallas ha sido ampliamente estudiado aplicando diferentes métodos para la obtención de resultados. Uno de estos métodos es el de la transformada de Hilbert.

La transformada de Hilbert es útil para calcular el contenido del espectro de frecuencias de una señal de energía o de potencia. Al analizar y diseñar filtros selectivos en frecuencia, permite separar las señales según su espectro. Este proceso se denomina “Discriminación en Frecuencia” o también “Discriminador de Frecuencias”.

Otro método para separar señales se basa en la “Selectividad en Fase”, también llamado “Discriminación en Fase”. Se desfasan las señales pertinentes de modo que se puedan separar fácilmente. El caso más sencillo consiste en desfasar una señal en π radianes o 180° , lo que se consigue invirtiendo la polaridad de la señal o multiplicando por -1 . El desfasar todas las componentes de una señal en 180° requiere el uso de un *transformador ideal*. Entiéndase por transformador ideal, un transformador que no presenta capacitancias, ni inductancias parásitas.

Otro desfase de interés es el de $\pm\frac{\pi}{2}$ o $\pm 90^\circ$. En particular, cuando los componentes angulares de una señal han sido desfasadas $\pm 90^\circ$, la función resultante se denomina *Transformada de Hilbert* de la señal. Se denota por $\mathcal{H}(f)$, aunque también se encuentra denotada como $\hat{g}(t)$.

Sea $g(t)$ una señal cuya transformada de Fourier es $G(f)$ o $G(\omega)$. La transformada de Hilbert de $g(t)$ se denota por $\hat{g}(t)$ y está dada por la ecuación (1). Claramente se puede ver que la transformada de Hilbert es un operador lineal.

$$\hat{g}(t) = g(t) * \frac{1}{\pi t} = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{g(\tau)}{t-\tau} d\tau \quad (1)$$

Esta ecuación define una integral impropia, puesto que para $t = \tau$ el integrando presenta una singularidad o indeterminación. Para evitar este problema se calcula la integral de forma simétrica en torno a $t = \tau$, como se muestra en la ecuación (2).

$$\int_{-\infty}^{\infty} \frac{g(\tau)}{t-\tau} d\tau = \lim_{\epsilon \rightarrow 0} \left[\int_{-\infty}^{t-\epsilon} \frac{g(\tau)}{t-\tau} d\tau + \int_{t+\epsilon}^{\infty} \frac{g(\tau)}{t-\tau} d\tau \right] \quad (2)$$

La transformada inversa de Hilbert puede calcularse mediante la ecuación (3), $g(t)$ y $\hat{g}(t)$ se dice que constituyen un par transformado de Hilbert.

$$g(t) = -\frac{1}{\pi} \int_{-\infty}^{\infty} \frac{\hat{g}(\tau)}{t-\tau} d\tau \quad (3)$$

De la definición de la transformada Hilbert se deduce que $\hat{g}(t)$ puede interpretarse como la convolución de $g(t)$ con la señal $\frac{1}{\pi t}$, ecuación (4):

$$\hat{g}(t) = g(t) * \frac{1}{\pi t} \quad (4)$$

Por la propiedad de la convolución de la transformada de Hilbert, la convolución de dos funciones en el dominio del tiempo, es transformada dentro de la multiplicación de sus transformadas de Fourier, en el dominio de la frecuencia.

Para la función del tiempo:

$$\frac{1}{\pi t} \leftrightarrow -j \operatorname{sgn}(f) \quad (5)$$

Donde $\operatorname{sgn}(f)$ es el signo de la función en el dominio de la frecuencia dado por:

$$\operatorname{sgn}(f) = \begin{cases} 1, & f > 0 \\ 0, & f = 0 \\ -1, & f < 0 \end{cases} \quad (6)$$

El par transformado de Fourier de la ecuación (5) es resultado de la aplicación de la propiedad de dualidad de la transformada de Fourier :

$$\operatorname{sgn}(t) = \frac{1}{j\pi f} \quad (7)$$

Si la transformada de Fourier de $g(t)$ es $G(f)$, entonces, por la propiedad de la convolución, se deduce que la transformada de Fourier de $\hat{g}(t)$, $\hat{G}(f)$, está dada por (8):

$$\hat{G}(f) = -j \operatorname{sgn}(f)G(f) \quad (8)$$

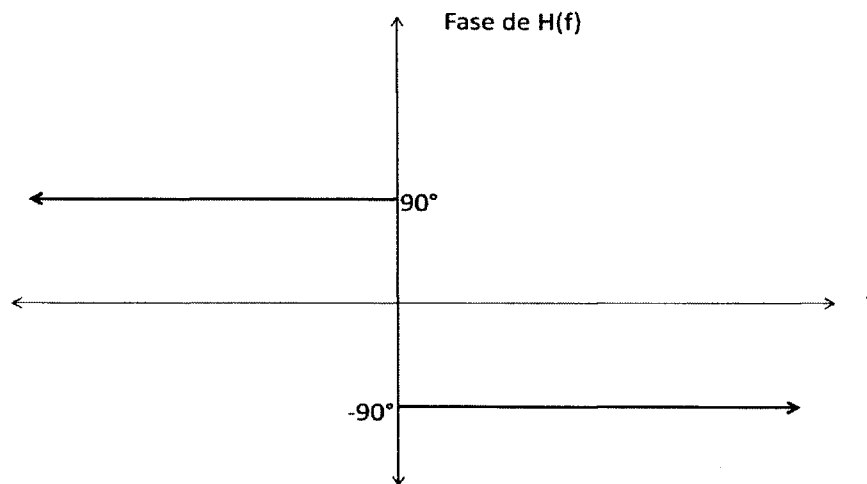


Figura 1. Respuesta en fase del sistema transformador de Hilbert

Se puede calcular la transformada de Hilbert de una señal $g(t)$ haciéndola pasar por un sistema LTI, (Lineal Invariante en el Tiempo), con respuesta al impulso $\frac{1}{\pi t}$ o también, con la función de transferencia $-j \operatorname{sgn}(f)$. Este sistema introduce un desfase de $-\frac{\pi}{2}$ (-90°), para frecuencias positivas y de $\frac{\pi}{2}$, (90°) para frecuencias negativas. En la Figura 1 puede verse la respuesta en fase de este sistema. $\mathcal{H}(f)$ es la transformada de Hilbert de la señal.

La amplitud de la señal a la salida de este sistema, no se modifica para ninguna frecuencia.

Este sistema ideal se denomina *Transformador de Hilbert*. Tiene aplicaciones importantes, por ejemplo:

1. Se puede utilizar para tener selectividad en fase, para un tipo especial de modulación en amplitud denominado modulación en banda lateral única o SSB.
2. Proporciona la base matemática necesaria para representar las señales paso banda.

La transformada Hilbert se puede aplicar a cualquier señal que tenga transformada Fourier y por lo tanto a señales de potencia y de energía usadas en sistemas eléctricos y de comunicaciones [25].

2.1.1. Propiedades de la Transformada de Hilbert

2.1.1.1. Propiedad 1

Una señal $g(t)$ y su transformada de Hilbert $\hat{g}(t)$, tienen la misma densidad espectral, la misma amplitud espectral y función de auto-correlación.

Sea $G(f)$ la transformada de Fourier de la función $g(t)$. La transformada de Hilbert de $g(t)$ está dada por la ecuación (4) que se reproduce de nuevo.

$$\hat{g}(t) = g(t) * \frac{1}{\pi t} \quad (9)$$

La transformada de Fourier de (9) está dada por (8): $\hat{G}(f) = -j \operatorname{sgn}(f) G(f)$

De (6) se deduce que la magnitud del término $-j \operatorname{sgn}$ es la unidad, entonces:

$$|\hat{G}(f)| = |G(f)| \quad (10)$$

Esta última ecuación indica que $|\hat{G}(f)|$ y $|G(f)|$ tienen exactamente la misma magnitud, por tanto la misma densidad espectral. También se concluye que $\hat{g}(t)$ y $g(t)$ tienen exactamente la misma energía que era lo que se buscaba comprobar.

Se puede concluir que:

1. Si $g(t)$ tiene un determinado ancho de banda, $\hat{g}(t)$ también va tener el mismo ancho de banda.

2. Si $g(t)$ es una señal de energía o de potencia, su transformada de Hilbert $\hat{g}(t)$ tendrán la misma energía o la misma potencia.

2.1.1.2. Propiedad 2

La función $g(t)$ y su transformada de Hilbert $\hat{g}(t)$ tienen la misma función de la autocorrelación.

Se deduce directamente de la propiedad anterior, puesto que la transformada inversa de Fourier de la densidad espectral es función de auto-correlación.

2.1.1.3. Propiedad 3

Una señal y su transformada Hilbert son ortogonales.

Para demostrarlo en el caso de señales de energía se calcula la correlación cruzada, debiendo valer cero en el origen para que las señales sean ortogonales según la ecuación (11) donde $R_{g\hat{g}}(\tau)$ es la correlación cruzada.

$$R_{g\hat{g}}(\tau) = \int_{-\infty}^{\infty} \hat{g}(t) * g(t - \tau) dt \quad (11)$$

Se sabe también que la transformada de Fourier de la correlación de la ecuación (11) se puede calcular en la ecuación (12).

$$R_{g\hat{g}}(\tau) \Leftrightarrow \hat{G}(f) * G(f) \quad (12)$$

A partir de las ecuaciones (11) y (12) se puede seguir el desarrollo de la ecuación (13), que vale cero puesto que el integrando es una función impar de la frecuencia. Esto es debido a que $\text{sgn}(f)$ es impar y $|G(f)|^2$ es par, el producto de una función par por una impar es impar. Por lo tanto, queda demostrado que son ortogonales.

$$R_{\hat{g}g}(0) = \int_{-\infty}^{\infty} \hat{g}(t) g^*(t - \tau) dt = \int_{-\infty}^{\infty} \hat{G}(f) * G(f) df \quad (13)$$

$$R_{\hat{g}g}(0) = \int_{-\infty}^{\infty} G^*(f) [-j \text{sgn}(f) G(f)] df$$

$$R_{\hat{g}g}(0) = -j \int_{-\infty}^{\infty} [\text{sgn}(f) |G(f)|^2] df$$

En el caso de las señales de potencia se prueba de la misma forma llegando al final a la ecuación (14), quedando demostrado que son ortogonales.

$$R_{\hat{g}g}(0) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T g^*(t) \hat{g}(t) dt = 0 \quad (14)$$

2.1.1.4. Propiedad 4

Si $\hat{g}(t)$ es la transformada de Hilbert de $g(t)$, la transformada de Hilbert de $\hat{g}(t)$ es $-g(t)$.

Hallar la transformada de Hilbert es equivalente a pasar la señal $g(t)$ a través un transformador de Hilbert, cuya función de transferencia es $H(f) = -j \operatorname{sgn}(f)$. Hallar la transformada de Hilbert de $\hat{g}(t)$ será equivalente a pasar $\hat{g}(t)$ por un segundo transformador de Hilbert. La función de transferencia de la conexión en cascada de los 2 transformadores será $\mathcal{H}(f) * \mathcal{H}(f)$. Calculando:

$$\mathcal{H}(f) * \mathcal{H}(f) = (-j \operatorname{sgn}(f))^2 = (j \operatorname{sgn}(f))^2 = (\sqrt{-1})^2 = -1 \quad (15)$$

El resultado nos indica que a la salida del sistema se tiene la señal de entrada $g(t)$ multiplicada por -1, o sea $-g(t)$, de esta forma queda probada la propiedad [1].

2.2. Lógica difusa en reconocimiento de patrones.

Las técnicas de reconocimiento de patrones pueden ser clasificados en dos categorías: *técnicas supervisadas* y *técnicas no supervisadas*.

Las técnicas no supervisadas usan un grupo de datos sin clasificar, mientras que la técnica supervisada usa un grupo de datos con una clasificación conocida. Estos dos tipos de técnicas son complementarias.

La técnica que se va a utilizar en el desarrollo del algoritmo para el reconocimiento de fallas de la red eléctrica, es el Fuzzy c-Means ya que la información se proporcionará en dos grupos y se requiere un reconocimiento automático por parte del sistema de dichos grupos los cuales determinarán los datos que presentan falla y los datos que no representan ninguna falla. Esta técnica generaliza todos los algoritmos de c-Means y permite a un dato pertenecer a múltiples agrupaciones; por lo tanto proporciona una partición suave de un grupo de datos dado. Para hacer esto, la función objetivo J_f de un c-Means normal se puede extender en dos modos:

1. Los grados de membresía Fuzzy se incorporaron dentro de la fórmula.
2. Un parámetro adicional m fue introducido como peso exponencial en la membresía Fuzzy, la función objetivo extendida queda entonces como:

$$J_m(P, V) = \sum_{i=1}^k \sum_{x_k \in X} (\mu_{c_i}(x_k))^m \|x_k - v_i\|^2 \quad (16)$$

donde P son las particiones del grupo de datos X formado por $C_1, C_2, C_3, \dots, C_k$. El parámetro m es el peso que determina el grado al cual los miembros parciales de un agrupamiento afectan al agrupamiento resultante.

Fuzzy c-Means trata de encontrar una buena partición por búsqueda para prototipos v_i que minimice la función objetivo J_m . Esta metodología también requiere buscar una función de membresía μ_{c_i} que minimice J_m .

2.2.1. Teorema de Fuzzy c-Means

El teorema puede definirse en cuatro pasos:

Paso 1: Iniciación:

De acuerdo con la notación mencionada en el numeral anterior y dada una matriz de datos Θ ($p \times X$) con el elemento μ_{ix} en posición (c, i) , $c = 1, \dots, p$; $i = 1, \dots, X$

Esta matriz se inicia con la siguiente restricción:

$$\sum_{i=1}^p \mu_{ci} = 1, \quad \forall i = 1, \dots, X \quad (17)$$

Paso 2: Cálculos de centros de clase:

Dados los valores de pertenencia μ_{ix} , los centros v_i de clase i están dados por

$$v_i = \frac{\sum_{x \in X} (\mu_{ci}(x))^m x}{\sum_{x \in X} (\mu_{ci}(x))^m} \quad 1 \leq i \leq k \quad (18)$$

Paso 3: Actualización de valores de pertenencia:

Dados los centros de clase calculados en el paso 2, los valores de pertenencia μ_{ix} son actualizados utilizando la siguiente fórmula:

$$\mu_{ci}(x) = \frac{1}{\sum_{j=1}^k \left(\frac{\|x-v_i\|^2}{\|x-v_j\|^2} \right)^{\frac{1}{m-1}}} \quad 1 \leq i \leq k, x \in X \quad (19)$$

Paso 4: El criterio de detección:

Basado en este teorema, *FCM* actualiza los prototipos y las funciones iterativas usando las ecuaciones anteriores hasta que convergen a un criterio alcanzado:

$$\|\Theta^{(t+1)} - \Theta^{(t)}\| \leq \epsilon \quad (20)$$

donde $\Theta^{(t)}$ es la matriz de valores de pertenencia en la iteración t y ϵ es un umbral a ser determinado por el usuario.

2.2.2. Validación de Agrupaciones

Uno de los principales temas en el método de agrupamiento es cómo evaluar los resultados del algoritmo; el problema es llamado *Validación de Agrupaciones*. Este problema consiste en buscar criterios para determinar que tan buena es una partición generada por el algoritmo de agrupación. Este tipo de criterios permiten tener los siguientes tres objetivos:

1. Comparar las salidas de algoritmos de agrupamiento alternativos para un grupo de datos.

2. Determinar el mejor número de agrupaciones para un grupo de datos dado
3. Determinar cuando un grupo de datos dado tiene una estructura

Desde el punto de vista matemático los criterios de la validación debe cumplir con los siguientes parámetros[36]:

Coefficiente de partición (cp)

$$cp = \sum_{x=1}^X \sum_{i=1}^P \frac{(\mu_{ci})^2}{J} \quad (21)$$

Entropía de partición (ep)

$$ep = -\frac{1}{X} \sum_{c=1}^X \sum_{i=1}^P \mu_{ci} \log_e \mu_{ci} \quad (22)$$

Exponente proporcional (exp)

$$exp = -\log_e \prod_{c=1}^X \sum_{i=1}^{m_k} (-1)^{i+1} \binom{p}{i} (1 - \mu_{ci})^{p-1} \quad (23)$$

El valor de m_k se define como el entero mas grande que sea menor o igual a $\frac{1}{\mu_k}$, donde:

$$\mu_k = \max\{\mu_{ci}; c = 1, \dots, p\} \quad (24)$$

Las siguientes relaciones se cumplen para los criterios anteriormente definidos

$$\frac{1}{c} \leq cp \leq 1 \quad 0 \leq ep \leq \log_e c \quad 0 \leq exp \leq \infty \quad (25)$$

2.2.3. Generalización de Fuzzy c-Means

Una mayor extensión del algoritmo Fuzzy c-Means (FCM) es generalizar la distancia medida entre el dato x_i y el prototipo v_j de

$$dist(x_i, v_j) = \|x_i - v_j\|^2 \quad (26)$$

a

$$dist(x_i, v_j) = (x_i - v_j)^T A_j (x_i - v_j)$$

donde A_j es una matriz simétrica $d \times d$ (d es la dimensión de x_j y v_j). Esto habilita un *FCM* ampliado para adaptar a diferentes formas de hiper-elipsoidales de diferentes agrupaciones por ajuste de la matriz A_j .

2.3. Otros conceptos básicos

2.3.1. Coordenadas esféricas

En un sistema de coordenadas esféricas, la ubicación de los puntos se maneja con 2 ángulos y un módulo. Los ángulos se llamarán φ (Phi) y θ (theta). El módulo se llamará ρ (Rho). Para ubicar un punto es necesario conocer los 2 ángulos y el módulo. El módulo es la recta que une el centro de las coordenadas con el punto en cuestión. θ es el ángulo formado por el eje Z y el módulo, y φ es el ángulo formado por el eje X y la proyección de módulo sobre el plano X-Y. Figura 2




Figura 2. Sistema de coordenadas cartesianas y su relación con las coordenadas esféricas.

Es fácil deducir que si para un punto dado se conocen los valores de los ángulos θ y φ , y la magnitud del módulo ρ , la ubicación del punto está completamente definida.

Las coordenadas esféricas en algunas aplicaciones se llaman coordenadas polares. En este caso las componentes cambian de nombre: El módulo ρ se llama “distancia radial”, el ángulo θ se llama la “coordenada polar”, y el ángulo φ es la “coordenada azimutal”.

Algunas características de estos parámetros son:

Del módulo ρ siempre se usa la magnitud, por lo tanto su signo siempre será positivo.

El ángulo θ varía entre 0 y π radianes, 0 radianes cuando el módulo apunta hacia arriba, (norte) y π radianes cuando el módulo apunta hacia abajo (sur).

El ángulo φ varía de 0 a 2π radianes.

Las relaciones matemáticas entre las coordenadas cartesianas y las coordenadas esféricas son:

$$X = \rho * \cos(\varphi) * \sin(\theta) \quad Y = \rho * \sin(\varphi) * \sin(\theta) \quad Z = \rho * \cos(\theta)$$

donde: $\rho \geq 0$ $0 \leq \varphi \leq 2\pi$ $0 \leq \theta \leq \pi$

2.3.2. Breve introducción a la teoría de la varianza

Si se tienen N de datos que forman una estadística X , de un evento determinado.

Sea \bar{X} el valor medio aritmético de los datos N , que se puede escribir:

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_N}{N} \quad (27)$$

Desviación de un dato, σ , es la diferencia entre el valor del dato y el valor medio del grupo de datos, o sea \bar{X} . Entonces la desviación del valor de un dato se expresa como:

$$\sigma_N = X_N - \bar{X} \quad (28)$$

La varianza es el valor medio de las desviaciones elevadas al cuadrado cada una. Generalmente la Varianza se representa por σ^2 . Lo dicho se escribe en la forma:

$$\sigma^2 = \frac{\sigma_1^2 + \sigma_2^2 + \dots + \sigma_N^2}{N} = \frac{\sum_{i=1}^N \sigma_i^2}{N} = \frac{\sum_{i=1}^N (X_N - \bar{X})^2}{N} \quad (29)$$

3. CAPITULO 3

ESTADO DEL ARTE

3.1. Casos de aplicación Hilbert

La transformada de Hilbert ha sido ampliamente utilizada en detección de fallas y anomalías en sistemas de información como motores de inducción, aplicaciones médicas en el sistema cardiaco, detección de fallas sobre una sola línea eléctrica. A continuación se describen brevemente algunas aplicaciones.

El equipo de trabajo de Zhenxing Liu, de la Wuhan University, [8], utilizan la transformada de Hilbert como una herramienta ideal de desfase para detección de fallas en motores de inducción de tipo jaula de ardilla; las fallas tenidas en cuenta son: rompimientos de barras del rotor y excentricidad. Este estudio se basa en el análisis espectral del estator de corriente con el módulo Hilbert, realizando inicialmente un diagnóstico con la aproximación del vector de Park y un análisis de desfase en cada una de las tres fases que componen la señal del rotor.

La transformada de Hilbert también ha sido aplicada en medicina. El grupo de trabajo de Abeysekera, de Queensland University de Brisbane, [9], investigó en el área de electrocardiografía, para buscar la forma de conseguir un diagnóstico asistido por computadora, por medio de la comparación de señales y su desfase. Con resultados muy alentadores pudo confirmar la posibilidad de usar software como ayuda para diagnóstico, encontrando morfologías normales y anómalas en un electrocardiograma.

Soo-Chan Pei, [5], describe aplicaciones de la transformada de Hilbert en análisis de sistemas ópticos, diseño de filtros, análisis de señales, y recuperación de fase, entre otros. Además explora otros métodos con los cuales puede hacer un análisis frecuencial a una señal, como el WDF (Wigner Distribution Function), el FRFT (Fractional Fourier Transform), del cual se deriva la transformada de Hilbert.

Por otro lado, el problema de detección de fallas en sistemas de potencia, usando la transformada Hilbert ya ha sido explorada en investigaciones anteriores por Chen Chunling [6]. Aplica diferentes tipos de fallas a una señal eléctrica y estas pueden ser reconocidas por medio de la utilización de la transformada de Hilbert. El principio básico es la detección de desfase de la señal la cual como característica tenía una frecuencia de 50Hz. La aplicación fué diseñada usando el software de la aplicación LabView, que les permitía trabajar en línea. El modelo es capaz de reconocer señales sin falla, señales de sobre voltaje, señales con voltajes momentáneos a tierra, fallas en fluctuación de voltaje, armónicas en las señal de voltaje, señales transitorios, obteniendo resultados certeros sin muchos retardos para el caso de un solo nodo. A diferencia del trabajo realizado por Chen Chunling, en la presente tesis se ampliará el análisis a más de un nodo con falla dentro de la red, y estas fallas se presentarán de manera simultánea por lo que la complejidad en el manejo de la información aumenta debido que no se van a tener solo tres variables para el análisis

sino 72. Adicionalmente, al ser un sistema en red presentará información falsa correspondiente al efecto cascada; es decir que en uno o más nodos puede dar información errónea de su estado de falla, por lo que uno de los retos es reconocer si esta información es cierta o falsa.

Otro de los casos de estudio es el descrito por Rosero, J et al, [15]. Por medio de la transformada de Hilbert consiguen detectar las fallas por desmagnetización en motores síncronos cuando en éstos ocurren caídas de voltaje y fallas de fases a tierra entre otros. Para obtener resultado se hicieron pruebas iniciales utilizando dos métodos: el primero de ellos basados en FFT (Fast Fourier Transform). Este método no puede diferenciar unas armónicas de otras cuando son producidas por la desmagnetización, debido al efecto de excentricidad, y por tanto se tiene una lectura engañosa del análisis de datos no lineales y no estacionarios. El segundo método, el de la transformada de Hilbert, proporciona una distribución de tiempo-frecuencia de la energía de la señal.

Esta herramienta también fué utilizada por Huy Li, [16], para la detección de fallas en rodamientos que son ampliamente usados en maquinaria industrial y cajas de cambios en los automóviles estándar. Antes de usar la transformada de Hilbert emplearon la FFT, y la transformada Wavelet. La estimación de la potencia espectral con estos métodos, presentaron limitaciones en análisis de las frecuencias. Al aplicar la transformada de Hilbert obtienen la envolvente de la señal, luego calculan el espectro marginal y lo analizan obteniendo como resultado el diagnóstico concluyente, de manera tal que se tiene una alta eficiencia del método.

Liling Sung et al, [17], utilizó la transformada de Hilbert como método para encontrar fallas en motores de inducción, cuando estos sufren rompimientos en las barras del rotor. Realiza un análisis en frecuencia de la señal entregada por el motor, el cual le indica si hay presencia o no de la falla.

Otro caso de aplicación en un sistema inmunológico lo describe Costa Branco, [4]. Empleando el método del Sistema Inmunológico Humano como medio para la detección de fallas en un motor tipo jaula de ardilla. Para lograrlo se tomó el espectro de frecuencias y se analizó el rango de éstas en operación óptima y cuando presenta fallas. De este modo se pudo caracterizar el espectro cuando se presentaba la falla. Esto se logró a través del análisis en el dominio de la frecuencia, usando la transformada de Fourier, obteniéndose resultados excelentes en la detección.

Ilhan Aydın et al, [12], aplicaron el modelo de sistema inmunológico humano en motores de inducción monofásicos. Utilizaron la transformada de Hilbert para reconstruir el espacio de fases de la señal y hacer su respectivo análisis, lo que permitió identificar el momento en que se presenta la falla. Posterior a esto, y aplicando Fuzzy clustering c-means, se logró la identificación de los centros y radios de las muestras con y sin fallas, lo que permitió determinar los distintos niveles de falla. La investigación aquí desarrollada se basó en el análisis de la amplitud de la señal de corriente para un motor monofásico. Este algoritmo carece de información sobre un tiempo de inicio de falla, y su resultado de determina a través de un valor de umbral lo que proporciona una lectura ideal para un tipo de motor simulado, en cuanto a la señal utilizada no se habla de una adición de ruido por lo que la efectividad del algoritmo en estas condiciones no queda establecido. En el algoritmo base de la presente tesis se encontrarán resultados que comprueben la efectividad del algoritmo para condiciones no ideales de la señal, cuando se adiciona cierto nivel de ruido.

Ruz-Hernandez et al.[13], plantean la solución al problema de diagnóstico de fallas en una red eléctrica, con el empleo de un esquema basado en redes neuronales. El proceso se ejecuta en dos fases: la primera corresponde a Generación de Residuos, y la segunda a una Clasificación de Falla. La primera fase halla los residuos usando las diferencias entre las medidas que provienen de la planta y las medidas suministradas por un predictor neuronal el cual es alimentado con datos no corruptos. Para la detección del segundo componente se utilizan los residuos anteriores como vectores bipolares, los cuales representan patrones de falla. Estos patrones de falla son almacenados en una memoria basada en una red neuronal recurrente. El esquema es aplicado a una base de datos obtenida del simulador.

Aydin et al [14], crearon un nuevo algoritmo basado en el sistema inmunológico humano, para encontrar fallas múltiples (hasta 3) en un motor de inducción, usando como reconocimiento de patrones vectores de park, combinándolos con clasificadores SVM ,(Support Vector Machines). Es uno de los métodos más usados en clasificación computarizada, obteniendo resultados que alcanzan un éxito de detección de la falla hasta del 98.85%.

3.2. Casos de aplicación de detección de fallas en redes eléctricas.

Ebron S. et al, [19], desarrollaron un algoritmo basado en redes neuronales, para la detección de fallas en redes eléctricas, en el cual tienen como consideración principal, las altas impedancias de la red. En este trabajo se substraen el comportamiento de las señales del sistema, tanto en funcionamiento correcto como cuando se presenta la falla, extrayendo alrededor de 20 características para la consideración de fallas, con las cuales es alimentada la red neuronal. Se han obtenido resultados alentadores, aunque se espera un trabajo futuro el cual tenga una estrategia más efectiva para la detección de fallas incipientes, ya que al considerar las impedancias puede confundirse el sistema. Por ejemplo, una lectura de baja tensión puede darse cuando una impedancia disminuye por una falla, o cuando en el sistema se presenta una baja tensión sin querer esto significar que se tenga falla.

Algunas de las investigaciones que se han hecho sobre fallas en redes eléctricas hablan sobre fragilidad y vulnerabilidad como lo hace Zijun Mao et al [20]. Ellos presentan una caracterización topológica de una red eléctrica de una ciudad, en función de la longitud entre nodos, el coeficiente de agrupación y grado de distribución, para finalmente a través de métodos probabilísticos, calcular la vulnerabilidad del sistema.

Yan Limei et al [21] analizan la problemática del efecto cascada en la redes eléctricas, usando la teoría de la fragilidad y construyendo un modelo de fragilidad de dos dimensiones, también llamado teoría SOC, Usando esta teoría se consiguen dos condiciones para la fragilidad: una que es motivada por el grado de carga, y la segunda, si el valor de perturbación es lo suficientemente grande. Se logra simular el modelo de fragilidad para, con un posterior análisis, usarla en el control y prevención de apagones.

La investigación de J.Pan et al [22], busca determinar la tasa de fallas en los componentes de una red eléctrica, a partir de las fallas estáticas, teniendo en cuenta su condición actual. Para ello, se trabaja con una serie de factores los cuales son asumidos, uno de estos factores es el mantenimiento

preventivo de los componentes. El resultado es normalizado. Posterior a esto, se aplica distribución lognormal definido con dos parámetros. El resultado será observado en una tabla comparativa que ayudará a determinar la falla.

Yang Y et al [30], en su artículo describen el desarrollo de un sistema de monitoreo de calidad de una red de eléctrica rural, haciendo uso de una tarjeta de adquisición de datos, un quipo de computo y Labview, para la parte de monitoreo recurren a la Transformada de Hilbert, esto lo hace para la red en general, mas no busca encontrar fallas ni definir de qué tipo de falla de trata, sin embargo este sería una buena guía para el trabajo futuro para la presente tesis.

Liu Y et al [32], desarrollan un algoritmo de detección de fallas en dos partes, la primera a través de Onduletas para descomponer la señal en sub bandas de alta y baja frecuencia. La segunda parte a través de la transformada de Hilbert obtiene la frecuencia instantánea y amplitud instantánea. Basados en la los criterios de amplitud y frecuencia el algoritmo decide si mantener la descomposición de la sub-banda o pasar a otra. Este algoritmo es probado en la simulación de una línea eléctrica de 10KV, con lo que logra obtener el tiempo en que se lleva la falla y la detección de que existe tal falla. Este algoritmo carece de la información sobre el tipo de falla que se presenta y como es probado sobre una única línea no se pude conocer su comportamiento en una red trifásica.

Scrysat O.R. et al[33], en su artículo presentan un algoritmo para detección de fallas no estacionarias en rodamientos, para ello hacen uno de la transformada de Hilbert para ello usa 6 conjuntos de datos del mismo rodamiento pero con falla distinta, y a través del análisis de la frecuencia que permite extraer la transformada de Hilbert y a través de el análisis de la respuesta se puede conocer que existió una falla. Por lo reciente del artículo y la falta de conclusiones se considera que aun está en proceso de investigación.

Hong Y et al [34], Para encontrar distorsiones en la señal de corriente dirigirá hacia un relevador, lo cual cauda un mal funcionamiento del mismo. Para ello, emplea la transformada onduleta con la cual logra encontrar el tiempo en que ocurre la falla e identificar los periodos de saturación, Utiliza posteriormente Fuzzy c-Means para agrupar las posibles corrientes de falla en 42 grupos de acuerdo a sus características por medio de un test estático. Luego, generan 42 fórmulas de regresión para la compensación de fallas.

Leite D. et al. [35] en su artículo desarrollan un software para la adquisición de datos de 4 motores que no se encuentran en red, posterior a la adquisición da datos y con la ayuda de redes neuronales y agrupación Fuzzy c-Means logran detectar los condiciones de falla en los motores.

4. CAPÍTULO 4: DESARROLLO DEL ALGORITMO

4.1. Descripción de la red eléctrica de comprobación

Se llama Red Eléctrica de Comprobación (REC), al modelo de red eléctrica con la cual se trabajará durante el desarrollo de la presente proyecto. Se describe a continuación:

La REC está compuesta por:

- 24 nodos principales,
- 20 generadores con diferentes voltajes,
- 21 cargas estáticas,
- 15 cargas dinámicas,
- 68 interruptores.

De REC se tiene información de las tres líneas (fases) eléctricas de cada nodo, la frecuencia de las señales de las líneas de fases, es siempre de 60 Hz. Esta red fue diseñada para la detección y diagnóstico de fallas por primera vez utilizando sistemas híbridos [7]

Para esta red REC, se simularon 51 escenarios (ver Tabla), cada uno de ellos utiliza los 24 nodos; se puede variar la cantidad de nodos con falla en cada escenario, hasta un máximo de 5 fallas por escenario. Las fallas pueden ser simultáneas. Existen 10 tipos distintos de fallas posibles, Tabla 1. Todas las fallas se simularon con el software Microtran. Más detalles relativos a la operación de este software se encuentran en [29].

Tipos de Falla	
# de Falla	Tipo de Falla
1	Línea A-Tierra
2	Línea B-Tierra
3	Línea C-Tierra
4	Línea A-Tierra y Línea B-Tierra
5	Línea A-Tierra y Línea C-Tierra
6	Línea B-Tierra y Línea C-Tierra
7	Línea A-Tierra, B-Tierra y C-Tierra
8	Línea A - Línea B
9	Línea A - Línea C
10	Línea B - Línea C
11	Sin Falla entre alguna de las líneas A, B C

Tabla 1. Tipos de Fallas

La distribución de la red se representa gráficamente en la siguiente Figura 3:

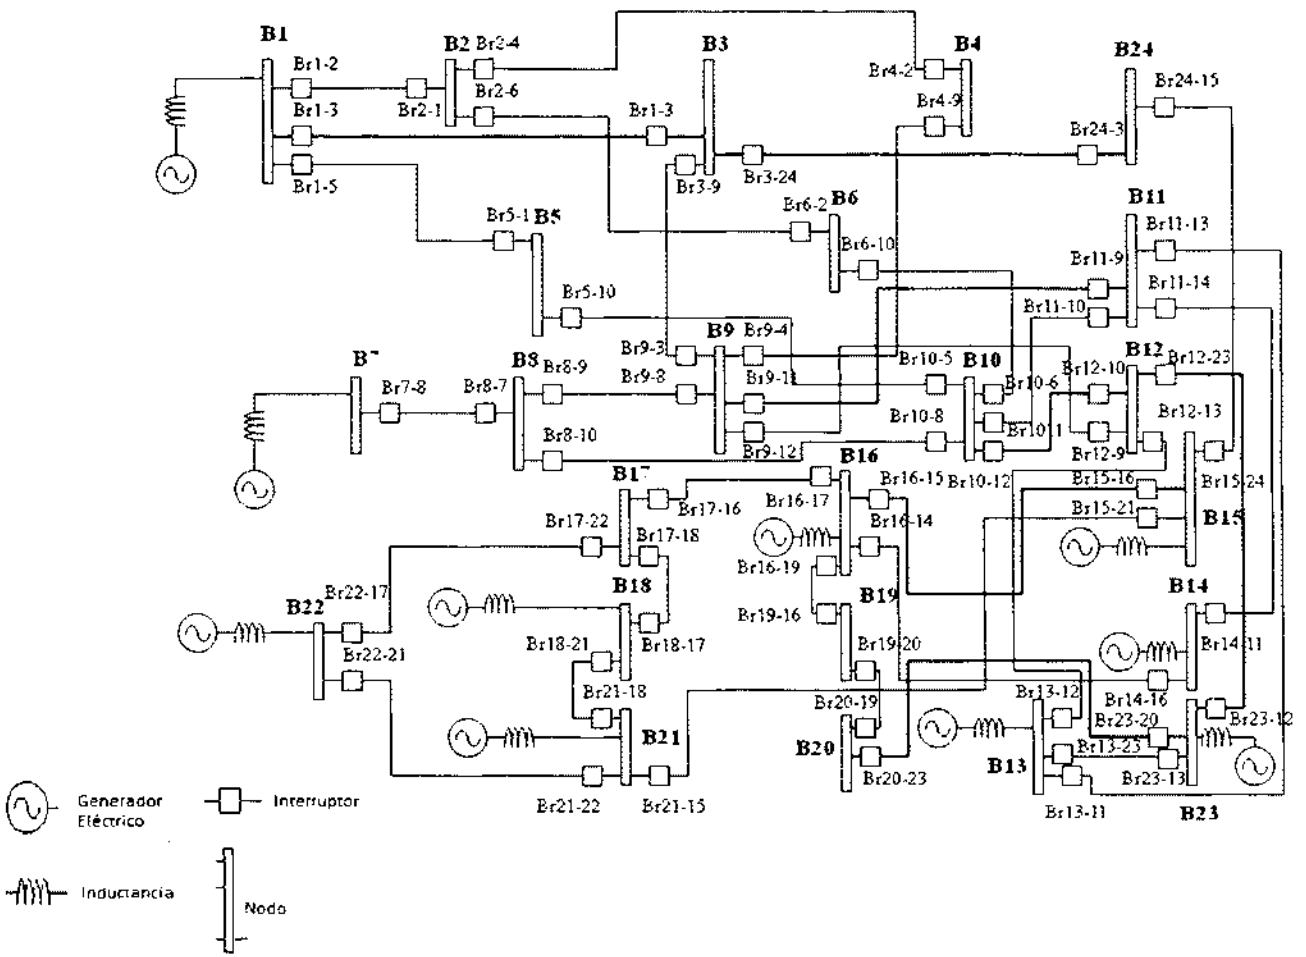


Figura 3. Distribución de la red eléctrica

Es conveniente definir lo que se llama "nodo cercano." Dos nodos se dice que son cercanos, cuando están interconectados de una manera directa. Por ejemplo, en la Figura 3, que muestra el esquema de la REC, los nodos 1 y 3 son cercanos, lo mismo que los nodos 3 y 24. Esta cercanía tendrá efecto sobre la técnica a escoger para localizar fallas.

4.1.1. Selección del parámetro a analizar

Supongamos que una línea de un nodo presenta una falla. Para saber cuál o cuáles de los parámetros que componen la señal de voltaje de la línea deben ser tenidos en cuenta para la detección de la falla, es importante conocer la forma como se entregan los datos del comportamiento de la red REC, y de qué manera se ven afectados dichos datos en presencia de las diferentes fallas. A continuación se muestran 3 ejemplos:

- Comportamiento de un nodo sin fallas.
- Comportamiento de un nodo con fallas entre Línea-Línea.
- Comportamiento de un nodo afectado por fallas línea-tierra.

Las fallas son simuladas y simultáneas. El instante en que comienza el proceso se considera como $t=0$. La unidad de tiempo es 1 milisegundo. (1 ms). Las fallas se producen en el lapso entre 4,000 y 4,300 ms.

El escenario utilizado es: *Datos5F3-19-5-10-17*; esto quiere decir que de los 24 nodos, 5 de ellos presentan falla, específicamente los nodos 3, 19, 5, 10 y 17. En un primer paso, se observan y se leen los parámetros de las tres líneas que componen el nodo 2 del escenario, que no presenta falla alguna. El comportamiento de las 3 señales, A, B, y C durante los 5,000 milisegundos se puede ver en la Figura 4. (Zona mostrada en verde). Debido a la escala de tiempo utilizada no es posible apreciar los detalles de las señales, por eso la Figura 5 muestra, en diferente escala de tiempo, el detalle de las señales entre los 4,000 y 4,300 ms aproximadamente. Se puede apreciar que las señales son senoidales, por lo tanto se tendrán en cuenta sus parámetros de amplitud y fase. En este caso cuentan los valores pico de las señales, que corresponden a 128 y -131 volts. En la figura se verifica la consistencia de las formas de onda de señales en las líneas debido a la ausencia de fallas.




Figura 4. Señal original sin falla 3 líneas de Nodo 2

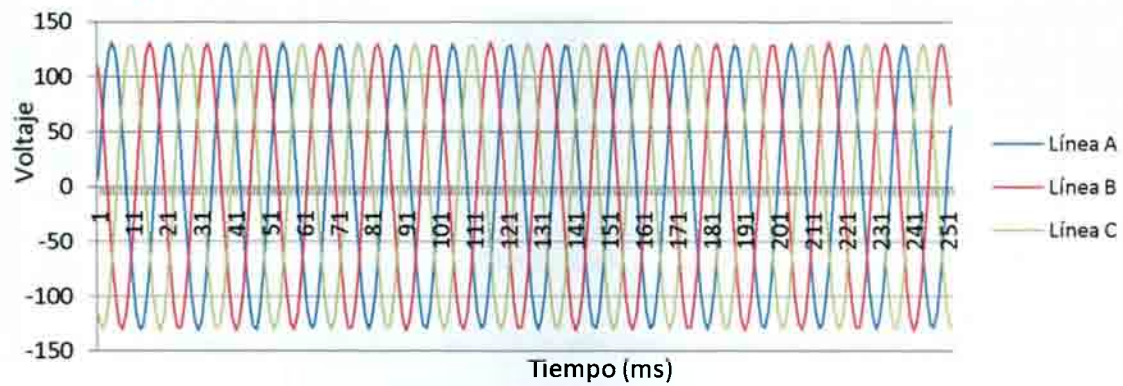


Figura 5. Señal original sin falla 3 líneas de Nodo 2 tiempo entre 1 y 100

Para este mismo escenario se toma ahora el nodo 3; este nodo, de acuerdo con el escenario presenta algún tipo de falla que estará en el lapso entre 4,000 a 4,300 ms. Las señales de las tres líneas A, B y C del nodo 3 se muestran en la Figura 6. Se observa una diferencia de amplitud para las fases A y B del nodo, lo cual indica que existe una posible falla; esto es más claro en la Figura 7, donde además se nota que para estas mismas líneas existe un cambio en su fase. Lo anterior es evidente en la Figura 8 que corresponde a una ampliación de la porción de tiempo de la señal donde se observó el cambio de fase.




Figura 6. Tres fases del nodo 3 con fallas entre línea A y línea B




Figura 7. Variación en la amplitud de la señal cuando se presenta la falla línea-línea



Figura 8. Cambio en la línea de las líneas que presentan fallas en el instante en que estas se presentan

Para ver qué ocurre en el mismo nodo 3, pero con otra clase de falla, se tomó un tercer escenario: “Datos1F3.txt”. La clase de falla en este caso de línea a tierra. La Figura 9 muestra el comportamiento del nodo en el lapso de 0 a 5,000 ms.




Figura 9. Líneas A,B y C's del nodo 3 con fallas línea A a tierra y línea B a tierra




Figura 10. La amplitud de las líneas en falla es igual a cero durante la presencia de la falla




Figura 11. La fase de las líneas en falla se pierde por completo

En la Figura 10 se observan las tres líneas del nodo en el instante anterior al que se presenta la falla, y un corto tiempo después, cuando la falla se está presentando. Si se hace una inspección un poco más detallada, Figura 11, se confirma que la amplitud de las líneas A y B es cero cuando la falla se presenta.

De acuerdo a las pruebas hechas con los demás escenarios y nodos, este comportamiento se cumple para todos los casos con falla a tierra; sin embargo se toma el parámetro fase, ya que el parámetro de amplitud presenta algunos casos de información falsa debido al efecto llamado "Cascada". Este efecto consiste en lo siguiente: cuando un nodo J es cercano a otro nodo K, si en el nodo K se presenta una falla, la amplitud del voltaje en el nodo J se ve afectada, y de esta forma

aparece un síntoma de una falla en J, pero realmente no existe falla en este nodo. Esto no sucede si tenemos en cuenta el parámetro de la fase de las líneas del nodo, en vez del parámetro de la amplitud. El parámetro de fase se ve afectado únicamente si el nodo realmente presenta falla.

4.2. Aplicación de la transformada de Hilbert y su análisis en frecuencia

Para facilitar la comprensión de la manera como se ha desarrollado el algoritmo para detección de fallas en la REC, se hará el seguimiento a cada paso con un ejemplo aplicado al escenario: Datos5F3-19-5-10-17. El trabajo se dividió en varias etapas como se muestra a continuación:

1. Análisis para un solo Nodo con Falla
 - a. Obtención del ángulo de cubrimiento y su acondicionamiento.
 - b. Clasificación de las fallas mediante Fuzzy c-Means.
 - c. Clasificación jerárquica de las fallas.

2. Análisis para 2 Nodos con distinto tipo de falla.
 - a. Obtención del ángulo de cubrimiento y su acondicionamiento.
 - b. Clasificación de las fallas mediante Fuzzy c-Means.
 - c. Clasificación jerárquica de las fallas.

3. Análisis para un escenario completo.
 - a. Obtención del ángulo de cubrimiento y su acondicionamiento.
 - b. Clasificación de las fallas mediante Fuzzy c-means.
 - c. Clasificación jerárquica de las fallas.
 - d. Fallas a tierra.
 - e. Fallas línea a línea.
 - f. Representación conjunta.
 - g. Tipos de fallas.

4.2.1. Análisis para un solo nodo con falla

a) Obtención de la fase y su acondicionamiento

Como se mencionó, se utilizará la transformada de Hilbert teniendo en cuenta los resultados obtenidos en la sección 4.1.2, que menciona la selección del parámetro por medio del cual se debe hacer la detección de fallas. Esta transformada permite hacer una selectividad en ángulo de cobertura sin importar la amplitud de la señal.

Al aplicar la función *Hilbert* de Matlab se obtiene la señal analítica de la forma:

$$\mathcal{H}(s(t)) = S_I(t) + j S_Q(t) \quad (30)$$

Donde la parte real $S_I(t)$ es:

$$S_I(t) = s(t) \cos(2\pi\omega_0 t) \quad (31)$$

Y la parte imaginaria $S_Q(t)$ es:

$$S_Q(t) = s(t) \sen(2\pi\omega_0 t) \quad (32)$$

Como lo que se desea obtener el ángulo de cobertura por la señal en el tiempo t , se puede calcular este ángulo de la transformada. Sea $\theta(t)$ el ángulo de cobertura por la señal. De (31) y (32) se puede escribir que:

$$\theta(t) = \angle \left(S_I(t) + j S_Q(t) \right) = \arctg \left(\frac{S_Q(t)}{S_I(t)} \right) \quad (33)$$

La Figura 12 es la respuesta de la transformada de Hilbert cuando procesa la ecuación (33), el cálculo del ángulo para las señales. En este caso se hizo para un muestreo que duró 5000 ms, o sea 5 segundos. Matlab proporciona la función denominada *angle* que permite graficar la ecuación (33).

Matlab también dispone de una función llamada *unwrap* que permite calcular y graficar el *ángulo de cubrimiento*, en radianes, que es el valor del ángulo acumulado cubierto por una señal durante un tiempo determinado. Es decir, procesa y grafica la ecuación (34). El resultado de esta operación se puede ver en la Figura 13.

$$y (\text{Angulo}) = wt \quad (34)$$

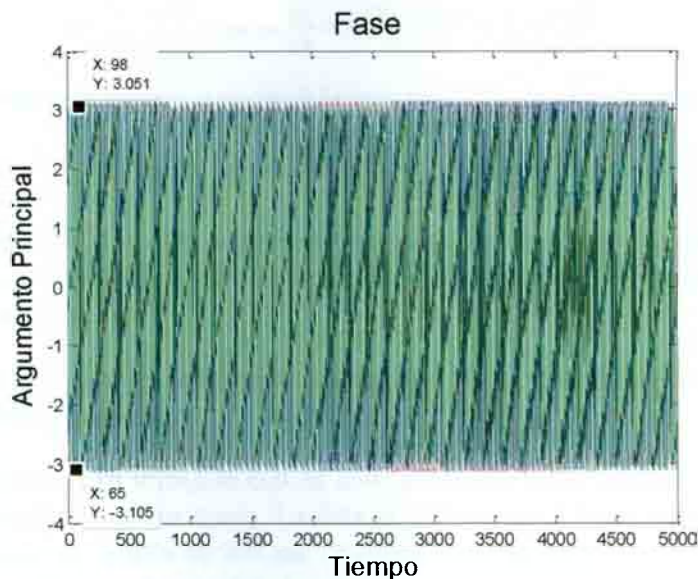


Figura 12. Gráfica de la obtención de los ángulos de fase




Figura 13. Gráfica de las fases

Esta gráfica corresponde a una línea recta donde la pendiente m es igual a w . El eje vertical corresponde a los valores del ángulo de cobertura; y sus unidades son los radianes. El eje horizontal es el tiempo, y sus unidades son los milisegundos.

La pendiente se puede calcular a partir de los valores dados en la gráfica, de la siguiente forma:

$$m = \frac{\Delta y}{\Delta x} = \frac{1887 + 1.571}{5000} = 0.3777 \quad (35)$$

También puede ser calculada a partir de la ecuación (22), donde sabemos que es igual a w .

$$m = w = \frac{2\pi f}{1000} = \frac{2 \cdot 3.1416 \cdot 60}{1000} = 0.377 \quad (36)$$

La división por ,1000 se debe a que la unidad usada aquí es el milisegundo y no el segundo. Se puede concluir que por cualquiera de los métodos el resultado es el mismo. La pendiente también se llama “Factor de fase”

Nota: Como la frecuencia es constante e igual a 60 Hz, el valor de la pendiente m será el mismo a través de todo el proyecto.

Hasta este punto se ha trabajado con un nodo sin fallas. Ahora supóngase que el nodo en estudio presenta falla en dos de sus líneas. La falla se presenta en el lapso entre los 4,000 y 4,300 ms, o sea una duración de la falla de 300 ms. Veamos cómo se afecta la Figura 13. Durante el tiempo que dura la falla, las líneas dañadas no cubren ningún ángulo, pero el tiempo sigue avanzando; por lo tanto la pendiente de la curva cambia, se vuelve 0. Cuando la falla se termina, la pendiente de la curva recupera su valor normal. La Figura 14 muestra lo dicho en forma gráfica. Comparando 2 casos, uno sin falla, Figura (a), y un caso con falla, Figura (b). Puede verse que

durante la falla el ángulo de cobertura no aumenta. La Figura 14 (a) muestra más en detalle el momento de la falla.

Con el fin de eliminar el ruido en la señal, que pudiera interpretarse como falla en el sistema, se aplica un filtro para suavizar esos cambios bruscos. Para ello se usa la función de Matlab *filter* que va tomando la muestra de datos que el usuario determine y va calculando su valor medio. De esta manera se va desplazando a través de los datos (Usando promedio móvil). La Figura 15 muestra en forma detallada, la curva en el momento de la falla, con filtro y sin filtro.

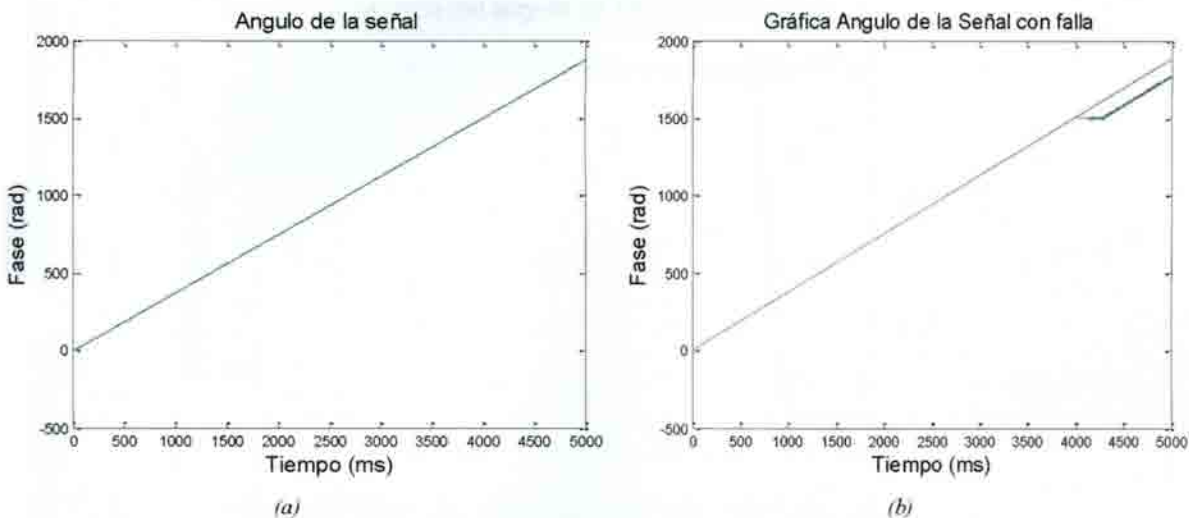


Figura 14. Señales de las fases con y sin falla. Gráfica (a), línea o fase sin falla. Gráfica (b), línea o fase con falla.

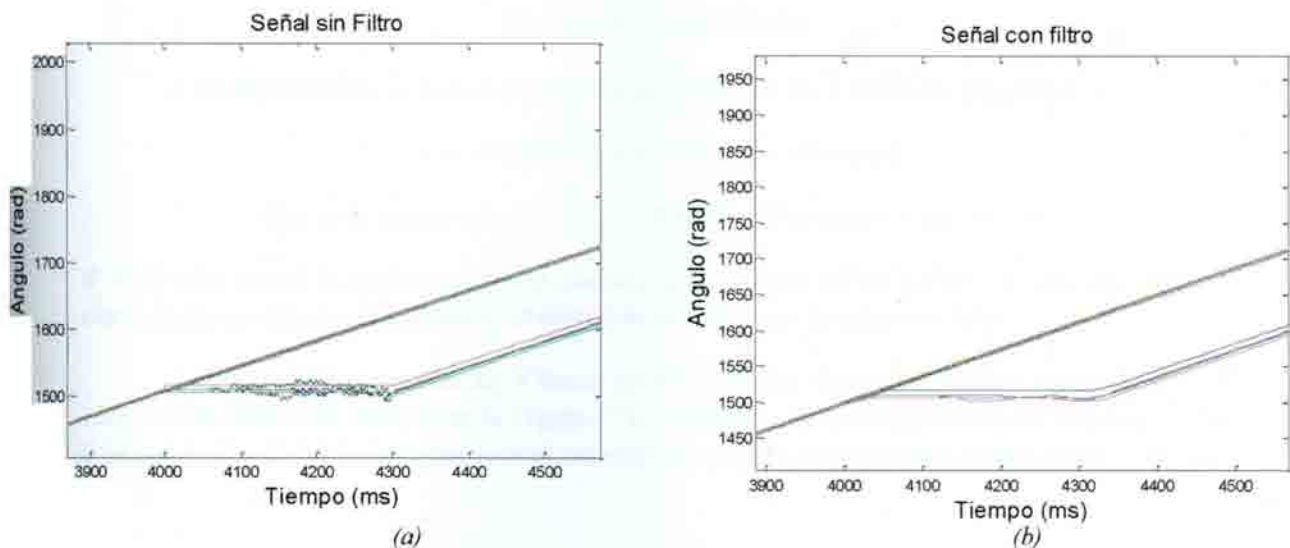


Figura 15. Señales de las fases con falla. Señal (a) sin filtro, (b) con filtro

Es posible calcular el ángulo que deja de cubrir la señal dañada durante el tiempo que dura la falla. De la ecuación (36), valor de la pendiente m , se deduce que:

$$\Delta\theta = m\Delta t \quad (37)$$

Para el caso del ejemplo, el tiempo que dura la falla, Δt , es de 300 ms. Reemplazando valores en la ecuación, se obtiene que $\Delta\theta = 113$ radianes. El ángulo que no cubrió la señal fue de 113 radianes.

La Figura 16 es la gráfica del “ángulo diferencia”, que está definido como sigue:




Figura 16. Angulo de diferencia

$$\angle \text{ de diferencia} = \angle \text{ de cobertura con falla} - \angle \text{ de cobertura sin falla, en } t. \quad (38)$$

$$\angle = \text{Angulo } t = \text{en el mismo tiempo } t$$

$$\text{Que es lo mismo que: } \text{Angulo diferencia} = \Delta\theta = -mt \quad (39)$$

θ es el valor actual de ángulo, m es la pendiente, t es el instante en que se hace la medición. De cierta forma es otra manera de medir el ángulo no cubierto por la señal con falla.

La Figura 16 representa las 3 líneas de los 24 nodos. Para lograr mayor claridad sobre el efecto de la diferencia, se tiene en la Figura 17 la representación de la diferencia del ángulo para las 3 líneas A, B y C del nodo 5 que para el escenario en estudio corresponden a falla tierra en las tres líneas.



Figura 17. Angulo de diferencia Nodo 5

A la diferencia de ángulo en el tiempo para los 24 nodos. Figura 16, se aplicó la derivada, ya que de acuerdo al concepto la derivada, ésta representa que tan rapido cambia una función en el tiempo, [23], de manera que se obtiene la mayor desviación en un punto dado. Para el caso en seguimiento, la Figura 18, que es la derivada de las señales de la Figura 16, muestra la mayor variación para varias fases en el tiempo 4,000 ms.

$$\text{PhaseShiftDot} = \frac{\Delta(\text{Phaseshift})}{\Delta t} \tag{40}$$

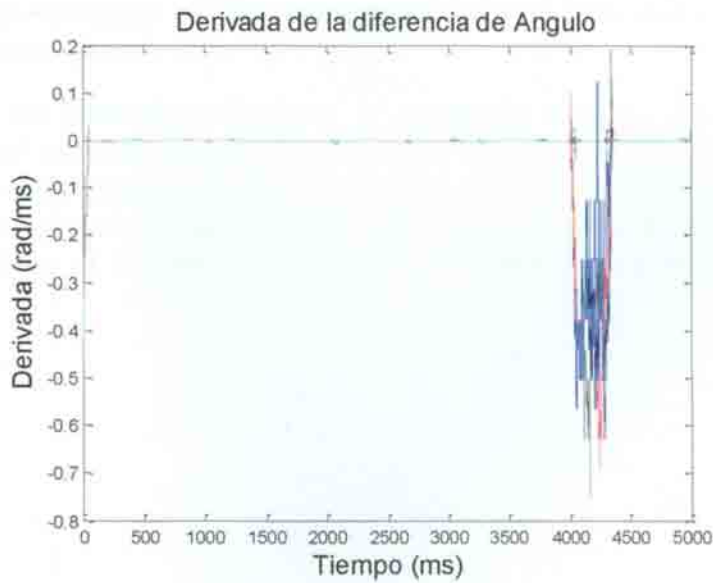


Figura 18. Derivada de la diferencia de ángulo

Al hacer un arreglo de los datos que se tiene al formar la Figura 18 de tal forma que ahora solo tomarán tres columnas de una matriz que representan las tres líneas A, B y C de todos los nodos, y si se hace una gráfica comparativa entre ellos, entonces, se obtiene la gráfica de la Figura 19. gráficas en 3 dimensiones.




Figura 19. Derivada de la diferencia para los 24 nodos

Como la Figura 19 es un poco compleja debido a la cantidad de datos que almacena, a continuación se tomará solo el ejemplo para las tres líneas de un solo nodo, con el objeto de tener mayor claridad en la explicación. La Figura 20 representa el nodo 3 del escenario en estudio y el cual contiene fallas entre línea A y línea B.

Al detallar con detenimiento la Figura 20 se observa una línea de puntos que no se encuentra dentro del resultado general de la derivada (datos con y sin falla). Estos puntos corresponden a una señal transitoria que se encuentra al iniciar el archivo de datos de cualquier escenario. Como esta información carece de veracidad, el paso a seguir es eliminar los primeros 50 datos en los cuales por el momento, se asume que no tendrán falla, y es donde se ubica el transitorio.

Derivada de la diferencia de ángulo




Figura 20. Derivada de la diferencia para el Nodo 3

Si se representa nuevamente la información se obtendrá la Figura 21. En esta Figura, se observan claramente tres grupos, un con mayor concentración de datos (en el centro) y dos con una concentración de datos menor (a los lados). Como la derivada de la diferencia de una señal que no presenta falla será aproximada a cero, entonces, se catalogan los datos cercanos al origen como datos sin fallas. Para el caso en estudio los datos sin fallas serán los de mayor concentración ya que su valor es el mas cercano a cero. Los datos mas alejados corresponderán a datos con una diferencia mucho mayor a cero y serán, de acuerdo a la definición, datos con falla.

Derivada de la diferencia de ángulo sin transitorios

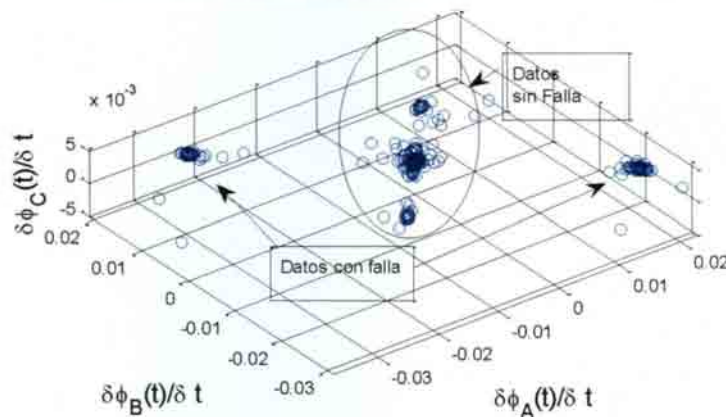


Figura 21. Derivada de la diferencia de ángulo sin los transitorios

Se ha visto que los datos que se denominaron con falla pertenecen a dos grupos; pues bien, estos corresponden realmente a un único grupo, pero éste produce un reflejo en su octante opuesto,

debido a que un punto representado en un plano tridimensional siempre representa una proyección a modo de sombra. Para evitar el duplicado de la información se toman únicamente los datos de primer octante, lo que ayudará en el momento de hacer la agrupación usando el método de Fuzzy c-means.

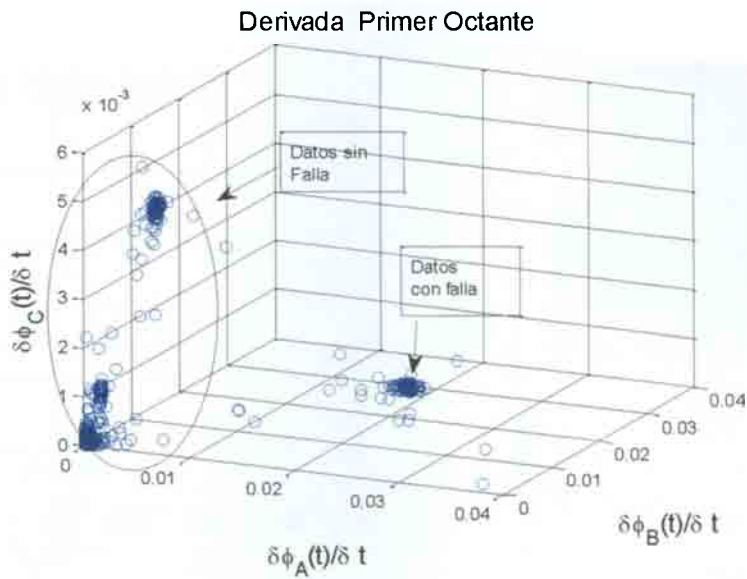


Figura 22. Derivada de la diferencia de ángulo en el primer octante

4.2.1.1. Clasificación de las fallas mediante Fuzzy c-Means

Como se vio anteriormente se definen los grupos de datos con falla y sin falla. Para hacer una mejor valoración de cómo cada punto hace parte de uno de estos grupos, se utilizará la herramienta de clasificación de datos Fuzzy c-Means. En matlab esta herramienta se encuentra como *fcm*.

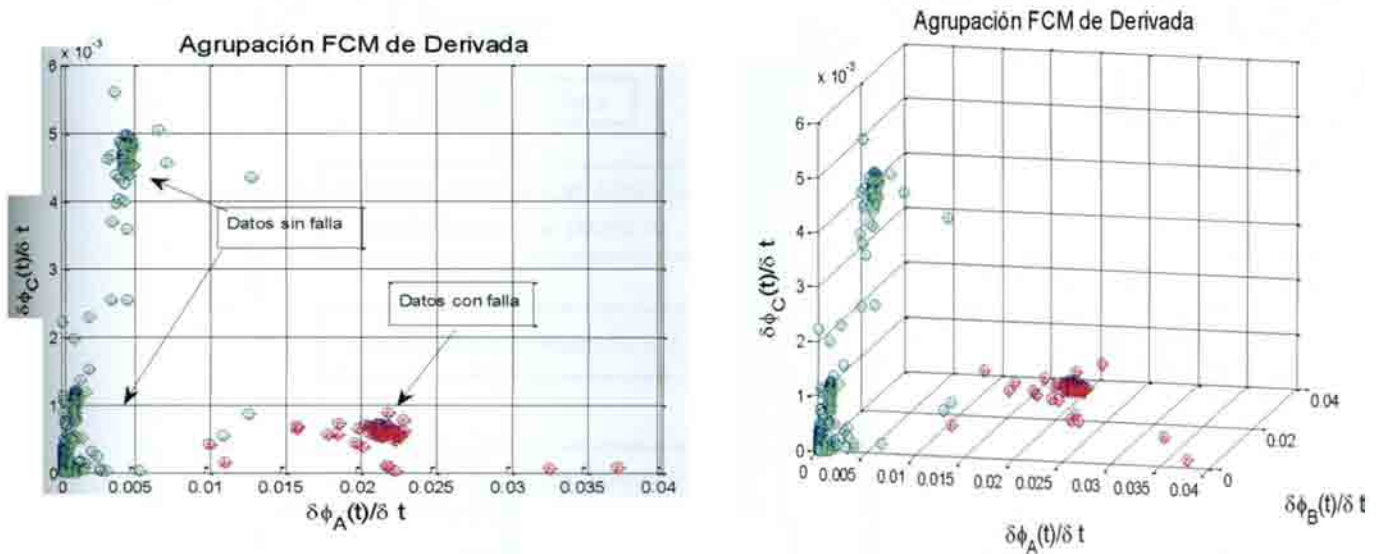


Figura 23. Aplicación de *fcm* a la derivada del desfase de los datos

La función *fcm* de matlab en términos, de programación, es una técnica en la cual un conjunto de datos es organizado en un número n de grupos (clusters), donde a cada dato del conjunto de datos se le asigna un grado de membresía U a un grupo. Por ejemplo, un cierto dato que se acerca al centro de un grupo (cluster) va a tener un alto grado de membresía y un dato que este lejos del centro va a tener un grado de pertenencia mucho menor. Este valor de membresía varía entre 1 y 0, el valor 1 significa que es un miembro del grupo, mientras que el valor 0 indica que no lo es, valores que se encuentren entre estos dos indicarán que son parcialmente miembros de alguno de los grupos. En el algoritmo de Fuzzy c-Means, para cada iteración, una función objeto es minimizada para encontrar la mejor ubicación de los grupos (clusters)

Se ha visto hasta este punto la obtención de la fase, su acondicionamiento y la clasificación de estos datos cuando se trabaja con un solo nodo en falla. Para facilitar el entendimiento de este proceso se utiliza diagrama de flujo de la Figura 24.

Diagrama de Flujo

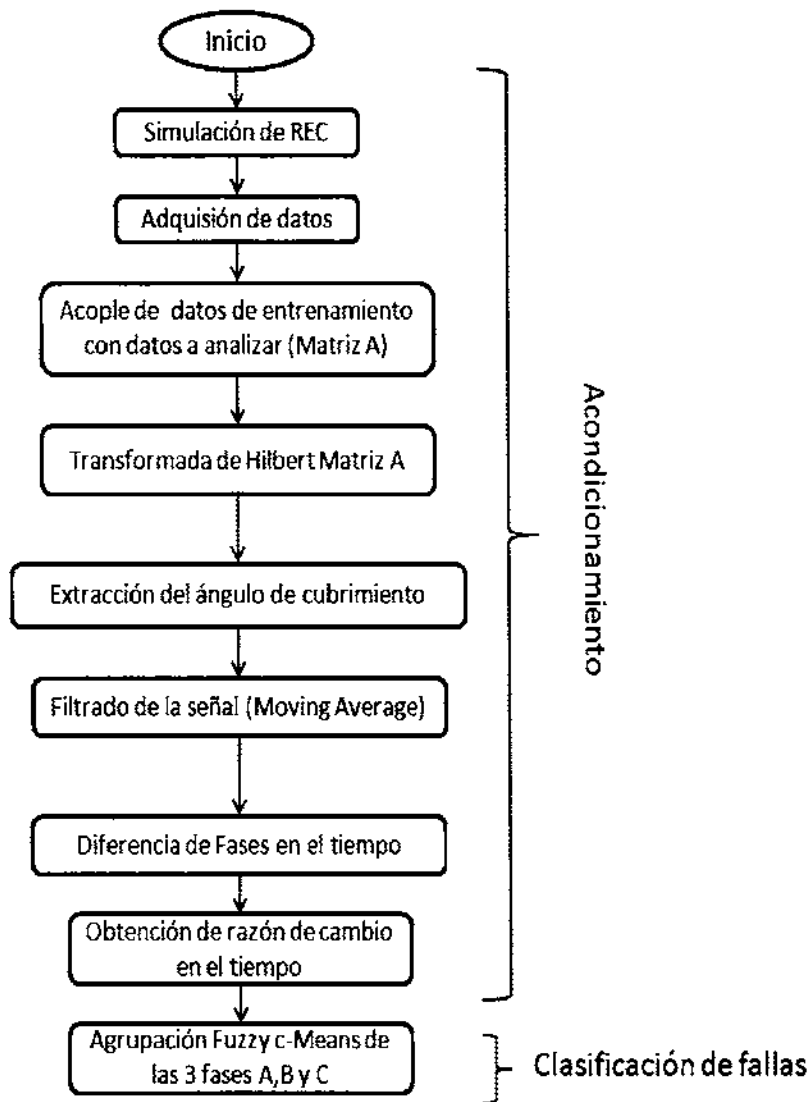


Figura 24. Diagrama de flujo para agrupación fuzzy de un solo nodo con falla

4.2.1.2. Análisis para 2 Nodos con distinto tipo falla

Para esta segunda de etapa de pruebas se utilizó el escenario: *Datos5F24-8-18-4-2,1* y se realizó el mismo procedimiento que el utilizado para el análisis con un nodo. Específicamente se analizaron los nodos 24 y 18, cada uno con una falla simulada, así:

Falla nodo 24: Líneas A-B-C a GND

Falla nodo 18: Línea a Línea A-B

Se obtuvo como resultado, en la clasificación por Fuzzy c-Means, la gráfica de la Figura 25




Figura 25. Agrupación de datos para dos nodos con falla.

En la gráfica de la Figura 25 se observa que los datos de falla en nodo 24, líneas A, B y C a GND, son plenamente reconocidas por el algoritmo de agrupación y corresponde a los puntos en rojo; mientras que los datos de la falla en el nodo 18, problema entre las líneas A y B, no son separados por el algoritmo. Sin embargo, al ampliar la zona de datos sin falla, área encerrada en el

círculo, es posible reconocerlos, ya que éstos conservan su forma. El no reconocimiento de los datos de las fallas por parte del sistema Fuzzy c-Means se debe a que los datos de las fallas línea a línea tienen valores muy cercanos a los de los datos cuando no hay fallas (comparado con el valor que toma un dato con falla línea a tierra). A estos datos se les asigna una clasificación en la variable U (membresía de grupo), de Fuzzy c-Means. Comparando los valores de membresía del grupo se puede definir cuáles son los datos de falla línea-tierra.

Se realizó una segunda prueba para 2 nodos con el mismo tipo de falla. Se utilizó el escenario: *Datos5F3-6-15-20-9*, y de éste los nodos 3 y 9. Específicamente las fallas fueron:

- Falla 1. Nodo 3, falla Línea a Línea, líneas A-B
- Falla 2. Nodo 9, falla Línea a Línea, líneas B-C

Al aplicar el algoritmo se obtuvo la gráfica de agrupación de datos de la Figura 26.

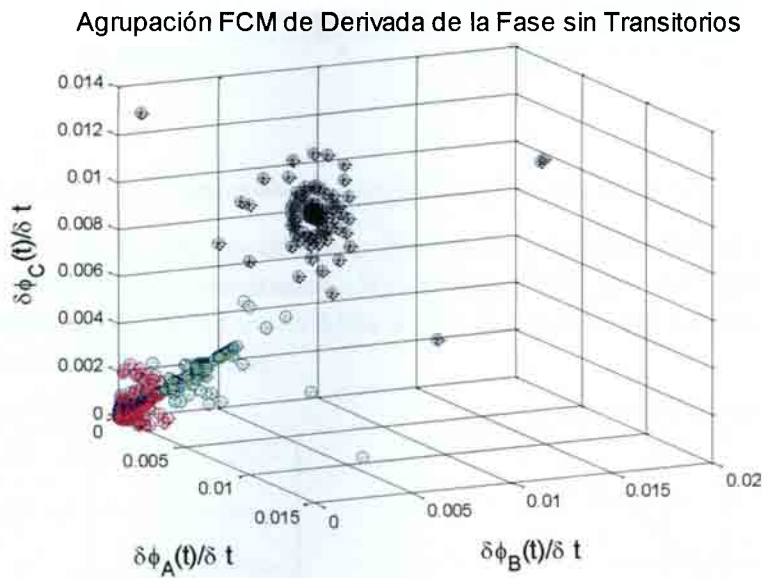


Figura 26. Agrupación Fuzzy c-means de dos nodos con tipo de falla línea a línea

Como se trata de dos fallas línea a línea, los valores de membresía de grupo U hacen diferencia entre los datos con falla línea –línea y los datos sin falla. Por tanto es posible la clara identificación de los tres grupos de datos. Los datos en rojo que corresponden a los datos sin falla, los datos en verde que son las fallas entre las líneas A-B del nodo 9 y los datos en negro que son las fallas entre líneas B-C del nodo 3.

Una tercera prueba de agrupación de datos con dos fallas corresponde la que se ejecuta a continuación. En este caso se utiliza el escenario: *Datos5F24-8-18-4-21*, del cual se toman los nodos 4 y 8. Estos 2 nodos tienen el mismo tipo de falla que son las siguientes:

- Fallas: Falla 1. Nodo 8 Falla Línea –Tierra A-C-GND
- Falla 2. Nodo 4 Falla Línea -Tierra B-C-GND

Usando el algoritmo para la agrupación Fuzzy c-Means obtenemos la gráfica del la Figura 27.

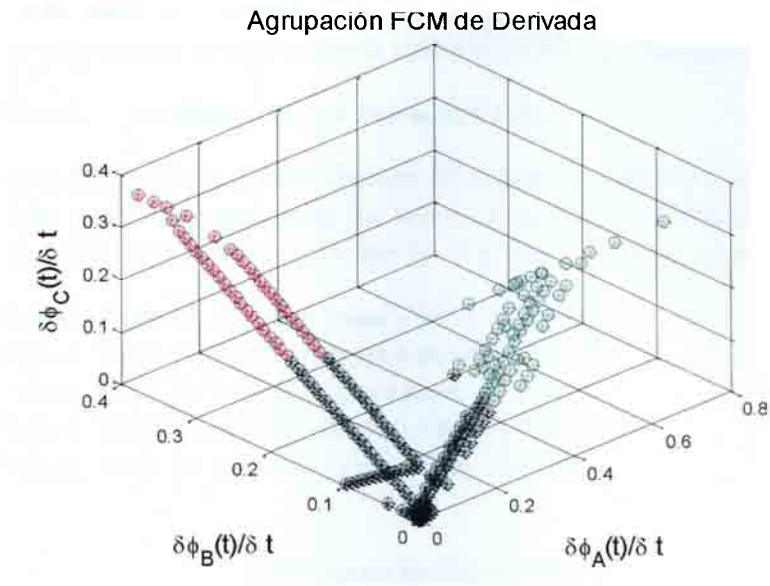


Figura 27. Agrupación Fuzzy c-means de dos nodos con tipo de falla línea a tierra.

En la Figura 27 se observa las dos diferentes fallas a tierra: los datos en azul corresponden los datos sin falla, los datos en rojo corresponden a la falla línea a tierra de A y C del nodo 8, y los datos en verde corresponden a la falla Línea a tierra de B y C del nodo 4. La Figura 28 muestra estos mismos datos desde ángulos diferentes.

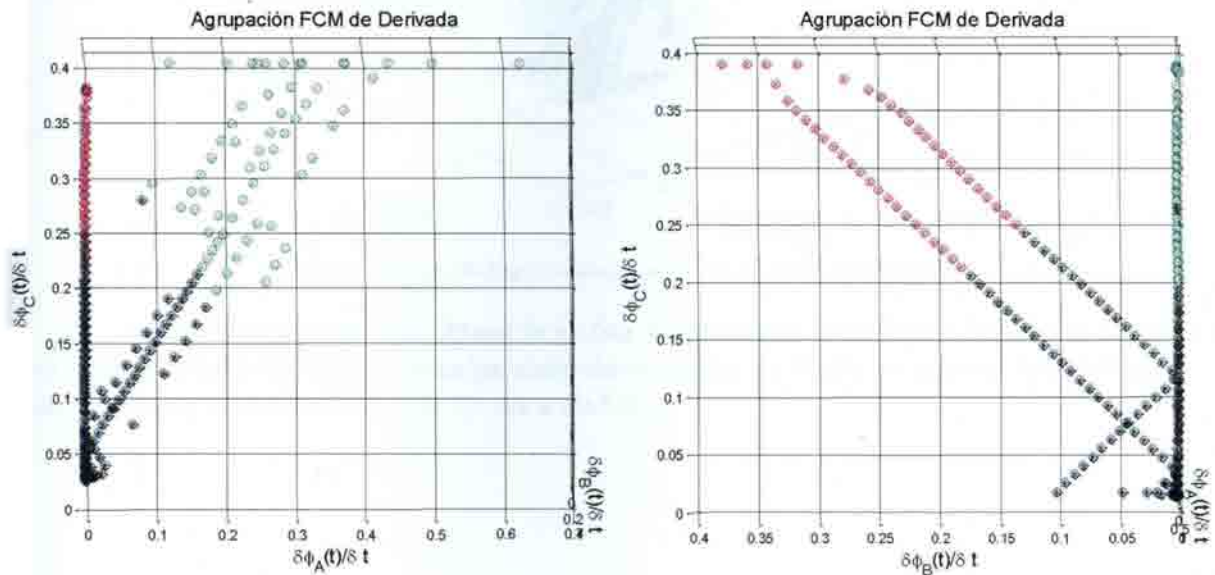


Figura 28. Agrupación Fuzzy c-Means de dos nodos con tipo de falla línea a tierra, vista 3D desde diferente ángulo.

Debido a la distribución de los datos con la respuesta a la agrupación por Fuzzy c-Means, se puede sacar una conclusión de tipo práctico: cuando se aplique el algoritmo para un escenario completo se debe hacer el reconocimiento en dos pasos, inicialmente para los datos que se encuentran con fallo a tierra, y como segunda instancia los datos que tienen falla línea a línea.

4.2.1.3. Análisis para un escenario completo.

La tercera etapa se basa en la aplicación del mismo algoritmo usado en el análisis de las 2 etapas anteriores, para la agrupación de los datos, empleando el sistema de Fuzzy c-Means. A continuación se analizará el escenario: *Datos5F14-18-24-23-10*, con las siguientes fallas simuladas:

- Falla 1. Nodo 10, falla tipo líneas a tierra. B-C-GND
- Falla 2. Nodo 14, falla tipo líneas a tierra. A-B-GND
- Falla 3. Nodo 18, falla tipo línea a línea. A-B
- Falla 4. Nodo 23, falla tipo líneas a tierra. A-B-C-GND
- Falla 5. Nodo 24, falla tipo líneas a tierra. B-GND

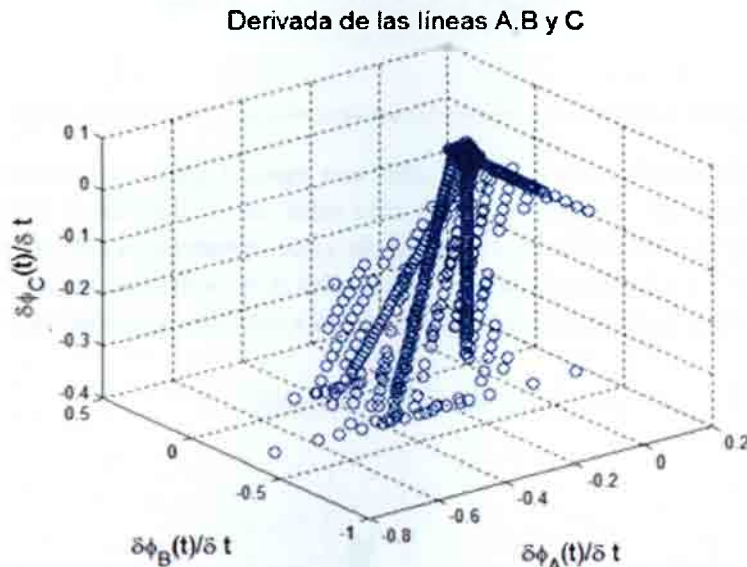


Figura 29. Agrupación Fuzzy c-means para todos los casos del escenario

Al aplicar el algoritmo se obtiene la gráfica de agrupación de la Figura 29. En esta ocasión se emplearán todas las fases de todos los nodos del escenario. La Figura 30 muestra la distribución discriminando los datos de fallas de los datos sin fallas.

Agrupamiento de Derivada de la diferencia




Figura 30. Derivada de diferencia sin transitorios para todos los datos del escenario

Este escenario presenta 4 nodos con falla a tierra y un nodo con falla línea a línea. La Figura 29 muestra la derivada de las fases para todos los nodos, y la Figura 30 la agrupación Fuzzy c-Means para los componentes con y sin falla, pero sin discriminar el tipo de falla. Lo que se hará a continuación será seleccionar solamente datos correspondientes a fallas a tierra. La Figura 31 muestra de distribución de las fallas a tierra, pero sin discriminar a que nodo pertenecen.

Representación de las fallas a tierra

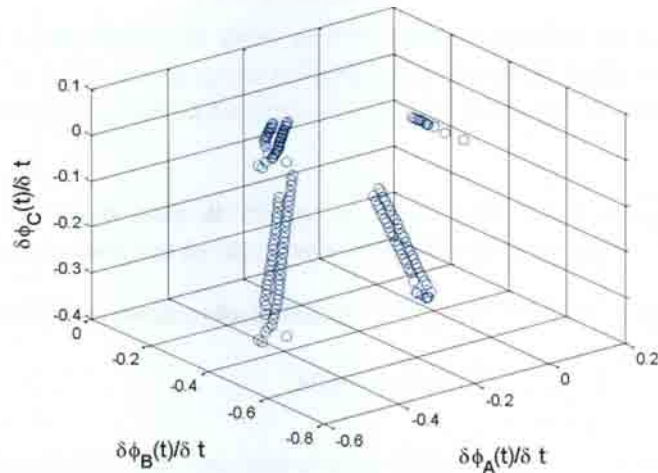


Figura 31. Derivada de las líneas con falla a tierra

Adquisición del diagrama de flujo del algoritmo

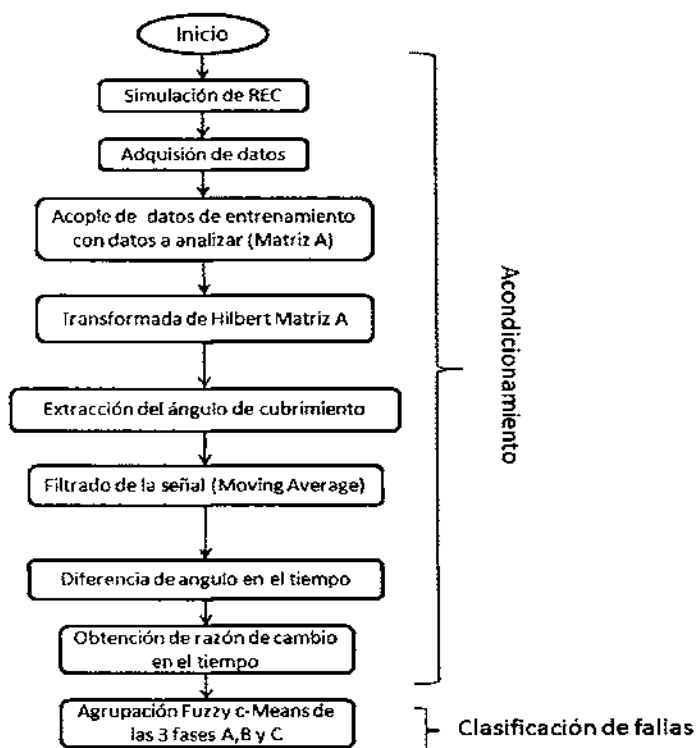


Figura 32. Diagrama de flujo del Algoritmo para un escenario completo

4.2.1.4. Descripción del Diagrama de flujo

1- La captura o adquisición de datos se hace desde el archivo de texto generado por la simulación de la REC, con la ayuda del programa *Microtran* hacia Matlab a través de la instrucción *load*. Esto permitirá hacer uso de todos los datos que se encuentran en el archivo de texto.

2- Se aplica la transformada de Hilbert al conjunto de datos con el fin de obtener la frecuencia y fase de cada una de las señales de línea de cada nodo.

De la ecuación (1), la transformada de Hilbert de la señal de voltaje $V(t)$ está definida por:

$$H(V) = \frac{1}{\pi t} * V(t) \quad (41)$$

Esta transformada es una convolución entre la señal original y $\frac{1}{\pi t}$, como se explicó anteriormente. La señal analítica $A(t) = V_r + j * V_i$ tiene una parte real V_r la cual son los datos originales y una parte imaginaria $j * V_i$, la cual contiene la transformada de Hilbert. La parte imaginaria es una versión de la secuencia real original, con un desfase de

90°. La ventaja de la transformada de Hilbert es que todas las frecuencias negativas de la señal original han sido filtradas.

Después que la transformada de Hilbert es aplicada a la señal original, se construye una envolvente de la señal compleja como se muestra a continuación:

$$E(t) = |A(t)| = |V(t) + jH(t)| \quad (42)$$

3- Como el parámetro a analizar corresponde a la fase de la señal, se hace la extracción únicamente de este parámetro con la instrucción *angle* de Matlab, obteniéndose la envolvente que gráficamente se representa en la Figura 33




Figura 33. Gráfica de la extracción de la fase de cada senooidal de los 24 nodos

4- Se utiliza la *unwrap* de Matlab para adquirir los ángulos de cobertura en un solo vector de datos, esto lo logra adicionando múltiplos de 2π , obteniendo la Figura 34 a continuación



Figura 34. Vector de ángulos de la señal de los 24 nodos

5- Para evitar que la señal reconozca algunos saltos como fallas, se diseñó un filtro de promedio móvil con un rango de 50.




Figura 35. A la izquierda se encuentran los vectores de ángulo sin filtrar a la derecha se ha aplicado el filtro de promedio móvil

6- Se hace ahora la diferencia de fase en el tiempo entre una señal con falla y una sin falla - de tal forma que aquellos datos que no tienen falla la diferencia tenderá a cero mientras que los datos con falla la diferencia será mucho mayor a cero, como se muestra en la siguiente Figura. Para ello se usa el valor de la pendiente m que se halló anteriormente.



Figura 36. Resultado de la diferencia de fases

7- A la señal anterior se aplicará la derivada, ya que ésta representa la rapidez de cambio de una función en el tiempo. Los datos dados por la derivada se ubican en un sistema de 3 dimensiones, ya que siempre se tienen 3 líneas. La gráfica obtenida es la de la Figura 37.




Figura 37. Derivada de la fase en 2D con respecto al tiempo y 3D con respecto a las tres fases

8- Se hace agrupación de los datos, discriminando los datos con falla de los datos sin falla, mediante la función *fc* (Fuzzy clustering). Figura 38.



Figura 38. Agrupación Fuzzy de la derivada de la fase

4.2.1.5. Clasificación Jerárquica de las Fallas

Como se vio en la Figura 25, analizando un escenario con fallas combinadas a tierra y fallas línea a línea, la clasificación de fallas línea a tierra es fácilmente identificable mientras que no es tan sencillo para las fallas línea a línea, debido al no reconocimiento de grupo que sufren los datos con falla línea a línea y los datos sin falla, cuando hay presencia de fallas a tierra. Se buscó la manera de hacer eficiente y correcta esta clasificación de datos. La manera encontrada fue a través del establecimiento de jerarquías durante la clasificación, este procedimiento se describe a continuación.

Una modalidad de representación de las fallas es hacerlo en un plano bidimensional: en función del tiempo en que se presenta la falla y en función del nodo a que pertenece. Figura 39. Durante este proceso se le asigna un nivel de jerarquía al tipo de falla: Las fallas tipo Línea a tierra se definirán como de nivel 1, y las fallas tipo Línea a línea como de nivel 2.

Para determinar las fallas Línea-Tierra, primero se identifican los índices que representan las fallas, lo cual se hace en el agrupamiento, por medio de la comparación de los centros de cada uno de los grupos. La información de los centros de cada agrupamiento es provista por la clasificación de datos *fcm* a través de la función *center* de Matlab. Ahora se forma la matriz de fallas a tierra, representada en la Figura 39.




Figura 39. Representación de fallas a tierra indicando tiempo y nodo en que se presenta.

Una vez que se han encontrado las fallas a tierra, se aíslan de la matriz original los nodos involucrados en ellas, y así facilitar identificación de las fallas de Línea-Línea. Se forma nuevamente la matriz de las derivadas de fase utilizada en el procedimiento anterior y se repite el mismo proceso utilizado para encontrar las fallas línea-tierra




Figura 40. Derivada de la diferencia del ángulo de cobertura antes (izq) y después (der) de hacer el agrupamiento por fcm




Figura 41. Representación de fallas línea- línea indicando tiempo y nodo en que se presentan.

Como paso final a esta sección se hace una representación conjunta de las fallas línea-línea y las fallas línea – tierra que muestra la Figura 42 y que muestra las clases de fallas en una sola gráfica.




Figura 42. Representación conjunta de las fallas .El color indica el tipo de falla: Rojo, fallas línea – tierra. Verde falla línea – línea. También ubica el nodo y tiempo de la falla.

En la representación conjunta de la Figura 42 se identifican 2 colores en los datos mostrados, el rojo y el verde. Esto se hizo para facilitar al usuario la identificación de la clase de

falla. Si es una falla de línea a tierra se representa con color rojo, si es una falla de línea a línea se representa con color verde. Además el eje X corresponde al tiempo (ms). El inicio de la marca indica el tiempo estimado del inicio de la falla. Sobre el eje Y se identifica el nodo al que pertenece la falla.

Una vez identificados estos parámetros se inicia la búsqueda del último parámetro por conocer de la falla, que es el “Tipo de falla”. Para determinarlo se analiza el siguiente procedimiento.

4.2.1.6. Tipos de fallas y su ubicación.

Una vez que las fallas han sido jerarquizadas, dependiendo de si son fallas línea a tierra o fallas línea-línea como se observa en la Figura 42, se deben ubicar con mayor precisión los sitios donde se localizan, lo mismo que confirmar el tipo de falla. En otras palabras, poder determinar en cual línea ó líneas del nodo está localizada una falla. Se sabe de antemano que pueden existir 10 tipos de fallas diferentes las cuales se mencionan en la Tabla 1. Para este propósito de ubicación se hace uso de las coordenadas esféricas. En el capítulo 2 se presenta un breve recordatorio de teoría de estas coordenadas.

Como ya se había obtenido la diferencia del ángulo de cobertura, ahora se aplica la función de matlab “*sph2cart*”, se convierte esta información, que inicialmente está en coordenadas cartesianas, a coordenadas esféricas; el resultado es una matriz que se llama “Theta (θ)”, otra matriz que se llama “Phi (ϕ)” y una tercera que “Rho (ρ)”. Posteriormente se multiplica la primera matriz “Theta (θ)” por la matriz de fallas a tierra; el resultado es una nueva matriz que se llama “Theta θ_f ”. Esta información es únicamente de los nodos que tiene falla a tierra. Expresándolo de manera matemática se tendría:

$$\theta_f = \theta \times fallas_m \quad (43)$$

donde: Theta es la matriz de diferencia de ángulo de cobertura obtenida por la derivada

fallas_m : Matriz de unos y ceros: los 1's representan la presencia de fallas a tierra, y los 0's la ausencia de fallas a tierra

θ_f es la matriz resultante .

Ahora se calcula el valor mínimo de la división de la suma del vector columna de la matriz θ_f entre la suma del vector de fallas, lo cual entrega como resultado un vector θ_{ff} con los valores de los ángulos θ , en radianes. Si no hay falla el valor será de 0. Cada columna del vector corresponde a un nodo. Matemáticamente, lo anterior se expresa como:

$$\theta_{ff} = \min \frac{\sum \theta_f}{\sum \theta_m} \quad (44)$$

Para hallar los valores de los ángulos ϕ , se sigue un procedimiento similar.

El paso siguiente es nuevamente pasar los datos al plano cartesiano (X, Y, Z) y elaborar una tabla de clasificación de los resultados dependiendo el tipo de falla a tierra. Tabla 2.

Tipo de fallas a tierra	
Índice	Tipo de Falla
1	Falla _A = [-1, 0, 0];
2	Falla _B = [0, -1, 0];
3	Falla _C = [0, 0, -1];
4	Falla _AB = [-1, -1, 0]/√2
5	Falla _AC = [-1, 0, -1]/√2
6	Falla _BC = [0, -1, -1]/√2;
7	Falla _ABC = [-1,- 1, -1]/√3

Tabla 2 Tipo de fallas a tierra

La Figura 43 muestra el sistema de coordenadas esférico utilizado para ubicar los ángulos calculados.

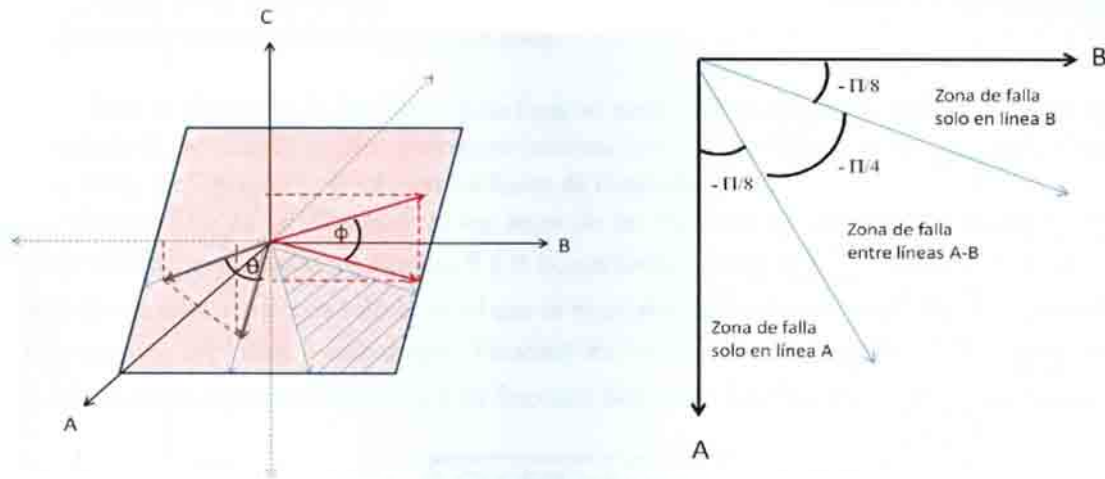


Figura 43. Representación grafica de la posición de las fallas en un plano tridimensional

hora se elabora otra matriz llamada "falla m c", la cual indicará, por medio de un índice que se ve en la Tabla 2 describe el tipo de falla a tierra que se está presentando. Para lograrlo se hace un análisis del tipo de falla en cada una de las líneas A, B y C para cada nodo calculando: la suma de los cuadrados de la diferencia entre el vector de falla (vector con el valor del ángulo de falla X, Y y Z) con el valor de la falla. El resultado es la matriz falla_m_c. Todo se puede resumir con la siguiente ecuación:

$$falla_m_c(indice) = (X - Tipo\ de\ falla(1))^2 + (Y - Tipo\ de\ falla(2))^2 + (Z - Tipo\ de\ falla(3))^2 \quad (45)$$

A esta matriz de fallas se le aplica el comando "min" de matlab. Este comando selecciona el valor mínimo por columna que se encuentra en la matriz y lo asocia a un índice determinado dando como resultado el vector índice que se muestra a continuación, este será el tipo de falla a tierra que se está presentando.

```
Index = 7 0 0 0 0 3 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 7 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 4
```

La matriz informa, si hay falla, el tipo de falla y el nodo en que se encuentra.

Haciendo un arreglo de matrices se extrae la información relevante que se muestra la tabla siguiente: Los detalles de los tipos de falla se encuentran en la Tabla 3.

ns =		NODO	TIPO DE FALLA
1	7	1	7
6	3	6	3
24	7	24	7
48	4	48	4

Tabla 3. Ubicación y tipo de falla a tierra en la red

Los tipos de falla a tierra se reconocieron inicialmente como una numeración del 1 al 7, Tabla 2, dependiendo del tipo de falla; pero en la información mostrada al usuario se identifican por su nombre como se verá más adelante.

Ahora ya se tiene la información requerida con respecto a las fallas a tierra, pero aun se necesita la información de las fallas línea a línea.

Para la ubicación de las fallas línea-línea se toman los conceptos de coordenadas esféricas del capítulo 2, de acuerdo a estos conceptos tenemos que, para la aplicación del presente proyecto, $X=A$, $Y=B$, $Z=C$, donde A, B y C son las líneas de la red eléctrica.

Nota: Por análisis de la ubicación de los datos de las fallas en las coordenadas esféricas, se ha podido verificar que cuando los ángulos θ y ϕ tienen valores menores a $\frac{\pi}{8}$, un dato de falla que esté dentro de ese arco, pertenece sólo al eje al que se encuentre más cercano. Si el dato se encuentra en los $\frac{\pi}{4}$ restantes, pertenece a ambos ejes. Teniendo en cuenta esta observación se logra establecer a qué línea o líneas pertenece la falla que un dato esté indicando. La Figura 44 resume lo anterior.




Figura 44. Manera de ubicar las fallas en las líneas.

Para la ubicación de las fallas línea-línea se usaron los valores esféricos de los ángulos θ y ϕ , ya que éstos, de acuerdo al cuadrante, permiten conocer la ubicación de los datos y de esta manera determinar el tipo de falla. Los valores de θ y ϕ se obtuvieron a partir del producto entre la matriz de fallas línea-línea "fallas_mm_1" y la matriz de derivadas en coordenadas esféricas. La

matriz “fallas_mm_1” tendrá valores de cero cuando no presente fallas y valores de 1 cuando si presente fallas.

Gráficamente se puede interpretar de la siguiente manera:

Si la falla es del tipo A-C entonces, tiene componentes en los ángulos θ y ϕ ; para el ángulo θ puede encontrarse el dato con valores entre $\frac{\pi}{8}$ y $-\frac{\pi}{8}$ ó $-\frac{\pi}{8} < \pi < \frac{\pi}{8}$ además para el ángulo ϕ debe tener un valor mayor a $\frac{\pi}{4}$.

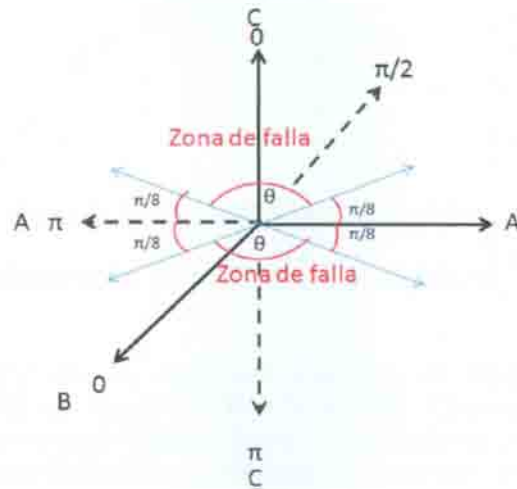


Figura 45. Localización de la falla A-C en el plano esférico

Si la falla es de tipo B-C, entonces tiene componentes en el ángulo θ con valores $\frac{\pi}{8} < -\frac{\pi}{2} < \frac{\pi}{8}$ ó

$$\frac{\pi}{8} < -\frac{\pi}{2} < \frac{\pi}{8}$$




Figura 46. Localización de la falla B-C en el plano esférico

Para cualquier otro caso corresponderá a una falla entre las líneas A-B

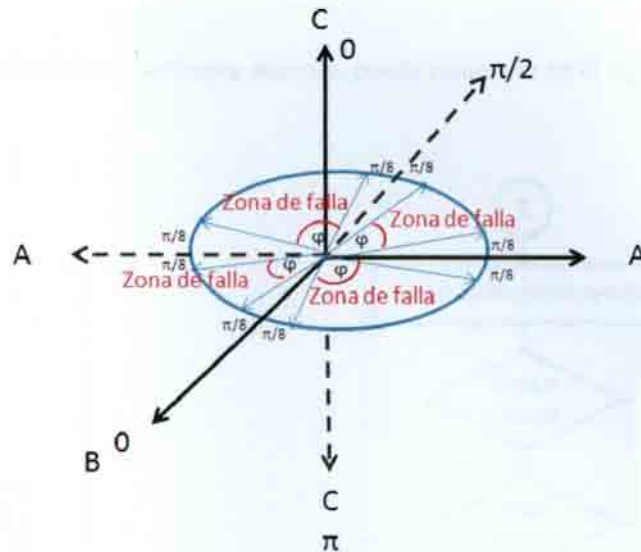


Figura 47. Localización de la falla A-B en el plano esférico

Como en el caso de las fallas a tierra, ahora se calcula los ángulos φ y θ , para las fallas línea – línea.

Posterior a esto y con los resultados obtenidos, se forma una matriz la cual se ha denominado *Maux*, esta es una matriz de 48×3 : 48 filas, 1 para cada nodo; 1 columna para el número de nodo; 1 columna para fallas a Tierra, y 1 columna para fallas línea a línea. De esta información se extraen los datos útiles o relevantes, es decir los nodos que contienen falla con el tipo de falla así:

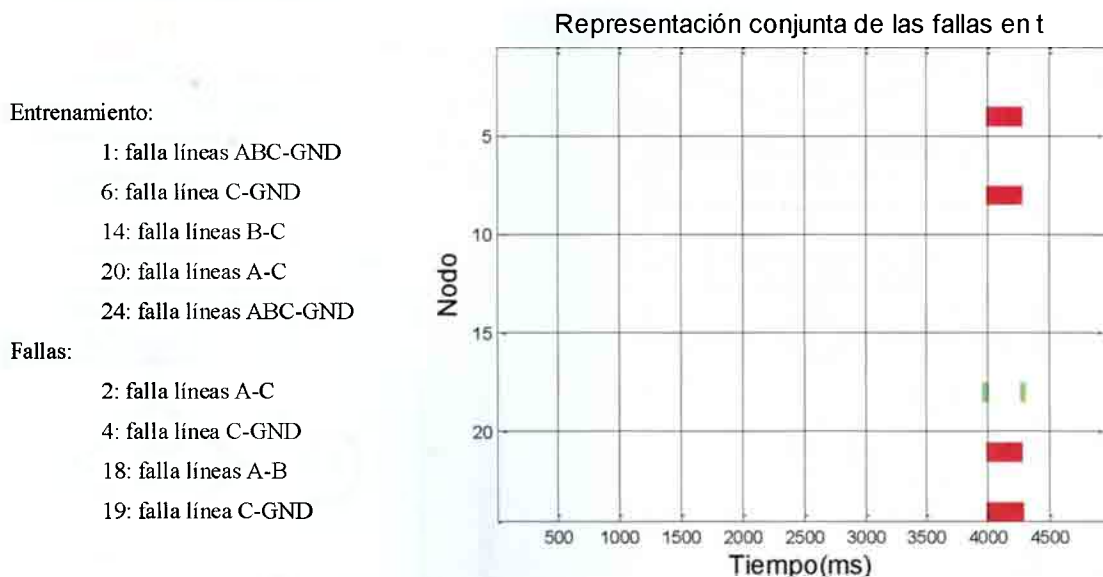
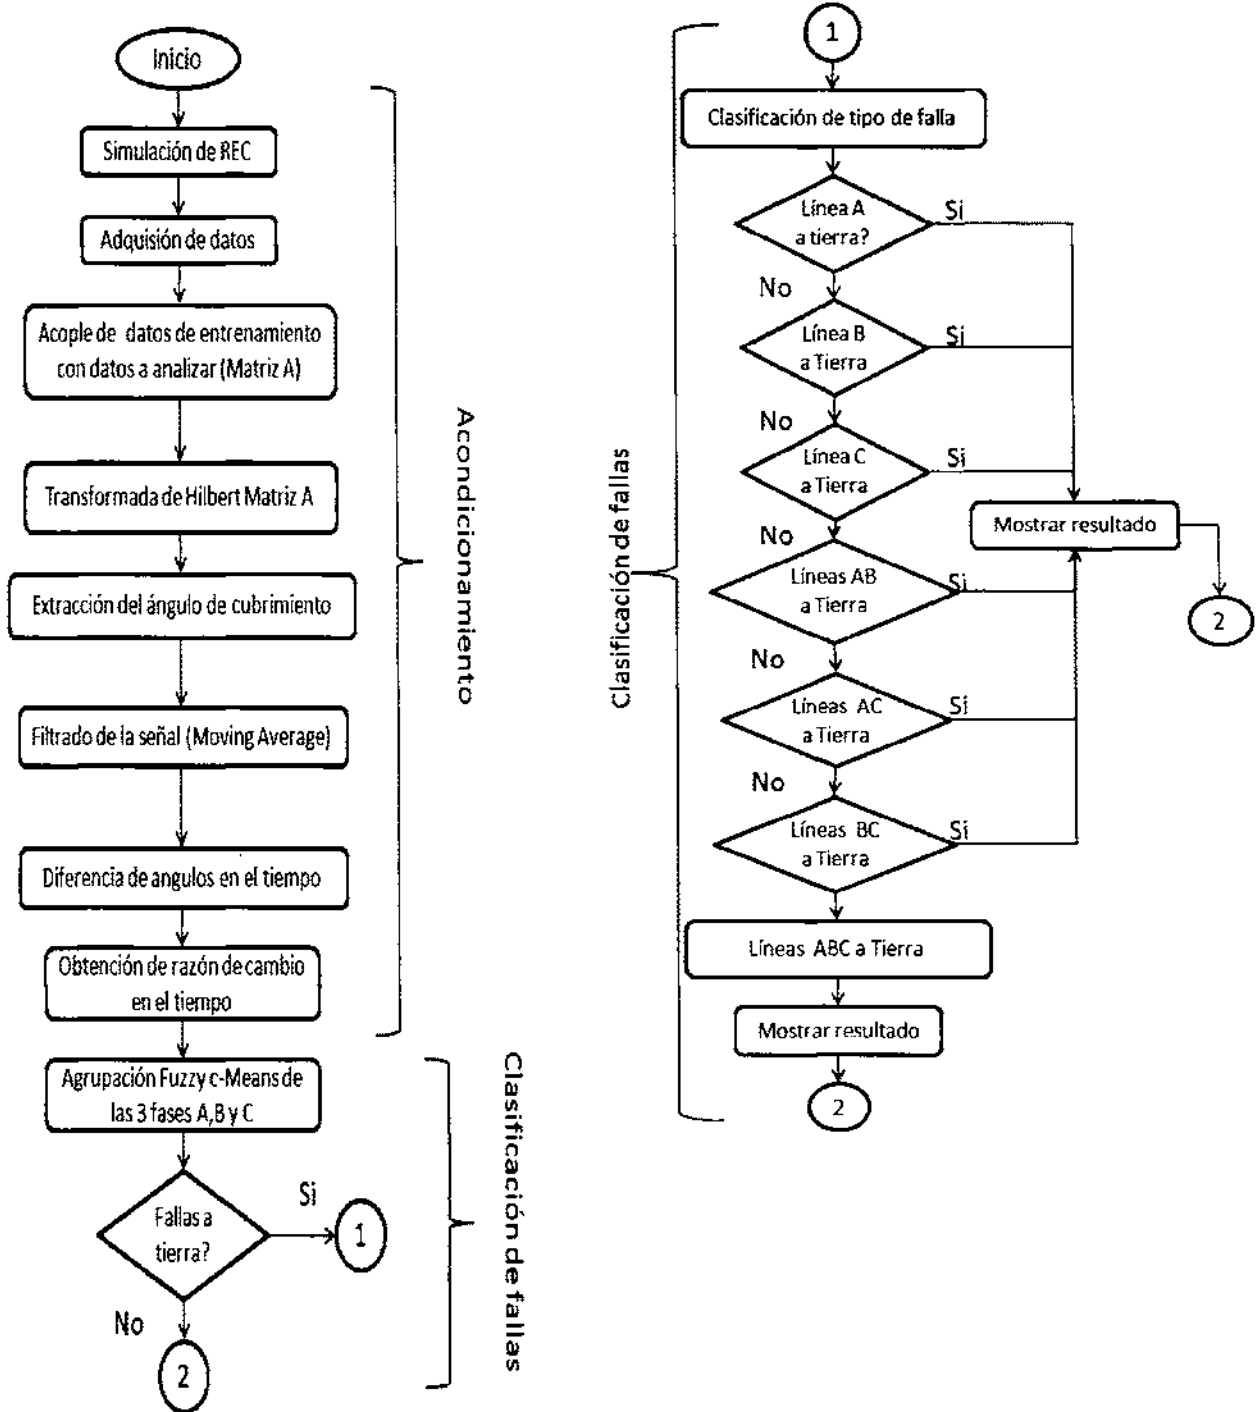


Figura 48. Resultado del algoritmo Hilbert Fuzzy c-Means

Con la representación conjunta se logra tener la información requerida: tipo de falla, clase de falla, nodo en el que se presenta la falla y tiempo aproximado en que se presenta la falla.

Todo el procedimiento anteriormente descrito, puede resumirse en el siguiente diagrama de flujo.



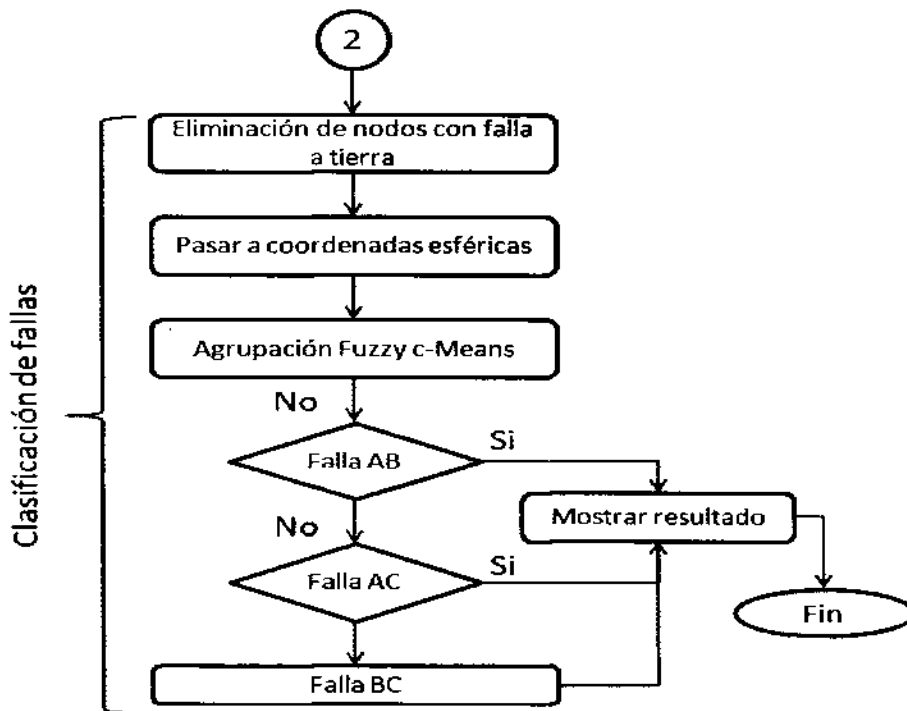


Figura 49. Diagrama De flujo del algoritmo Hilbert Fuzzy c-Means

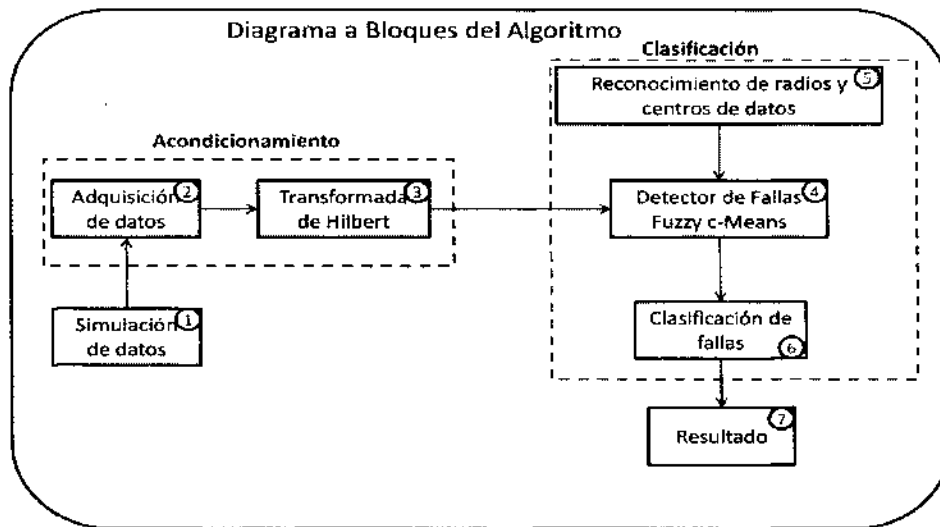


Figura 50. Diagrama a Bloques del Algoritmo Hilbert - Fuzzy c-Means

La Figura 50 muestra el diagrama en bloques del algoritmo Hilbert - Fuzzy c-Means. En el bloque 1 se encuentra la información de los datos que es entregada por el software Microtran en forma de archivo de texto. A fin de poder extraer la información de la señal de voltaje de la fase

correspondiente, se transfieren manualmente estos datos, (bloque 2), al bloque 3 donde se les aplica la transformada de Hilbert. En esta etapa también se hace acondicionamiento de los datos mediante el análisis de señales. Utilizando el clasificador difuso Fuzzy c-Means se acondiciona la información al tipo de falla correspondiente y se clasifica. El clasificador Fuzzy c-Means realiza la distribución de los datos teniendo en cuenta la distancia entre ellos, (bloques 4, 5), y formando grupos con los datos más cercanos entre sí. La cantidad de grupos formados depende de la cantidad de clases de datos que se quieren distribuir; para este caso se tienen 2 clases de grupos: grupo de datos con falla y grupo de datos sin falla; esta etapa la realiza el bloque 6. Finalmente los resultados son mostrados por el programa del bloque 7.

5. CAPITULO 5

Hilbert - Varianza y la Transformada Onduleta

5.1. Algoritmo Hilbert - Varianza

El algoritmo Hilbert – Fuzzy c-Means que fue anterior mente desarrollado, será comparado con los resultados obtenidos a través de otro algoritmo que utiliza el mismo principio de transformada de Hilbert para el acondicionamiento de datos; pero, usa la varianza de la diferencia de ángulo de cobertura como método de clasificación de las fallas. Teniendo en como antecedente la breve descripción del concepto de varianza del capítulo 2, a continuación se presenta una breve descripción del algoritmo Hilbert-Varianza.

Para la explicación del algoritmo de usa un ejemplo que es el escenario *Datos4F4-2-19-18*. El algoritmo Hilbert Varianza inicialmente hace la captura de datos de los escenarios que se obtuvieron a partir de la simulación de la REC con el software Microtran. A esta matriz de datos capturada se aplica la transformada de Hilbert para obtener la fase de las líneas A, B y C de la señal de voltaje, y por medio del procedimiento de acondicionamiento que se siguió en el algoritmo Hilbert –Fuzzy c-Means, se obtiene la diferencia del ángulo de la señal de voltaje. La Figura 51 muestra el resultado de este proceso, cuando se presenta una falla. El análisis matemático para llegar a este resultado fue desarrollado en la sección 4.2.1




Figura 51. Gráfica de la diferencia de los ángulos

Ahora, se busca la mayor variabilidad de los datos de la matriz de desfase de la señal. Como se observa en la Figura 51. A una mayor variabilidad habrá una mayor posibilidad de falla.

La Figura 53 muestra el resultado de calcular y graficar la varianza de los datos de la diferencia de ángulo de la señal obtenidos anteriormente, Figura 52. Esta varianza se calcula para cada una de las 3 líneas (A, B y C) de los 24 nodos. En total son 72 líneas analizadas.

En este primer resultado de las varianzas, se determinaron las fallas a tierra tomando todos los nodos y líneas disponibles por escenario. Hay un valor singular de la varianza que es de 500. Este valor de 500 es el resultado de pruebas empíricas con los datos de diferentes escenarios y tipos de prueba, observándose en dichas pruebas que, para varianzas menores a 500, no hay presencia de falla, mientras, que si el valor de varianza iguala o supera los 500 existe falla.




Figura 52. Gráfica la diferencia de ángulo de cobertura después de la aplicación del filtro de promedio móvil.




Figura 53. Representación de la varianza en los 24 nodos 3 líneas

Posterior a este análisis de varianza para fallas a tierra, se toman las columnas que representan las líneas A y B de cada nodo, de la matriz originalmente capturada. Estas dos columnas se restan para obtener una diferencia y formar un nuevo vector. Este vector diferencia

de estas dos columnas proporcionará un valor no aproximado a cero, cuando se trate de presencia de falla. Ahora se forma una nueva matriz con cada uno de los 24 vectores resultantes de la diferencias y se efectúa nuevamente el análisis de Hilbert para selección de la fase. Se hace filtrado por con la ayuda del promedio móvil y se calcula y grafica la varianza. La Figura 54 muestra los resultados. Este procedimiento indicará cuando se tienen falla entre líneas A-B y en que nodo.




Figura 54. Representación de la varianza en los 24 nodos Líneas A-B

El mismo análisis hecho para las líneas A- B se realizó para las líneas A-C, y B-C y los resultados se observan en la gráfica de la Figura 55:

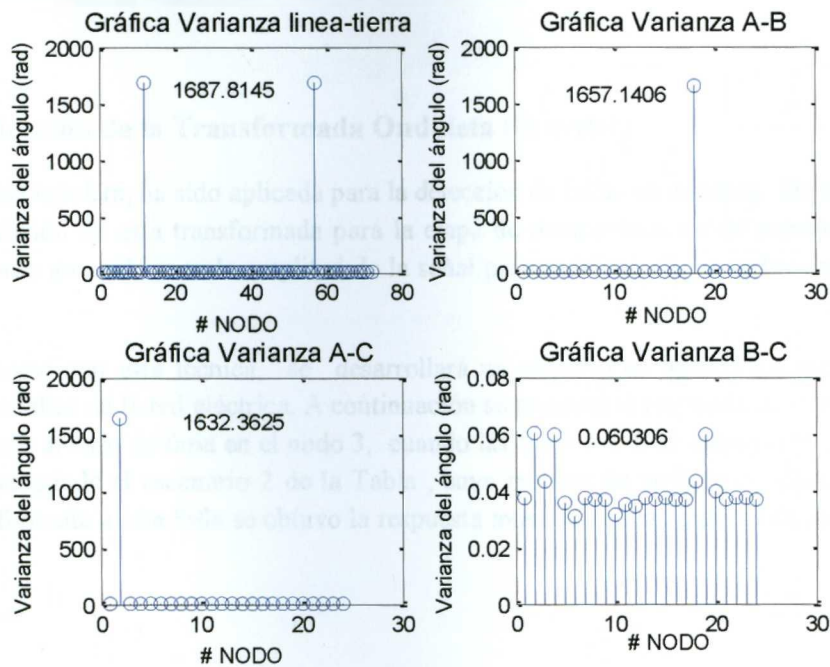


Figura 55. Representación de las varianzas en todos los casos

Una vez se tienen los nodos y líneas en los cuales se está presentando la falla, ahora se deben excluir aquellas fallas de A-B, A-C y B-C que presentan tanto en los casos de fallas a tierra como fallas línea a línea, ya que estas fallas corresponden únicamente a fallas línea a línea. De esta manera se logra tener la información requerida para los parámetros tipo de falla, clase de falla y Nodo en el que se presenta la falla. El programa del algoritmo arroja un resultado como se muestra a continuación:

```

Formato entregado por Matlab
nodos_tierra =
    4  19
residuo =
    3  3
    18: falla líneas A-B
    2: falla líneas A-C
    : falla líneas B-C

```

El resultado anterior se interpreta de la siguiente manera: Los nodos 4 y 19 presentan fallas a tierra en la línea 3 es decir, en la línea C. El nodo 18 presenta falla línea-línea entre A y B. El nodo 2 presenta falla línea a línea entre A y C. Ningún nodo presenta fallas entre líneas B y C. Si se hace una comparación del resultado arrojado por el algoritmo Hilbert – Varianza con la información que se tiene del escenario 34 en la Tabla, entonces, se puede decir que el resultado es correcto. Como se verá en el capítulo siguiente, el presente algoritmo fue probado en varios escenarios con muy buenos resultados.

5.2. Aplicación de la Transformada Onduleta (Wavelet)

La transformada Onduleta, ha sido aplicada para la detección de fallas en motores. De aquí nació la idea de la aplicación de esta transformada para la etapa de reconocimiento de patrones en la red eléctrica, haciendo un análisis en la amplitud de la señal para cada uno de los nodos caracterizados en la REC.

Para familiarizarse con esta técnica, se desarrollará un ejemplo de aplicación con una de las simulaciones de fallas de la red eléctrica. A continuación se presenta la respuesta de la transformada Onduleta aplicada al caso de falla en el nodo 3, cuando las fases A y B se encuentran a tierra. Esta simulación corresponde al escenario 2 de la Tabla, cuyo nombre de archivo es: Datos1F3.txt. Al aplicar la transformada a esta falla se obtuvo la respuesta mostrada en las gráficas de la Figura 56 y Figura 57:

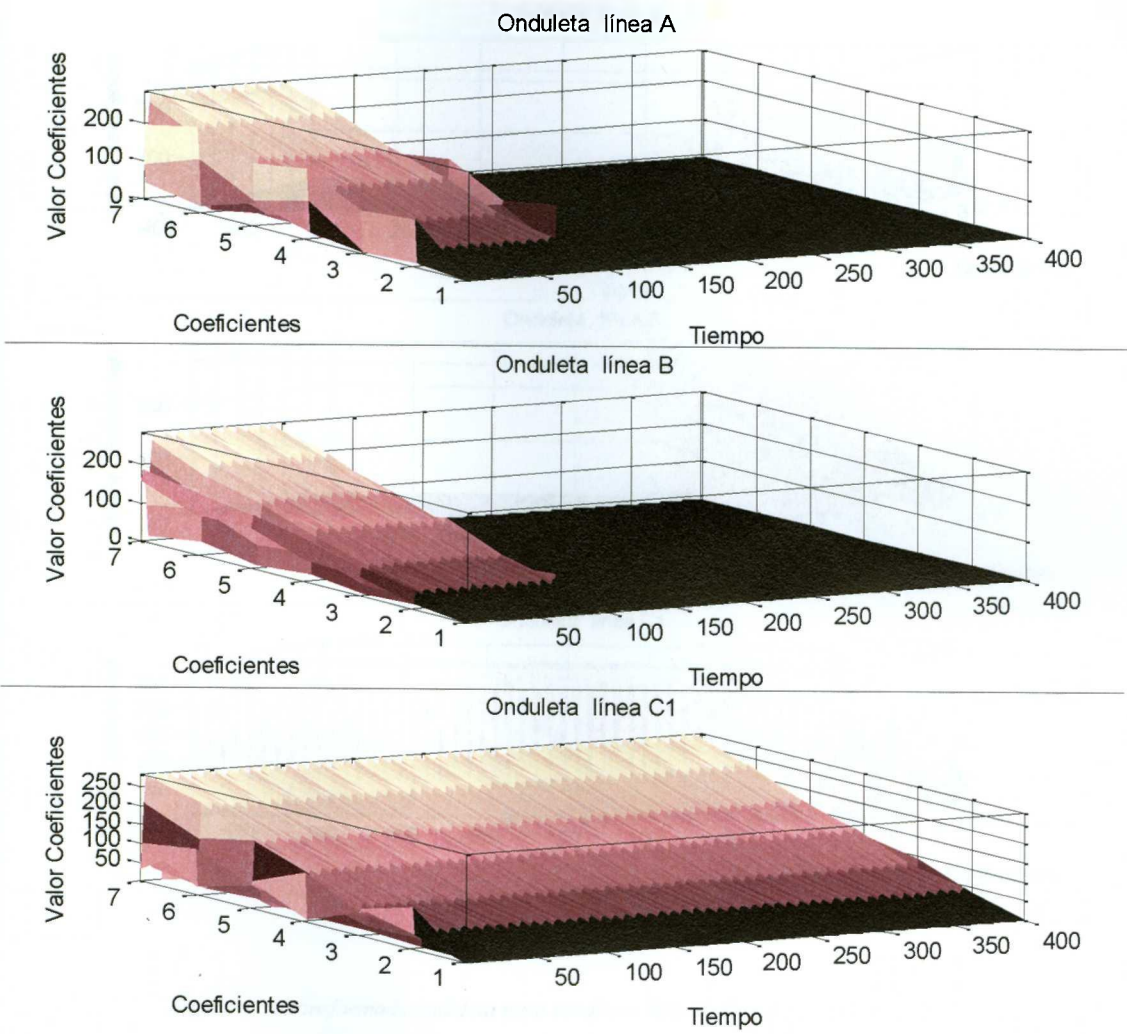


Figura 56. Transformada onduleta para señal con falla de fase A y B a tierra Nodo 3

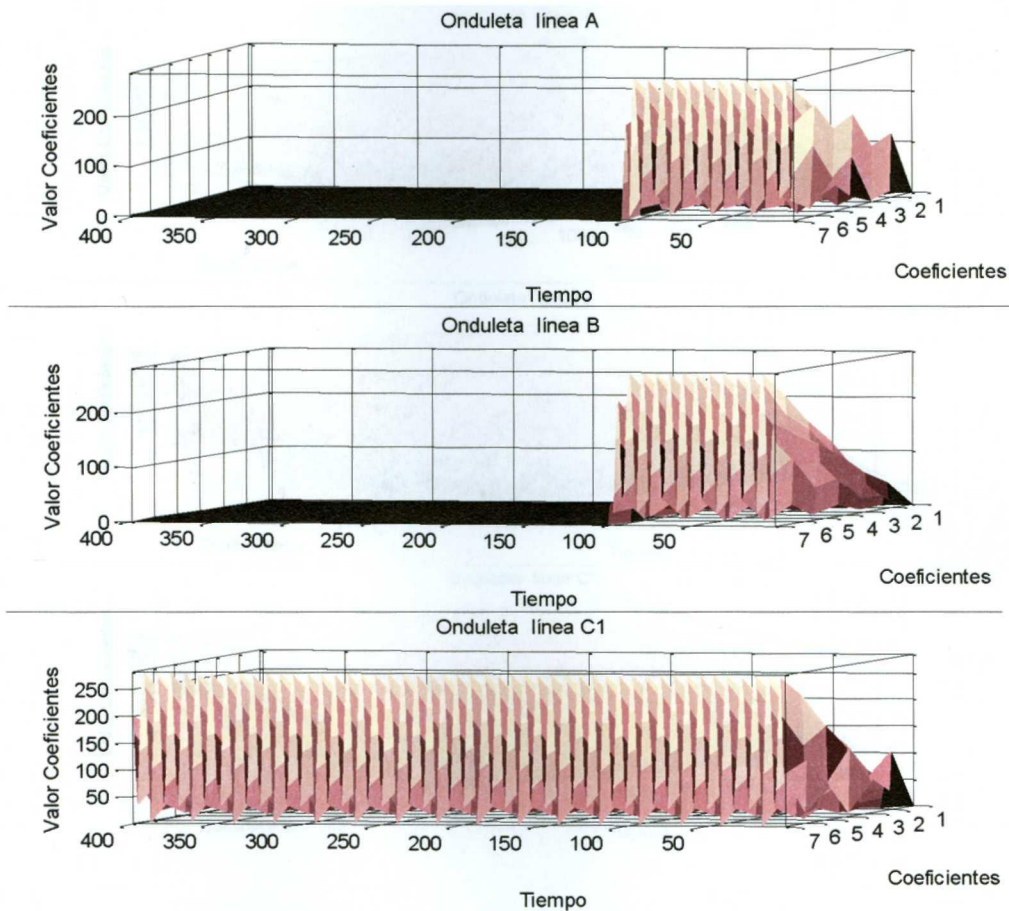


Figura 57. Transformada onduleta para señal con falla de fase A y B a tierra nodo 3

La gráfica dada por la transformada tiene 3 ejes: El eje de tiempo; la escala está dada en milisegundos, se analiza en el lapso de 0 a 400 milisegundos; un eje de coeficientes, El coeficiente es el resultado numérico que resulta al aplicar la transformada a un determinado valor de frecuencia. Para el caso de la figura, se calcularon 7 coeficientes en cada medición, que están marcados del 1 al 7 en la figura. Finalmente ,un eje que indica los valores de los diferentes coeficientes calculados.

La Figura 56 muestra 3 gráficas, una para cada una de las líneas del nodo. La Figura 57 es la misma Figura 56, pero vista por detrás, con el fin de facilitar la comprensión. La Figura 58 corresponde al caso en que el nodo 3 no presente ninguna falla. La Figura 59 corresponde al caso en que el nodo 3 presente falla de línea a línea, específicamente fallas entre las líneas A y B.

Puede observarse en la Figura 56 , que para las líneas A y B, en el lapso de 100 a 400 ms, que es el instante donde se hace el análisis, cuando aparece la falla a tierra, los coeficientes de la transformada tienen un valor de cero. Si se comparan estos resultados con los dados en el mismo instante y para el mismo nodo, pero sin presencia de fallas, Figura 58, los valores son bastante diferentes.

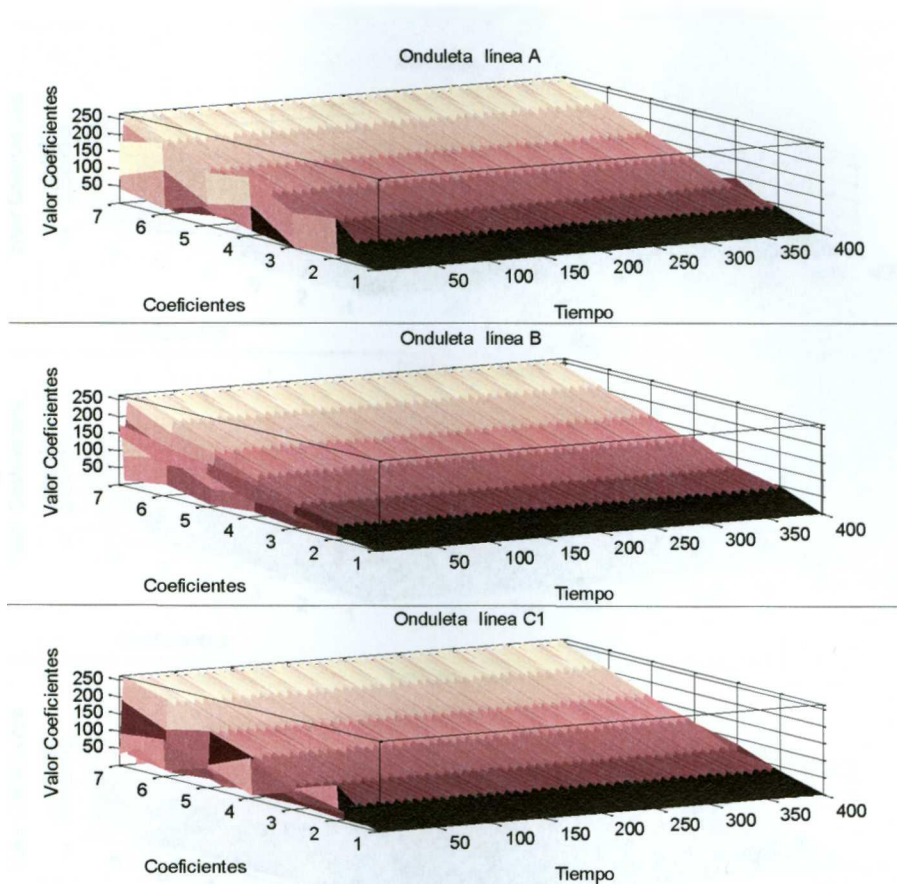


Figura 58. Transformada onduleta para señal sin fallas nodo 3

Ahora, si se hace el análisis para el caso del nodo 3, pero tomando una falla línea a línea, específicamente entre las líneas A y B, como se muestra en la en la Figura 59, se puede observar la diferencia en los valores de los coeficientes. La Tabla 4 resume los valores de los coeficientes encontrados durante todo el proceso de análisis.

	Nodo 3 sin falla	Nodo 3. Falla: Líneas A y B a tierra	Nodo 3 Falla entre líneas A y B
Fase A	264.28	0	172.69
Fase B	263.87	0	141.81
Fase C	263.85	283.76	283.76

Tabla 4. Diferentes valores de los coeficientes en las pruebas realizadas para diferentes tipos de falla en el nodo 3

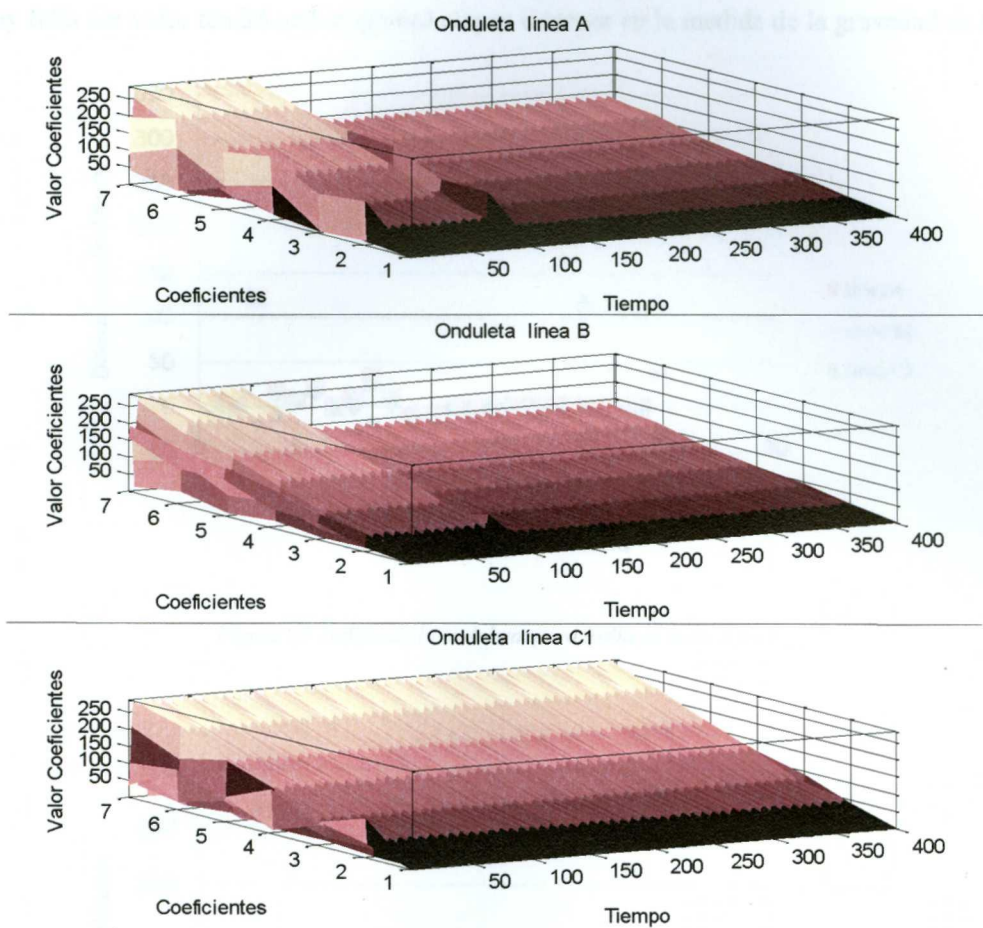


Figura 59. Transformada onduleta para señal con falla de línea a línea

Nótese que cuando el nodo no tiene fallas, los coeficientes dados por la transformada Onduleta tienen aproximadamente el mismo valor para las 3 líneas.

Posterior a esta comprobación, se analizaron más en detalle los voltajes en los nodos. Se encontró un inconveniente con los nodos cercanos a los nodos que presentan fallas: Cuando hay una falla en un nodo, los valores de voltaje de los nodos cercanos resultan afectados, debido al efecto cascada descrito en el capítulo II. Este hecho crea incertidumbre, porque da la impresión que el nodo cercano también tiene falla, lo que realmente no es cierto. Esto se puede observar en las figuras 60, 61 y 62. En estas figuras el eje horizontal define los nodos, el eje vertical se denomina “Diferencia de Altura”. Esta diferencia corresponde a:

$$\text{Diferencia de altura} = V \text{ del nodo sin falla} - V \text{ del mismo nodo con falla} \quad (46)$$

donde $V = \text{Voltaje}$

De acuerdo con esta definición, un punto que no tenga falla, la diferencia de altura debe ser 0. Si hay falla ese valor tendrá una magnitud mayor o menor en la medida de la gravedad de la falla.




Figura 60. Salida de la onduleta para Falla en nodo 3 y 19




Figura 61. Salida de la onduleta para Falla en nodo 3

Se analiza ahora el caso de la Figura 61, que corresponde a las lecturas arrojadas para una falla en el nodo 3. Las líneas A y B se pusieron a Tierra. La figura muestra que al momento de la falla la diferencia de altura llega hasta el valor 265 para las 2 líneas, mostrando la gravedad de la falla. Además de eso, algunos nodos vecinos se ven afectados como el 24, que muestra una diferencia de altura de 75. En primera instancia se diría que este nodo también tiene falla, pero de hecho sabemos que no es así. Es por el efecto cascada que el nodo 24 resulta afectado. La Figura 3, (diagrama de la red REC), confirma que efectivamente el nodo 24 es un nodo vecino del nodo 3.




Figura 62. Salida de la onduleta para Falla en nodos 2, 3, 7 y 24

Observando las Figura 60, Figura 61 y Figura 62 se puede concluir que además de las fallas reales, muchos nodos cercanos a los nodos con falla, resultan afectados, por efecto cascada. Esto indica que no es posible identificar con certeza cuales fallas son reales y cuándo los nodos presentan variaciones como consecuencia de nodos aledaños.

De acuerdo con E. Huang et al, [27], para poder usar la transformada onduleta en sistemas no lineales, debe hacerse un manejo de los datos del sistema; éste no lo hace en forma natural. Además la transformada onduleta no es la mejor manera de hacer un análisis de datos no-estacionarios.

Por el inconveniente anterior se decidió tomar otra ruta para la detección de fallas. Esta nueva ruta consistió en la utilización de una nueva transformada, la Transformada de Hilbert, y el análisis de sus resultados con respecto a la fase de la señal en estudio. En el apéndice B Se encuentra el código utilizado para la aplicación de la transformada onduleta en Matlab .

6. CAPITULO 6

PRUEBAS Y RESULTADOS

Las pruebas para la medición de la efectividad de los algoritmos Hilbert – Fuzzy c-Means y Hilbert – Varianza se efectuaron en 4 partes:

La primera parte consistió en evaluar la efectividad del algoritmo para la detección de la clase de falla, tipo de Falla, nodo en que se presenta la falla y tiempo estimado en que se presenta la falla..

La segunda parte consistió en hacer una verificación, por nodo y por el número de fallas presentes en un escenario, de la veracidad de la información arrojada por el algoritmo en cuanto al tipo de falla que se presenta en cada escenario analizado.

En la tercera parte se hizo una revisión de “*tiempo de estimación de inicio de la falla*” arrojado por el algoritmo de Hilbert – Fuzzy c-Means.

La cuarta parte consistió en adicionar ruido a la señal de voltaje para comprobar la efectividad del algoritmo Hilbert Fuzzy c-means.

Con el fin de tener criterios para hacer una comparación entre el algoritmo de Hilbert – Fuzzy c-Means y el Algoritmo Hilbert – Varianza, las dos primeras partes se realizaron para ambos algoritmos.

6.1. Clase, Tipo, Nodo y Tiempo (Primera Parte)

En esta primera prueba se busca, ante la presencia de una falla, evaluar la efectividad de los algoritmos en la detección de los parámetros: Clase de falla, Tipo de falla, Nodo y Tiempo de inicio d la falla. Entendiéndose por:

- Clase de falla: Si se trata de una falla a tierra o de una falla línea a línea.
- Tipo de falla: Cuál línea o líneas están presentando la falla.
- Nodo: Cuál es el nodo en que se está presentando la falla.
- Tiempo: El momento estimado en que inicia la falla. Es importante recordar que todas fallas de la Tabla se presentan en el tiempo de 4,000ms.

Cada una de las respuestas arrojadas por los algoritmos respecto a los anteriores parámetros tendrá una calificación con un valor de 1 si es un acierto, y un valor de 0 si se trata de un error en la detección. Para decidir si es acierto o error, los valores dados se comparan con la información proporcionada al momento de diseñar la simulación.(Ver Tabla y Tabla .)

Cuantitativamente la efectividad se calculará por la ecuación (40):

$$\text{Porcentaje de efectividad} = \frac{\text{No.de casos sin error}}{\text{No.de casos analizados}} \times 100 \quad (47)$$

Se analizaron por separado los escenarios con 1 sola falla, con 2, 3 ,4 y 5 tipos de falla que se presentan simultáneamente como se ve en las tablas a continuación:

1 FALLA			ALGORITMO HILBERT-FUZZY C-MEANS			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE LA FALLA
1	Datos0fallas	cero fallas	1	1	1	
2	Datos1F4	4 B-C-GND	1	1	1	3984
3	Datos1F7	7 B-C	1	1	1	3953
4	Datos1F7v2	7 A-B	1	1	1	3951
5	Datos1F8	8 C-GND	1	1	1	3987
6	Datos1F9	9 C-GND	1	1	1	3987
7	Datos1F15	15 A-B-GND	1	1	1	3979
8	Datos1F19	19 A-C	1	1	1	3954
		TOTAL ACIERTOS	8	8	8	
Porcentaje de eficiencia			100	100	100	3,970.71

Tabla 5. Eficiencia para Escenarios con una sola falla utilizando el algoritmo Hilbert – Fuzzy c-Means

1 FALLA			ALGORITMO HILBERT-ANALISIS DE VARIANZA			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE FALLA
1	Datos0fallas	cero fallas	1	1	1	N/A
2	Datos1F4	4 B-C-GND	1	1	1	N/A
3	Datos1F7	7 B-C	1	1	1	N/A
4	Datos1F7v2	7 A-B	1	1	1	N/A
5	Datos1F8	8 C-GND	1	1	1	N/A
6	Datos1F9	9 C-GND	1	1	1	N/A
7	Datos1F15	15 A-B-GND	1	1	1	N/A
8	Datos1F19	19 A-C	1	1	1	N/A
		TOTAL ACIERTOS	8	8	8	
Porcentaje de eficiencia			100	100	100	

Tabla 6. Eficiencia para Escenarios con una sola falla utilizando el algoritmo Hilbert – Varianza

En la Tabla 5 y Tabla 6 se observa que para los escenarios con una sola falla, los dos algoritmos presentan una eficiencia del 100 % en clase de falla, Tipo de Falla y Nodo.

*Solo el algoritmo de Hilbert – Fuzzy c-Means proporciona el tiempo estimado de inicio de las fallas, con un promedio de 3,974.2ms. Última columna Tabla 5.

2 FALLAS			ALGORITMO HILBERT-FUZZY C-MEANS			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE LA FALLA
1	Datos2F4-5	4 B-C-GND 5 A-B-GND	1	1	1	3983
2	Datos2F5-2	5 A-B 2 A-C	1	1	1	3953
3	Datos2F10-2	10 A-B 2 B-C-GND	1	1	E1	3984
4	Datos2F11-14	11 A-C 14 B-C	1	1	1	3956
5	Datos2F17-6	17 A-B-GND 6 A-B	1	1	1	3979
6	Datos2F19-7	19 A-C-GND 7 A-C	1	1	1	3979
7	Datos2F21-8	21 A-C-GND 8 B-C	1	1	1	3979
8	Datos2F21-20	21 A-C-GND 20 C-GND	1	1	1	3986
9	Datos2F23-7	23 A-C-GND 7 A-B	1	1	1	3986
		TOTAL ACIERTOS	9	9	8	
Porcentaje de eficiencia			100	100	88,88	3,976.11

Tabla 7. Eficiencia para Escenarios con dos fallas utilizando el algoritmo Hibert – Fuzzy c-Means

2 FALLAS			ALGORITMO HILBERT-ANALISIS DE VARIANZA			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE FALLA
1	Datos2F4-5	4 B-C-GND 5 A-B-GND	1	1	1	N/A
2	Datos2F5-2	5 A-B 2 A-C	1	1	1	N/A
3	Datos2F10-2	10 A-B 2 B-C-GND	1	1	1	N/A
4	Datos2F11-14	11 A-C 14 B-C	1	1	1	N/A
5	Datos2F17-6	17 A-B-GND 6 A-B	1	1	1	N/A
6	Datos2F19-7	19 A-C-GND 7 A-C	1	1	1	N/A
7	Datos2F21-8	21 A-C-GND 8 B-C	1	1	1	N/A
8	Datos2F21-20	21 A-C-GND 20 C-GND	1	1	1	N/A
9	Datos2F23-7	23 A-C-GND 7 A-B	1	1	1	N/A
		TOTAL ACIERTOS	9	9	9	
Porcentaje de eficiencia			100	100	100	

Tabla 8. Eficiencia para Escenarios con dos fallas utilizando el algoritmo Hilbert – Varianza

En la Tabla 7 y Tabla 8 se observa que para los escenarios con dos fallas simultáneas, los dos algoritmos presentan una eficiencia del 100% en Clase de falla y Tipo de falla pero en Nodo, el ítem 3 de la Tabla 7, que corresponde al escenario Datos2F10-2, tiene una calificación E1. Este es un error por falso positivo, es decir que muestra una falla que realmente no existió y que no fue simulada. Esta falla es el resultado de una perturbación en el nodo con falso positivo, debido al efecto cascada que produce alguno de sus nodos cercanos y que si se encuentra con falla. En este caso es el Nodo 6 presenta un falso positivo debido a la falla a tierra que presenta el nodo 2 que es un nodo cercano.

En cuanto al parámetro de tiempo, proporciona un estimado promedio de 3976,1 ms. para el algoritmo Hilbert – Fuzzy c-Means. En cuanto al algoritmo Hilbert – Varianza para los parámetros Clase de falla, Tipo de falla y Nodo tienen una efectividad del 100% pero no proporciona un estimado del tiempo en que inician las fallas.

3 FALLAS			ALGORITMO HILBERT-FUZZY C-MEANS			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE FALLA
1	Datos3F2-20-5	2 B-C 20 A-GND 5 B-C	1	1	1	3990
2	Datos3F3-18-1	3 B-GND 18 B-C 1 A-B-C-GND	1	1	1	4001
3	Datos3F7-20-23	7 A-GND 20 B-C 23 C-GND	1	1	1	3986
4	Datos3F14-1-21	14 A-C-GND 1 A-B-GND 21 B-C-GND	1	1	1	3984
5	Datos3F15-11-16	15 A-B-C-GND 11 C-GND 16 A-B	1	1	1	3989
6	Datos3F24-11-13	24 A-B-GND 11 A-B 13 A-B	1	1	1	3978
7	Datos3F24-12-8	24 B-C 12 B-GND 8 B-C	1	1	1	3984
		TOTAL ACIERTOS	7	7	7	
Porcentaje de eficiencia			100	100	100	3,987.25

Tabla 9. Eficiencia para Escenarios con tres fallas utilizando el algoritmo Hilbert – Fuzzy c-Means

3 FALLAS			ALGORITMO HILBERT-ANALISIS DE VARIANZA			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE FALLA
1	Datos3F2-20-5	2 B-C 20 A-GND 5 B-C	1	1	1	N/A
2	Datos3F3-18-1	3 B-GND 18 B-C 1 A-B-C-GND	1	1	1	N/A
3	Datos3F7-20-23	7 A-GND 20 B-C 23 C-GND	1	1	1	N/A
4	Datos3F14-1-21	14 A-C-GND 1 A-B-GND 21 B-C-GND	1	1	1	N/A
5	Datos3F15-11-16	15 A-B-C-GND 11 C-GND 16 A-B	1	1	1	N/A
6	Datos3F24-11-13	24 A-B-GND 11 A-B 13 A-B	1	1	1	N/A
7	Datos3F24-12-8	24 B-C 12 B-GND 8 B-C	1	1	1	N/A
		TOTAL ACIERTOS	7	7	7	
Porcentaje de eficiencia			100	100	100	

Tabla 10. Eficiencia para Escenarios con tres fallas utilizando el algoritmo Hilbert – Varianza

En la Tabla 9 y la Tabla 10 se puede observar que para escenarios con 3 fallas simultáneas los dos algoritmos, Hilbert-Fuzzy c-Means y Hilbert – Varianza, presentan un 100% de efectividad en Clase de falla, Tipo de falla y Nodo. Solo el algoritmo Hilbert-Fuzzy c-Means proporciona un tiempo estimado de inicio de las fallas con un valor promedio de 3,987.25ms.

4 FALLAS			ALGORITMO HILBERT-FUZZY C-MEANS			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE LA FALLA
1	Datos4F2-3-7-24	2 A-B-C-GND 3 C-GND 7 A-C-GND 24 A-GND	1	1	1	3977
2	Datos4F4-2-19-18	4 C-GND 2 A-C 19 C-GND 18 A-B	1	1	1	3954
3	Datos4F4-9-23-13	4 B-GND 9 A-C 23 A-B 13 B-C ^6	1	1	1	3956
4	Datos4F6-17-2-12	6 C-GND 17 A-C 2 A-C 12 B-C	1	1	1	3954
5	Datos4F7-9-12-17	7 A-B-C-GND 9 A-B 12 C-GND 17 A-C-GND	1	1	1	3973
6	Datos4F14-9-3-5	14 A-B-C-GND 9 A-C-GND 3 A-GND 5 B-C-GND	1	1	1	3979
7	Datos4F15-14-6-5	15 A-B-GND 14 B-C-GND 6 B-C-GND 5 B-C-GND	1	1	1	3976
8	Datos4F16-11-9-8	16 B-C-GND 11 A-GND 9 B-GND 8 B-C-GND	1	1	1	3982
9	Datos4F23-14-15-16	23 A-B 14 C-GND 15 B-C 16 A-B-C-GND ^6	1	1	E1	3988
TOTAL ACIERTOS			9	9	8	
Porcentaje de eficiencia			100	100	88,88	3,972.4

Tabla 11. Eficiencia para Escenarios con cuatro fallas utilizando el algoritmo Hibert – Fuzzy c-Means

4 FALLAS			ALGORITMO HILBERT-ANALISIS DE VARIANZA			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE FALLA
1	Datos4F2-3-7-24	2 A-B-C-GND 3 C-GND 7 A-C-GND 24 A-GND	1	1	1	N/A
2	Datos4F4-2-19-18	4 C-GND 2 A-C 19 C-GND 18 A-B	1	1	1	N/A
3	Datos4F4-9-23-13	4 B-GND 9 A-C 23 A-B 13 B-C ^6	1	1	1	N/A
4	Datos4F6-17-2-12	6 C-GND 17 A-C 2 A-C 12 B-C	1	1	1	N/A
5	Datos4F7-9-12-17	7 A-B-C-GND 9 A-B 12 C-GND 17 A-C-GND	1	1	1	N/A
6	Datos4F14-9-3-5	14 A-B-C-GND 9 A-C-GND 3 A-GND 5 B-C-GND	1	1	1	N/A
7	Datos4F15-14-6-5	15 A-B-GND 14 B-C-GND 6 B-C-GND 5 B-C-GND	1	1	1	N/A
8	Datos4F16-11-9-8	16 B-C-GND 11 A-GND 9 B-GND 8 B-C-GND	1	1	1	N/A
9	Datos4F23-14-15-16	23 A-B 14 C-GND 15 B-C 16 A-B-C-GND ^6	1	1	E1	N/A
TOTAL ACIERTOS			9	9	8	
Porcentaje de eficiencia			100	100	88,88	

Tabla 12. Eficiencia para Escenarios con cuatro fallas utilizando el algoritmo Hibert – Varianza

En la Tabla 11 y la Tabla 12 se observan nueve escenarios con cuatro fallas simultáneas cada uno. Para los dos los algoritmos Hibert-Fuzzy c-Means y Hibert -Varianza presentan un 100% de efectividad en Clase de falla, Tipo de falla, para Nodo tienen una efectividad de 88.88% debido a que muestra un falso positivo en el nodo 20, del ítem 9. Esta falla adicional, es un resultante de una perturbación en el nodo con falso positivo debido al efecto cascada que produce alguno de sus nodos aledaños y que se encuentra en falla. Para este caso el Nodo 20 presenta un falso positivo debido a la falla que presenta el nodo 23. En cuanto al tiempo, el algoritmo Hilbert – Fuzzy c-Means proporciona un estimado de 3,972.4ms.

5 FALLAS			ALGORITMO HILBERT-FUZZY C-MEANS			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE LA FALLA
1	Datos5F2-11-12-8-21	2 A-C 11 C-GND 12 A-B 8 B-C 21 A-B-C-GND	1	1	1	3952
2	Datos5F2-23-14-19-20	2 A-B-GND 23 A-C 14 B-C-GND 19 A-B-GND 20 B-C-GND	1	1	1	3984
3	Datos5F3-6-15-20-9	3 A-B 6 A-C 15 A-GND 20 B-C 9 B-C ^12	1	1	E1	3990
4	Datos5F3-19-5-10-17	3 A-B 19 A-C-GND 5 A-B-C-GND 10 A-C 17 B-GND	1	1	1	3978
5	Datos5F7-18-6-20-2	7 A-GND 18 A-B-GND 6 B-C-GND 20 B-C 2 A-B	1	1	1	3976
6	Datos5F14-18-24-23-10	14 A-B-GND 18 A-B 24 B-GND 23 A-B-C-GND 10 B-C-GND	1	1	1	3977
7	Datos5F16-7-20-2-5	16 A-GND 7 A-B-C-GND 20 C-GND 2 A-C 5 C-GND	1	1	1	3975
8	Datos5F16-9-7-10-18	16 B-C-GND 9 B-C-GND 7 B-C 10 B-C 18 A-B	1	1	E1	3983
9	Datos5F24-8-18-4-21	24 A-B-C-GND 8 A-C-GND 18 A-B 4 B-C-GND 21 A-B-C-GND	1	1	1	3981
		TOTAL ACIERTOS	9	9	7	
Porcentaje de eficiencia			100	100	77,77	3,977.33

Tabla 13. Eficiencia para Escenarios con cinco fallas utilizando el algoritmo Hilbert – Fuzzy c-Means

5 FALLAS			ALGORITMO HILBERT-ANALISIS DE VARIANZA			
ITEM	ARCHIVO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE FALLA
1	Datos5F2-11-12-8-21	2 A-C 11 C-GND 12 A-B 8 B-C 21 A-B-C-GND	1	1	1	N/A
2	Datos5F2-23-14-19-20	2 A-B-GND 23 A-C 14 B-C-GND 19 A-B-GND 20 B-C-GND	1	1	1	N/A
3	Datos5F3-6-15-20-9	3 A-B 6 A-C 15 A-GND 20 B-C 9 B-C ^12	1	1	1	N/A
4	Datos5F3-19-5-10-17	3 A-B 19 A-C-GND 5 A-B-C-GND 10 A-C 17 B-GND	1	1	1	N/A
5	Datos5F7-18-6-20-2	7 A-GND 18 A-B-GND 6 B-C-GND 20 B-C 2 A-B	1	1	1	N/A
6	Datos5F14-18-24-23-10	14 A-B-GND 18 A-B 24 B-GND 23 A-B-C-GND 10 B-C-GND	1	1	1	N/A
7	Datos5F16-7-20-2-5	16 A-GND 7 A-B-C-GND 20 C-GND 2 A-C 5 C-GND	1	1	1	N/A
8	Datos5F16-9-7-10-18	16 B-C-GND 9 B-C-GND 7 B-C 10 B-C 18 A-B	1	1	E1	N/A
9	Datos5F24-8-18-4-21	24 A-B-C-GND 8 A-C-GND 18 A-B 4 B-C-GND 21 A-B-C-GND	1	1	1	N/A
		TOTAL ACIERTOS	9	9	8	
Porcentaje de eficiencia			100	100	88,88	

Tabla 14. Eficiencia para Escenarios con cinco fallas utilizando el algoritmo Hilbert – Varianza

Tabla 13 y Tabla 14 se observan nueve escenarios con 5 fallas simultáneas cada uno. Para los dos los algoritmos Hilbert-Fuzzy c-Means y Hilbert –Varianza, presentan un 100% de efectividad en Clase de falla, Tipo de falla, para Nodo tienen una efectividad de 88.88% para el algoritmo Hilbert – Varianza y 77.77% para el algoritmo Hilbert-Fuzzy c-Means debido a que muestra falsos positivo en los nodos 6 y 8, del ítem 8, la falla del ítem 8 no es posible diferenciarla ya que en amplitud de voltaje y frecuencia tienen la característica de una señal con falla. Se presenta también un falso positivo en el ítem 3 nodo 24, En cuanto al tiempo proporciona un estimado de 3977,33ms para el algoritmo Hilbert – Fuzzy c-Means.

Se hicieron 14 pruebas más con fallas simultáneas en tiempos diferentes al de los anteriores escenarios obteniendo los resultados que se muestran a continuación:

1 a 5 FALLAS			ALGORITMO HILBERT-FUZZY C-MEANS			
ITEM	ESCENARIO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE LA FALLA
1	Test1	21 A-B	1	1	1	951
2	Test2	12 B-C-GND	1	1	1	2985
3	Test3	18 A-C	1	1	1	3954
4	Test4	5 A-B-GND 1 B-C	1	1	1	492
5	Test5	3 B-C 9 A-B	1	1	1	1979
6	Test7	4 A-C-GND 8 C-GND 23 A-B GND	1	1	1	178
7	Test8	14 C-GND 17 A-C 13 B-C	1	1	1	3453
8	Test9	12 A-B-GND 13 B-C-GND 18 B-GND	1	1	1	2082
9	Test10	3 A-B 15 A-B 24 A-B 1 A-C 16 A-C	1	1	1	4180
10	Test11	5B-GND 7 A-B-GND 11 A-B-C-GND 13 A-B-GND	1	1	1	790
11	Test12	5 A-B-C-GND 22 A-B-GND 18 A-B 21 A-B	1	1	1	3176
12	Test13	6 B-GND 13 A-B-C-GND 15 B-C-GND 5A-B 11 A-C	1	1	E1	360
13	Test14	1 A-B-GND 17 A-C-GND 20 B-C GND 23 A-C 24 A-C	1	1	1	1192
14	Test15	4 C-GND 7 A-B-GND 8 A-C-GND 10 A-B GND 21 A-B	1	1	1	3281
TOTAL ACIERTOS			14	14	13	
Porcentaje de eficiencia			100	100	92,85	

Tabla 15. Eficiencia para Escenarios con diferente número de fallas utilizando el algoritmo Hilbert – Fuzzy c-Means

Otros Escenarios de Comprobación			ALGORITMO HILBERT-ANALISIS DE VARIANZA			
ITEM	ESCENARIO	DESCRIPCION	CLASE DE FALLA	TIPO DE FALLA	NODO(S)	T DE FALLA
1	Test1	21 A-B	1	1	1	N/A
2	Test2	12 B-C-GND	1	1	1	N/A
3	Test3	18 A-C	1	1	1	N/A
4	Test4	5 A-B-GND 1 B-C	1	1	1	N/A
5	Test5	3 B-C 9 A-B	1	1	1	N/A
6	Test7	4 A-C-GND 8 C-GND 23 A-B GND	1	1	1	N/A
7	Test8	14 C-GND 17 A-C 13 B-C	1	1	1	N/A
8	Test9	12 A-B-GND 13 B-C-GND 18 B-GND	1	1	1	N/A
9	Test10	3 A-B 15 A-B 24 A-B 1 A-C 16 A-C	1	1	1	N/A
10	Test11	5B-GND 7 A-B-GND 11 A-B-C-GND 13 A-B-GND	1	1	1	N/A
11	Test12	5 A-B-C-GND 22 A-B-GND 18 A-B 21 A-B	1	1	1	N/A
12	Test13	6 B-GND 13 A-B-C-GND 15 B-C-GND 5A-B 11 A-C	1	1	1	N/A
13	Test14	1 A-B-GND 17 A-C-GND 20 B-C GND 23 A-C 24 A-C	1	1	1	N/A
14	Test15	4 C-GND 7 A-B-GND 8 A-C-GND 10 A-B GND 21 A-B	1	1	1	N/A
TOTAL ACIERTOS			14	14	14	
Porcentaje de eficiencia			100	100	100	

Tabla 16. Eficiencia para Escenarios con diferente número de fallas utilizando el algoritmo Hilbert – Varianza

La Tabla 15 y Tabla 16 muestran escenarios con diferente cantidad de fallas y con tiempos de inicio de fallas diferentes. La eficiencia que tienen los algoritmos Hilbert – Fuzzy c-Means y Hilbert – Varianza en cuanto a Clase de falla y Tipo de falla es del 100%, para el parámetro Nodo, el algoritmo Hilbert – Fuzzy c-Means tiene una eficiencia del 92.85% ya que en el ítem 12 presenta una falla de falso positivo para el nodo 24 que se ve afectado por falla en el nodo 15.

Para los escenarios anteriores los ítem 3 y 9 de los escenarios para 4 fallas (ver Tabla 12) y para el ítem 3 de los escenarios con 5 fallas (ver tabla Tabla 13) se debe ajustar manualmente el radio detección de fallas línea a línea en el algoritmo fuzzy c-meas, ya que el modelo encontrado de manera empírica no se ajusta a la variación de los radios de los diferentes tipos de falla.

Se considerará el escenario Datos4F4-9-23-13 para ejemplificar de manera gráfica el caso de cambio de radio para óptima detección. En la Figura 63 se muestra la detección de fallas línea a línea con un radio ρ^{18} y en la Figura 64 se modificó este radio al ρ^6 .

Agrupación de la Derivada de la Fase sin Transitorios

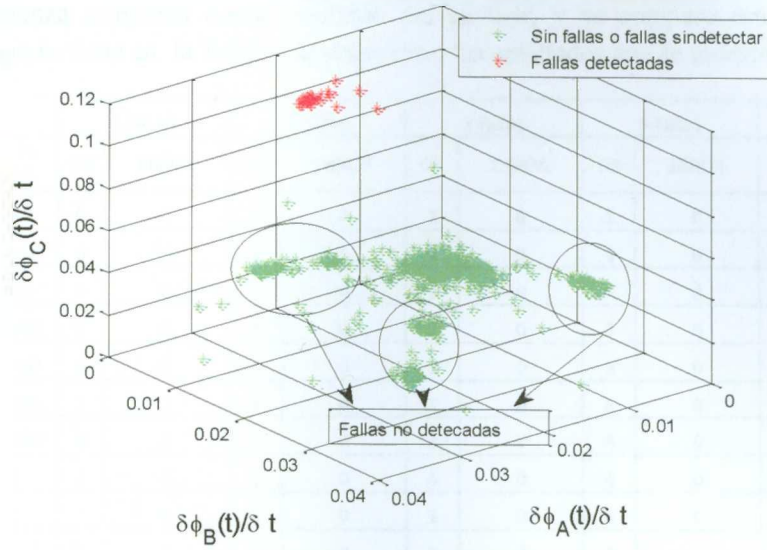


Figura 63. Escenario Datos4F4-9-23-13 con radio ρ^{18} con error en detección de fallas línea a línea

Agrupación de la Derivada de la Fase sin Transitorios




Figura 64. Escenario Datos4F4-9-23-13 con radio ρ^6 con error en detección de fallas línea a línea

6.2. Comprobación de tipos de fallas (Segunda Parte)

Se realizó una comprobación para el tipo de falla que los algoritmos Hilbert- Fuzzy c-Means y Hilbert – Varianza arrojaban como resultado del análisis, y se comparó este resultado con la información que se tiene en la Tabla . Se obtuvieron los resultados que se muestran en la Tabla 17.

ITEM	TIPO DE FALLA	1 FALLA		2 Fallas		3 Fallas		4 Fallas		5 Fallas	
		OK	ERROR	OK	ERROR	OK	ERROR	OK	ERROR	OK	ERROR
1	A-GND	0	0	0	0	2	0	3	0	3	0
2	B-GND	0	0	1	0	2	0	3	0	2	0
3	C-GND	3	0	1	0	2	0	7	0	4	0
4	AB-GND	2	0	2	0	2	0	3	0	4	0
5	AC-GND	0	0	4	0	1	0	3	0	2	0
6	BC-GND	1	0	2	0	1	0	6	0	7	0
7	ABC-GND	0	0	0	0	3	0	4	0	8	0
8	AB	1	0	5	0	4	0	4	0	7	0
9	AC	1	0	3	0	1	0	4	0	6	0
10	BC	1	0	2	0	6	0	3	0	7	0

Tabla 17. Comprobación del tipo de falla detectada

De acuerdo al análisis de los dos algoritmos, la detección del tipo de falla en ambos casos tiene un 100% de eficiencia, es decir que al detectar y diagnosticar la línea o líneas en las que se está presentando la falla, cualquiera de los dos algoritmos logra hacerlo con alto grado de certeza.

La red REC que está siendo aplicada en el presente proyecto, se utilizó para el desarrollo de un algoritmo de detección de fallas basado en Redes Bayesianas Híbridas (RBH) [28]. Para efectos de medir la efectividad del algoritmo Hilbert – Fuzzy c-Means y el algoritmo Hilbert – Varianza, se presentan a continuación los resultados de este modelo anterior RBH y se compara con los resultados obtenidos para los algoritmos basados en Hilbert. Se evalúan en las mismas condiciones tanto para fallas simples como simultáneas (de 1 a 5 fallas). Las fallas presentadas fueron seleccionadas aleatoriamente y pueden ser del tipo línea – línea, una-dos y tres fases a tierra. Los datos continuos (voltajes) se generaron con el software *Microtran* y los estados discretos de los interruptores de protección, se tomaron del resultado de una simulación Montecarlo, [28] y corresponden a los escenarios mostrados en la Tabla .

En la Tabla 18 se muestran los resultados obtenidos para el modelo RBH. Se utilizaron 25 escenarios que presentaban fallas simples y simultáneas (de 1 a 5 fallas). La última columna de esta tabla muestra el porcentaje de eficiencia para la identificación del tipo de falla, el cual varía entre 66.67% y 100% dependiendo del tipo de falla. La Tabla 19 y la Tabla 20 muestran los resultados de la eficiencia obtenida con el algoritmo Hilbert –Fuzzy c-Means para la identificación de tipo de falla. Se utilizaron para esta comprobación, 41 escenarios representados en la Tabla y 14 escenarios representados en la Tabla que presentan fallas simples y simultáneas (de 1 a 5 fallas) Los resultados de eficiencia para esta comprobación se encuentran en el 100% para la identificación de cualquier tipo de falla. La Tabla 19 y la Tabla 20 muestran los porcentajes de eficiencia para el

algoritmo Hilbert-Varianza los cuales son de 100% para la identificación en cualquier tipo de falla, para estas dos últimas tablas se utilizaron los mismos escenarios que para la prueba del algoritmo Hilbert- Fuzzy c-Means . Ahora, si se comparan los resultados obtenidos anteriormente para cada uno de los algoritmos; se encuentra que se tiene una mejora sustancial de la eficiencia para la identificaciones de tipo de falla cuando se usa el algoritmo Hilbert – Fuzzy c-Means, o el algoritmo Hilbert –Varianza. Mejorando en un porcentaje de 9.09% para el tipo de falla AB, 14.29% en el tipo de falla AC, 33.33% para los tipos de falla BC y B a tierra y 22.22% para el tipo de falla C a tierra.

ITEM	TIPO DE FALLA	1 Falla		2 Fallas		3 Fallas		4 Fallas		5 Fallas		Eficiencia %
		OK	ERROR	OK	ERROR	OK	ERROR	OK	ERROR	OK	ERROR	
1	AB	1	0	2	0	3	0	2	0	2	1	90.91
2	AC	1	0	1	0	0	0	0	1	4	0	85.71
3	BC	0	0	0	1	1	2	1	0	4	0	66.67
4	A-GND	0	0	0	0	1	0	2	0	2	0	100.00
5	B-GND	0	0	0	0	1	0	1	1	0	0	66.67
6	C-GND	2	0	0	0	1	0	0	2	4	0	77.78
7	AB-GND	1	0	2	0	2	0	1	0	0	0	100.00
8	AC-GND	0	0	2	0	1	0	2	0	1	0	100.00
9	BC-GND	0	0	2	0	1	0	5	0	1	0	100.00
10	ABC-GND	0	0	0	0	2	0	2	0	6	0	100.00

Tabla 18. Porcentaje de eficiencia por tipo de falla para el modelo RBH

ITEM	TIPO DE FALLA	1 Falla		2 Fallas		3 Fallas		4 Fallas		5 Fallas		Eficiencia %
		OK	ERROR	OK	ERROR	OK	ERROR	OK	ERROR	OK	ERROR	
1	AB	1	0	4	0	3	0	4	0	7	0	100.00
2	AC	1	0	3	0	0	0	4	0	5	0	100.00
3	BC	1	0	2	0	6	0	3	0	7	0	100.00
4	A-GND	0	0	0	0	2	0	3	0	3	0	100.00
5	B-GND	0	0	0	0	2	0	2	0	2	0	100.00
6	C-GND	2	0	1	0	2	0	6	0	3	0	100.00
7	AB-GND	1	0	2	0	2	0	2	0	4	0	100.00
8	AC-GND	0	0	4	0	1	0	3	0	2	0	100.00
9	BC-GND	1	0	2	0	1	0	6	0	7	0	100.00
10	ABC-GND	0	0	0	0	2	0	4	0	6	0	100.00

Tabla 19. Porcentaje de eficiencia por tipo de falla para el modelo Hilbert- Fuzzy c-Means escenarios de la Tabla

ITEM	TIPO DE FALLA	1 Falla		2 Fallas		3 Fallas		4 Fallas		5 Fallas		Eficiencia
		OK	ERROR	OK	ERROR	OK	ERROR	OK	ERROR	OK	ERROR	%
1	AB	1	0	1	0	0	0	2	0	5	0	100,00
2	AC	1	0	0	0	1	0	0	0	3	0	100,00
3	BC	0	0	2	0	1	0	0	0	2	0	100,00
4	A-GND	0	0	0	0	0	0	0	0	0	0	0,00
5	B-GND	0	0	0	0	1	0	1	0	1	0	100,00
6	C-GND	0	0	0	0	2	0	0	0	1	0	100,00
7	AB-GND	0	0	1	0	2	0	3	0	3	0	100,00
8	AC-GND	0	0	0	0	1	0	0	0	2	0	100,00
9	BC-GND	1	0	0	0	1	0	0	0	2	0	100,00
10	ABC-GND	0	0	0	0	0	0	2	0	1	0	100,00

Tabla 20. Porcentaje de eficiencia por tipo de falla para el modelo Hilbert- Varianza escenarios Tabla

La Tabla 21 muestra la eficiencia de 3 algoritmos, en función del número de fallas presentes en cada escenario, y del tipo de falla. Específicamente se presenta para el algoritmo RBH [28], el algoritmo Hilbert – Fuzzy c-Means, y el algoritmo Hilbert – Varianza. Los escenarios utilizados para estas pruebas fueron los mismos que se usaron para encontrar los porcentajes de eficiencia por tipo de falla.

Algoritmo RBH		Algoritmo Hilbert- Fuzzy c-Means		Algoritmo Hilbert- Varianza	
#Fallas	%Eficiencia	#Fallas	%Eficiencia	#Fallas	%Eficiencia
1	100.00	1	100.00	1	100.00
2	90.00	2	100.00	2	100.00
3	86.67	3	100.00	3	100.00
4	80.00	4	100.00	4	100.00
5	96.00	5	100.00	5	100.00

Tabla 21. Porcentaje de de eficiencia dependiendo del número de fallas

De los resultados anteriores se destaca la mejora que se obtiene utilizando los algoritmos Hilbert- Fuzzy c-Means y Hilbert – Varianza, con respecto a la utilización del algoritmo RBH. Con los 2 primeros algoritmos se alcanza un 100% de eficiencia en la calidad de la detección, mientras que con RBH la calidad o la eficiencia disminuyen cuando hay 2 o más fallas.

6.3. Comprobación de los Tiempos estimados (Tercera Parte)

El algoritmo Hilbert- Fuzzy c-Means tiene la propiedad de proporcionar un estimado del instante en que la falla inicia; este tiempo es tan solo un estimado ya que la transformada de Hilbert requiere de un cierto tiempo para llegar a su estado estable. Los resultados obtenidos de esta prueba fueron analizados de acuerdo al número de fallas, además se sabía de antemano que para los escenarios de la Tabla , la falla correspondiente se inicia en el instante 4,000ms. Los resultados de estas pruebas se presentan de manera resumida en la Tabla 23 Tabla 22. Posteriormente se hicieron pruebas con los escenarios de la Tabla que presentaban fallas simples y 2 o más fallas simultáneas en diferentes tiempos, estos resultados fueron verificados contra los escenarios originales como se ve en la Tabla 23.

ESCENARIO	Tiempo estimado de inicio de la falla (ms)				
	1 FALLA	2 FALLAS	3 FALLAS	4 FALLAS	5 FALLAS
1	0	3951	3990	3985	3952
2	3986	3983	4001	3977	3984
3	3984	3953	0	3954	3990
4	3987	3984	3986	3956	3978
5	3953	3956	0	3954	3976
6	3951	3979	3984	3973	3977
7	3987	3979	3989	3979	3975
8	3987	3979	3986	3976	3983
9	3979	3986	3978	3982	3991
10	3954	3986	3984	3988	3981
Promedio	3974,22	3973,6	3987,25	3972,4	3978,7

Tabla 22. Promedio de tiempos de estimado de inicio de falla

De acuerdo a la tabla anterior se tiene un rango de presencia estima de la falla en un rango de diferencia entre -12.75 ms a -27.6 ms con el valor original en que se presenta la falla cuyo valor es de $4,000\text{ ms}$ como se mencionó anteriormente.

Para escenarios que presentaban fallas simples o simultáneas en diferentes tiempos se obtuvieron los siguientes resultados:

Tiempo estimado de inicio de la falla				
ITEM	ESCENARIO	T DE LA FALLA (ms)	T REAL DE LA FALLA (ms)	DESVIACIÓN (ms)
1	Test1	951	1000	49
2	Test2	2985	3000	15
3	Test3	3954	4000	46
4	Test4	492	500	8
5	Test5	1979	2000	21
6	Test7	178	200	22
7	Test8	3453	3500	47
8	Test9	2082	2100	18
9	Test10	4179	4200	21
10	Test11	790	800	10
11	Test12	3176	3200	24
12	Test13	360	400	40
13	Test14	1192	1200	8
14	Test15	3281	3300	19

Tabla 23. Tiempo estimado de inicio de fallas para diferentes escenarios

Se verificaron cada uno de los resultados de la anterior tabla con el escenario original y se obtuvo un rango de desviación entre 8 y 50 ms con respecto al inicio original de la falla. A continuación se mostrarán algunos de los tiempos de la presencia original de la falla Vs el tiempo estimado por el algoritmo Hilbert- Fuzzy c-Means.




Figura 65. Tiempo de la falla original Vs Tiempo estimado de la falla en el escenario Test 4




Figura 66. Tiempo de la falla original Vs Tiempo estimado de la falla en el escenario Test 10

En la Figura 65 y Figura 66 muestran el origen de los datos que proporcionan el valor estimado del tiempo en que inicia la falla y cuyos resultados obtenidos se muestran en la Tabla 23; esta misma comparación fué realizada para cada uno de los escenarios que se tienen en la Tabla .

6.4. Pruebas con Ruido (Cuarta parte)

Para conocer el comportamiento del algoritmo Hilbert-Fuzzy- c-Means ante la señal de voltaje con ruido en la amplitud, se aplicó a los datos originales una perturbación con las siguientes características:

$$DR = DO + X\% DO \times (\pm RDM) \quad (48)$$

donde: $DR = \text{Dato con Ruido}$, $DO = \text{Dato Original}$, $RDM = \text{Número Aleatorio entre } \pm 1$
 $X = \text{Variación del porcentaje de ruido adicional}$.

El valor de X se varió entre el 10% y el 70% , estas pruebas se realizaron en los escenarios que se observan en la Tabla 24, cabe mencionar que estos escenarios fueron probados para los algoritmos Hilbert-Fuzzy c-Means y Hilbert-Varianza cuando originalmente se encontraban sin ruido. Durante estas pruebas, los escenarios tuvieron un 100% de efectividad en los parámetros medidos de Clase de falla, Tipo de Falla y Nodo (ver sección 6.1).

No. De Prueba	Escenario	10%	20%	30%	40%	50%	60%	70%
7	Datos1F8	1	1	1	1	1	E2	E2
18	Datos2F19-7	1	1	1	1	1	1	E2
30	Datos3F24-11-13	1	1	1	E3	E2 E1	E3	E2
34	Datos4F4-2-19-18	1	1	1	E1	E1	E1	E1 E3
47	Datos5F14-18-24-23-10	1	1	1	E1	E1	E1	E2
57	Test7	1	1	1	E1	E1	E2	E2
64	Test14	1	1	1	1	1	1	E2

Tabla 24. Resultado de las pruebas con adición de ruido en los datos para el algoritmo Hilbert Fuzzy c-Means

CONVENCIONES	
1	Fallas bien detectadas
E1	Línea mal detectada
E2	Falsos Positivos
E3	Falsos Negativos

Tabla 25. Convenciones usadas en la tabla de resultados de las pruebas con ruido

No. De Prueba	Escenario	10%	20%	30%	40%	50%	60%	70%
7	Datos1F8	1	1	E1 E2	E1 E2	E1 E2	E1 E2	E1 E2
18	Datos2F19-7	E1 E2	E2	E1 E2	E1 E2	E1 E2	E1 E2	E1 E2
30	Datos3F24-11-13	E2	E2	E1 E2	E1 E2	E1 E2	E1 E2	E1 E2
34	Datos4F4-2-19-18	E1 E2	E1 E2	E1 E2	E1 E2	E1 E2	E1 E2	E1 E2
47	Datos5F14-18-24-23-10	E1 E2	E2	E1 E2	E1 E2	E1 E2	E1 E2	E1 E2
57	Test7	1	1	E1 E2	E1 E2	E1 E2	E1 E2	E1 E2
64	Test14	E1 E2	E2	E1 E2	E1 E2	E1 E2	E1 E2	E1 E2

Tabla 26. Resultado de las pruebas con adición de ruido en los datos para el algoritmo Hilbert Varianza

De la Tabla 24 se puede observar que al agregar a la señal un nivel de ruido equivalente al 10%, 20% y el 30 % del valor original, el algoritmo Hilbert- Fuzzy-c-Means mantiene una excelente

respuesta, es decir mantiene su eficiencia como se mostró en las tablas anteriores. Al adicionarle ruido a la señal en un 40% o 50% en el 42.85% de los escenarios se mantiene una buena respuesta mientras que el 57.15% restante presenta algún error en su respuesta, el error más común es E1 que es error de línea mal detectada, esto quiere decir que si la falla real se trataba de una falla línea-

línea entre A y B el algoritmo lo detecta como una falla entre línea A y Línea C, o si se trataba de una falla de líneas A y B a tierra el algoritmo solo detecta B a tierra. Para el 60% de adición de ruido la efectividad del sistema baja aún más, ya que solo el 28.57% de los escenarios son exitosos y el 71.43%, presentando errores en el reconocimiento de falsos positivos, falsos negativos y líneas mal detectadas. Al aumentar más el ruido en la señal original a un 70% se encuentra que para ninguno de los escenarios hay un buen reconocimiento.

Tabla 26 muestra los resultados obtenidos del algoritmo Hilbert – Varianza, al ingresar datos con ruido. Para esta prueba se utilizaron los mismos escenarios de la prueba anterior, y con los mismos niveles de ruido aplicados al algoritmo Hilbert Fuzzy-c-Means. Los resultados para el Algoritmo Hilbert Varianza no son tan alentadores, ya que como se observa en los resultados, tiene buena respuesta solo para 2 escenarios con 10% y 20% de ruido, con lo que se tiene una eficiencia del algoritmo en presencia de ruido del 28.57%. Para los otros escenarios presenta dos tipo de errores, Falsos Positivos y líneas mal detectadas.

En la Figura 67, se observan los efectos del ruido sobre la señal original. Para ello se tomó la línea A del Nodo 24 en el escenario *Datos3F24-11-13*, durante el tiempo 3,970 a 3,995




Figura 67. Efectos del ruido en diferentes porcentajes sobre una señal

En el *Apéndice D* se encuentra gráficamente los efectos del ruido sobre el conjunto completo de los 24 nodos y sus tres líneas en un tiempo entre los 3,980 ms y los 4,080 ms.

7. CAPITULO 7

CONCLUSIONES Y TRABAJO FUTURO

Se ha presentado en esta tesis un algoritmo para de detección y diagnóstico de fallas, el cual se ha verificado en un modelo de red industrial trifásica compuesta por 24 nodos principales, 20 generadores con diferentes voltajes, 21 cargas estáticas, 15 cargas dinámicas y 68 interruptores. Su análisis fue basado en la simulación de la respuesta en voltajes de la red hecha a través del software *Microtran*.

7.1. Ventajas

En detección y diagnóstico de fallas hay 2 pasos claves para llegar a un buen resultado: el acondicionamiento de la información y la clasificación; del éxito de la primera, dependerán los resultados de la segunda.

De la primera etapa del análisis de extracción del parámetro, base del estudio para la detección y diagnóstico de falla, se puede concluir que, la amplitud de la señal de voltaje no puede arrojar resultados totalmente veraces, debido al efecto cascada que se presenta las redes eléctricas cuando hay fallas. El sistema reporta más nodos con falla de los que en realidad tienen falla.

La técnica de extraer el parámetro de ángulo de cubrimiento por medio de la transformada de Hilbert y luego realizar agrupamiento con el algoritmo de Fuzzy c-Means, proporciona resultados que muestran una efectividad superior comparados a los de trabajos realizados con otras técnicas en la misma área. De acuerdo a los resultados del parámetro tipo de falla en el trabajo con el algoritmo RBH (Redes Bayesianas Híbridas) la eficiencia para el tipo de falla de línea a línea A-B la eficiencia es del 90.91%, cuando se tiene una falla de línea línea A-C el algoritmo presenta una eficiencia del 85.71 %, cuando se habla de la falla AC el algoritmo RBH tiene una eficiencia del 66.67%, cuando se tiene una falla de la línea B a tierra la eficiencia es de 66.67% y cuando la falla es de la línea C a tierra la eficiencia es del 77.78% para el resto de los casos tiene una eficiencia del 100%, a pesar de contar con muy buenas respuestas, el algoritmo Hilbert – Fuzzy c-Means lo supera ya que tiene una efectividad del 100% para cualquiera de los casos de falla sin importar el número de fallas simultaneas que se presenten en la red. Esto muestra que el algoritmo Hilbert fuzzy c – Means tiene un principio sólido en el parámetro analizado para la detección de la falla.

Durante el desarrollo del estudio se exploró otro método para la clasificación de las fallas, conocido como Hilbert–Varianza, llamado así porque la parte correspondiente al acondicionamiento de la señal se basó en el mismo principio del algoritmo Hilbert – Fuzzy c-Means, y para la etapa de clasificación se utilizó un método que emplea la varianza. Comparando el algoritmo Hilbert – Fuzzy c-Means con el algoritmo Hilbert – Varianza en cuanto a los parámetros de clase de falla tipo de falla y nodo en falla, se encuentra que, el primer algoritmo se ve levemente reducido en su efectividad en cuanto al parámetro de nodos identificados con falla pues se tiene un resultado de 88.88% de efectividad cuando existen 4 fallas simultaneas en la red y 77.77% cuando se presentan 5 fallas simultaneas. En cuanto al algoritmo Hilbert –Varianza en el

caso de 4 fallas simultaneas, presenta una efectividad del 88.88% y para el caso de 5 fallas simultaneas su efectividad corresponde al 88.88% superando para el caso de 5 fallas simultaneas al algoritmo Hilbert- Fuzzy c-Means. Aun presentándose esta diferencia en efectividad, el algoritmo Hilbert –Fuzzy c-Means sigue manteniendo una muy buena respuesta en cuanto a la información del parámetro nodo con falla. Otro punto importante es la entrega de información con respecto al tiempo de inicio de falla, solo el algoritmo Hilbert – Fuzzy c-Means puede determinar un tiempo estimado de inicio de falla, este parámetro no es entregado por el algoritmo Hilbert – Varianza ni el algoritmo RBH [29] con el cual se hace la comparación del parámetro tipo de falla.

La información de inicio aproximado de falla podría ser utilizado en la industria para detectar una falla que sea repetitiva en el tiempo, o para otras aplicaciones.

El algoritmo Hilbert Fuzzy c-Means tiene una muy buena respuesta a señales con ruido en la amplitud, como pudo comprobarse. El sistema logra soportar un ruido hasta de +/- 30% de la variación de amplitud de la señal con respuesta sin errores. En la realidad, tal magnitud de variación no es un caso muy común, al menos para una línea de 120 volts. No se puede decir lo mismo para el algoritmo Hilbert-Varianza que, tiene una eficiencia muy pobre ante presencia de ruido; por lo cual cabe resaltar la superioridad en este aspecto del algoritmo del que es objeto el presente trabajo.

7.2. Limitaciones

Una de las principales desventajas, desde el punto de vista de aplicación en línea, es el tiempo de procesamiento de la información que tiene el algoritmo Hilbert – Fuzzy c-Means. El cual depende del tamaño de la información a analizar.

Otra de las limitaciones es el manejo del radio de localización de fallas de línea a línea, ya que el que se usa actualmente ha sido escogido de manera empírica, lo cual, en un momento dado, podría dar errores de falsos positivos o falsos negativos.

7.3. Trabajo futuro

Se sugieren como áreas potenciales de investigación:

1. De acuerdo con la topología de la red, identificar aquellos nodos que presentan fallas producto de un efecto cascada, haciendo resaltar esta condición en el resultado arrojado por el algoritmo.
2. Como se pudo apreciar, el algoritmo Hilbert Fuzzy c-Means proporciona un tiempo estimado de inicio de falla, el cual podría aproximarse más al instante exacto de inicio de la falla y ampliar este resultado para determinar la duración de ésta.

3. Para la clasificación a través de Fuzzy c-Means, encontrar la mejor manera de hacer un radio de clasificación adaptable para mejorar la eficiencia del algoritmo, de modo tal que no se requiera de una modificación forzada de los parámetros de programación.
4. Otro de los aspectos a mejorar corresponde al tiempo de ejecución del método a nivel de simulación. Una buena alternativa para la optimización de este trabajo, sería la búsqueda de procesos más eficientes que reduzcan el tiempo de detección de la falla.
5. Generar una interfaz de usuario para hacer la toma de datos directamente de la fuente generadora, y de esta manera crear un sistema en línea; primero a nivel experimental con un sistema de simulación, posteriormente con una red eléctrica real a pequeña escala y, posteriormente hacer una evaluación del algoritmo a una escala mayor, de modo tal que pueda ser implementado un proyecto a nivel industrial.

REFERENCIAS

- [1] *Transformada de Hilbert y Señales Pasobanda*, Sistemas Lineales. Curso 2004/05, <http://www.lpi.tel.uva.es/~santi/slweb/hilbert.pdf>
- [2] Vicenc Puig, J. Quebedo, T. Escobet , *Control Tolerante a Fallos (Parte I) Fundamentos de Diagnóstico de Fallos*, **Departament Enginyeria de Sistemes, Automàtica i Informàtica Industrial (ESAII)**- Campus de Terrasa Universitat Politècnica de Catalunya (UPC)
- [3] Vicenc Puig, J. Quebedo, T. Escobet, *Control Tolerante a Fallos (Parte II): Mecanismo de Tolerancia y sistema supervisor* **Departament Enginyeria de Sistemes, Automàtica i Informàtica Industrial (ESAII)**- Campus de Terrasa Universitat Politècnica de Catalunya (UPC)
- [4] J.A Dente P.J. Costa Branco and R.Vilela Mendes. *Using immunology principles for fault detection*. **IEEE Transactions on Industrial Electronics**, 50(2), Pages. :362-373, 2003.
- [5] Soo-Chan Pei, Jian-Jiun Ding, *Relation Between Fractional operations and Time-Frequency distribution and Their Application*, **IEEE transaction on signal processing**, Vol 49, No. 8, August 2001.
- [6] | Chen Chunling, Yang Yong, Xu Tongyu, Cao Yingli, Wang Xiaofeng, *Power Quality Disturbances Detection Based on Hilbert Phase Shifting*, School of Information and Electric Engineering Shenyang agricultural University, **IEEE Power and Energy Engineering Conference, 2009. APPEEC 2009. Asia-Pacific**, Pages 1-4
- [7] Luis Eduardo Garza Castañón. *Tesis hybrid system faults diagnosis with probabilistic logic reasoning framework*. **Tesis de doctorado ITESM Monterrey N.L, 2001**.
- [8] Zhenxing Liu, Xiaolong Zhang, Xianggen Yin, Zhe Zhang, *Rotor cage fault diagnosis in induction motors based on spectral analysis of current Hilbert modulus* Wuhan Univ. of Sci. & Technol., China, **Power Engineering Society General Meeting, 2004. IEEE** Pages 1500 - 1503 Vol.2
- [9] Abeysekera, R., Bolton, R., Westphal, L., Boashash, B., *Patterns in Hilbert transforms and Wigner-Ville distributions of electrocardiogram data* Queensland University of Technology, Brisbane, Australia, **Acoustics, Speech, and Signal Processing, IEEE International Conference on ICASSP '86**.Pages 1793 – 1796.
- [10] Ruqiang Yan and Robert X. Gao, *A Tour of the Tour of the Hilbert-Huang Transform: An Empirical Tool for Signal Analysis*, **Instrumentation & Measurement Magazine, IEEE 2007**, Page(s): 40 – 45
- [11] Ahmed O. Abdul Salam, *Hilbert Transform in Image Processing*, Lecturer, Saddam University, Engineering Faculty, Sharjah, United Arab Emirates, Industrial Electronics, 1999. **ISIE '99. Proceedings of the IEEE International Symposium on** , Page(s): 111 - 113 vol.1

- [12] İlhan Aydin Mehmet Karakose Erhan Akin. *Artificial immune inspires fault detection algorithm based on fuzzy clustering and genetic algorithm methods*. **IEEE International Conference on Computational Intelligence for Measurement System And Applications, 2008**. Page(s): 93 - 98
- [13] Ruz-Hernandez, J.A. ; Sanchez, E.N. ; Suarez, D.A., *Neural networks-based scheme for fault diagnosis in fossil electric power plants* , **Neural Networks, 2005. IJCNN '05. Proceedings. 2005 IEEE International Joint Conference on**. Page(s): 1740 - 1745 vol. 3, 2005
- [14] Aydin, I. ; Karakose, M. ; Akin, E. , *Artificial Immune Based Support Vector Machine Algorithm for Fault Diagnosis of Induction Motors*, **Electrical Machines and Power Electronics, 2007. ACEMP '07. International Aegean Conference on**, Page(s): 217 – 221, 02, Mayo 2008
- [15] Rosero, J. ; Romeral, L. ; Ortega, J.A. ; Urresty, J.C. , *Demagnetization fault detection by means of Hilbert Huang transform of the stator current decomposition in PMSM*, **Industrial Electronics, 2008. ISIE 2008. IEEE International Symposium on**, Pages 172 - 177 , 18 noviembre 2008.
- [16] Hui Li; Yuping Zhang, *Bearing Localized Fault Detection Based on Hilbert-Huang Transformation*, **Fuzzy Systems and Knowledge Discovery, 2007. FSKD 2007. Vol 4, Fourth International Conference on**, Pages 138 – 142, 2007.
- [17] Liling Sun, *Detection of rotor bar breaking fault in induction motors based on Hilbert modulus gyration radius of filtered stator current signal*, **IEEE Electrical Machines and Systems, 2008. ICEMS 2008. International Conference on**, pages 877 – 881, 17-20 Oct. 2008.
- [18] Hui Li ; Haiqi Zheng ; Liwei Tang , *Gear Fault Diagnosis Based on Order Tracking and Hilbert-Huang Transform*, **IEEE Fuzzy Systems and Knowledge Discovery, 2009. FSKD '09. Sixth International Conference on**, pages 468 – 472, 28 Diciembre 2009
- [19] Ebron S. ; Lubkeman D.L. ; White M., *A neural network approach to the detection of incipient faults on power distribution feeders*, **Power Delivery, IEEE Transactions on** . Page(s): 905 – 914, Abril 1990
- [20] Z. Mao; Q. Fei, *Vulnerability Analysis of Urban Infrastructures*, **Industrial and Information Systems, 2009. IIS '09. International Conference on**. Page(s): 395 - 398 , 26 junio 2009.
- [21] Y. Limei; J Hongzhang; Rong Panxiang, *Brittleness in electric transmission network*. **Transmission and Distribution Conference and Exhibition: Asia and Pacific, 2005 IEEE/PES**, Page(s): 1 – 4, 05 diciembre 2005.
- [22] J. Pan; Z. Wang; D. Lubkeman; *Condition Based Failure rate modeling for electric network components*. **Power Systems Conference and Exposition, 2009. PSCE '09. IEEE/PES**, Page(s): 1 – 6, 24 abril 2009.
- [23] T. Apostol; E. Linés, 2006, *Análisis Matemático*, Ed. Reverté S.A Page 125
- [24] Grainger J. ; Stevenson W, 1994, *Power System Analysis*, McGraw-Hill, Inc, USA, Page(s): 380-381

- [25] Ravi Kurman I., *Signals and Systems*, PHI, Pages: 187-189
- [26] Pelleg D; Moore Andrew, *X means: extending K-means with Efficient Estimation of the Number of Clusters*, **School of Computer, Carnegie Mellon University, Pittsburg, PA15213 USA**
- [27] Norden E. Huang¹, Zheng Shen, Steven R. Long, Manli C. Wu, Hsing H. Shih, Qunan Zheng⁶, Nai-Chyuan Yen, Chi Chao Tung and Henry H. Liu, *The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis*, **The Royal Society**, Great Britain 1998, Pages 903 - 962
- [28] Deneb Robles Guillén, *Diagnóstico de Fallas en Redes Eléctricas Industriales mediante Redes Bayesianas Híbridadas*, Tesis Maestría, Monterrey, **Instituto Tecnológico y de Estudios Superiores de Monterrey**, 2010.
- [29] Frank R. Kschischang, *The Hilbert Transform*, Department of Electrical and Computer Engineering, University of Toronto, 2006
- [30] Yang Y, Wang X, Chan C, *Real-time Power Quality Monitoring and Analysis Platform of Rural Power Network Based on Virtual Instrument*, College of Information and Electrical Engineering, Shenyang Agricultural University Shenyang, Liaoning Province, China, **Electronic Measurement & Instruments, 2009. ICEMI '09. 9th International Conference on**, Page(s): 1-630 - 1-635, 2009.
- [31] Flores-Quintanilla J., Morales Mendes R., Ramirez Mendoza R., Garza Castañón L., Cantú-Ortiz F., *Towards a new Fault Diagnosis System for Electric Machines based on Dynamic Probabilistic Models* **American Control Conference, 2005. Proceedings of the 2005**, Page(s): 2775 - 2780 vol. 4
- [32] Liu Y, Zhao G., *Power System Fault Detection based on Stationary Wavelet Packet Transform and Hilbert Transform*, **Image and Signal Processing, 2008. CISP '08. Congress on Volume: 4**, Page(s): 307 - 310 2008
- [33] O .R. Seryasat, M. Aliyari shoorehdeli, F .Honarvar, A. Rahmani Haddadnia, *Multi-fault diagnosis of ball bearing using intrinsic mode functions, Hilbert marginal spectrum and multi - class support vector machine*, **Mechanical and Electronics Engineering (ICMEE), 2010 2nd International Conference on Volume: 2**, Page(s): V2-145 - V2-149, 2010.
- [34] Honh Ying-Yi, Wei D., *Compensation of Distorted Secondary Current Caused by Saturation and Remanence in a Current Transformer*, **Power Delivery, IEEE Transactions on**, pages 47 - 54 , 2009.
- [35] Leite D., Hell M., Diez P., Gariglio B., Nascimento L, Costa P., *Real-Time Model-Based Fault Detection and Diagnosis for Alternators and Induction Motors*, **Electric Machines & Drives Conference, 2007. IEMDC '07. IEEE International**, pages 202-207, 2007.
- [36] Weber R, *Data Mining en la empresa y en las finanzas utilizando tecnologías inteligentes*, **Revista Ingeniería de Sistemas Volumen 14 No.1, páginas 61-78, Junio 2000.**

APENDICES

Apéndice A: Parámetros de la Red IEEE

Valores de la Red				
Bus	Voltaje de Base	Carga		
Número	(Kvolts)	Mwatts	Mvar	%
1	138	108	22	3.8
2	138	97	20	3.4
3	138	180	37	6.3
4	138	74	15	2.6
5	138	71	14	2.5
6	138	136	28	4.8
7	138	125	25	4.4
8	138	171	35	6.0
9	138	175	36	6.1
10	138	195	40	6.8
13	230	265	54	9.3
14	230	194	39	6.8
15	230	317	64	11.1
16	230	100	20	3.5
18	230	333	68	11.7
19	230	181	37	6.4
20	230	128	26	4.5

Tabla A1. Cargas en la Red de potencia IEEE

Impedancias de Línea			
del bus (#)	al bus (#)	Resistencia (Ω)	Inductancia (mH)
1	2	1.38	19.50
1	3	28.88	296.36
1	5	11.53	118.57
2	4	17.35	177.79
2	6	26.29	269.42
3	9	16.29	166.98
3	24	1.22	117.73
4	9	14.18	145.51
5	10	12.06	123.9
6	10	7.35	84.89
7	8	8.41	86.16
8	9	33.59	231.67
8	10	22.59	231.67
9	11	1.22	117.73
9	12	1.22	117.73
10	11	1.22	117.73
10	12	1.22	117.73
11	13	3.23	66.79
11	14	2.86	58.65
12	13	3.23	66.79
12	23	6.56	135.55
13	23	5.87	121.38
14	16	2.65	54.58
15	16	1.16	24.28
15	21	3.33	68.76
15	24	3.54	72.83
16	17	1.75	36.34
16	19	1.59	32.41
17	18	0.95	20.21
17	22	7.14	147.76
18	21	1.75	36.34
19	20	2.70	55.57
20	23	1.48	30.31
21	22	4.60	95.14

Tabla A2. Impedancias de la red de potencia IEEE

Apéndice B: Tablas de escenarios simulados

# Prueba	# Falla (s)	Nombre Simulación	Fallas presentes en la simulación	Esenarios de Entrenamiento
1	1	Datos0fallas	cero fallas	
2		Datos1F3	3 A-B-GND	Usado para entrenamiento
3		Datos1F4	4 B-C-GND	
4		Datos1F6	6 C-GND	Usado para entrenamiento
5		Datos1F7	7 B-C	
6		Datos1F7v2	7 A-B	
7		Datos1F8	8 C-GND	
8		Datos1F9	9 C-GND	
9		Datos1F14	14 A-C	
10		Datos1F15	15 A-B-GND	
11		Datos1F19	19 A-C	
12	2	Datos2F3-19	3 A-B 19 B-GND	Usado para entrenamiento
13		Datos2F4-5	4 B-C-GND 5 A-B-GND	
14		Datos2F5-2	5 A-B 2 A-C	
15		Datos2F10-2	10 A-B 2 B-C-GND	
16		Datos2F11-14	11 A-C 14 B-C	
17		Datos2F17-6	17 A-B-GND 6 A-B	
18		Datos2F19-7	19 A-C-GND 7 A-C	
19		Datos2F21-8	21 A-C-GND 8 B-C	
20		Datos2F21-20	21 A-C-GND 20 C-GND	
21		Datos2F23-7	23 A-C-GND 7 A-B	
22	3	Datos3F2-20-5	2 B-C 20 A-GND 5 B-C	
23		Datos3F3-18-1	3 B-GND 18 B-C 1 A-B-C-GND	
24		Datos3F4-17-14	4 C-GND 17 A-C-GND 14 C-GND	
25		Datos3F7-20-23	7 A-GND 20 B-C 23 C-GND	
26		Datos3F8-13-12	8 C-GND 13 A-B-GND 12 A-C-GND	
27		Datos3F14-1-21	14 A-C-GND 1 A-B-GND 21 B-C-GND	
28		Datos3F15-11-16	15 A-B-C-GND 11 C-GND 16 A-B	
29		Datos3F19-8-22	19 A-C 8 A-B-C-GND 22 A-B	Usado para entrenamiento
30		Datos3F24-11-13	24 A-B-GND 11 A-B 13 A-B	
31		Datos3F24-12-8	24 B-C 12 B-GND 8 B-C	

Continúa en la siguiente página

# Prueba	# Falla (s)	Nombre Simulación	Fallas presentes en la simulación	Escenarios de Entrenamiento	
32	4	Datos4F1-9-6-17	1 C-GND 9 A-B-GND 6 B-GND 17 A-B-GND	Usado para entrenamiento	
33		Datos4F2-3-7-24	2 A-B-C-GND 3 C-GND 7 A-C-GND 24 A-GND		
34		Datos4F4-2-19-18	4 C-GND 2 A-C 19 C-GND 18 A-B		
35		Datos4F4-9-23-13	4 B-GND 9 A-C 23 A-B 13 B-C		
36		Datos4F6-17-2-12	6 C-GND 17 A-C 2 A-C 12 B-C		
37		Datos4F7-9-12-17	7 A-B-C-GND 9 A-B 12 C-GND 17 A-C-GND		
38		Datos4F14-9-3-5	14 A-B-C-GND 9 A-C-GND 3 A-GND 5 B-C-GND		
39		Datos4F15-14-6-5	15 A-B-GND 14 B-C-GND 6 B-C-GND 5 B-C-GND		
40		Datos4F16-11-9-8	16 B-C-GND 11 A-GND 9 B-GND 8 B-C-GND		
41		Datos4F23-14-15-16	23 A-B 14 C-GND 15 B-C 16 A-B-C-GND		
42		5	Datos5F2-11-12-8-21	2 A-C 11 C-GND 12 A-B 8 B-C 21 A-B-C-GND	
43			Datos5F2-23-14-19-20	2 A-B-GND 23 A-C 14 B-C-GND 19 A-B-GND 20 B-C-GND	
44	Datos5F3-6-15-20-9		3 A-B 6 A-C 15 A-GND 20 B-C 9 B-C		
45	Datos5F3-19-5-10-17		3 A-B 19 A-C-GND 5 A-B-C-GND 10 A-C 17 B-GND		
46	Datos5F7-18-6-20-2		7 A-GND 18 A-B-GND 6 B-C-GND 20 B-C 2 A-B		
47	Datos5F14-18-24-23-10		14 A-B-GND 18 A-B 24 B-GND 23 A-B-C-GND 10 B-C-GND		
48	Datos5F16-7-20-2-5		16 A-GND 7 A-B-C-GND 20 C-GND 2 A-C 5 C-GND		
49	Datos5F16-9-7-10-18		16 B-C-GND 9 B-C-GND 7 B-C 10 B-C 18 A-B		
50	Datos5F20-14-24-6-1		20 A-C 14 B-C 24 A-B-C-GND 6 C-GND 1 A-B-C-GND	Usado para entrenamiento	
51	Datos5F24-8-18-4-21		24 A-B-C-GND 8 A-C-GND 18 A-B 4 B-C-GND 21 A-B-C-GND		

Tabla B1. Escenarios de simulación de la red para entrenamiento y prueba del Algoritmo

Otros Escenarios de Comprobación			
# Prueba	# Falla(s)	Nombre Escenario	Fallas Presentes en la Simulación
52	1	Test1	21 A-B
53		Test2	12 B-C-GND
54		Test3	18 A-C
55	2	Test4	5 A-B-GND 1 B-C
56		Test5	3 B-C 9 A-B
57	3	Test7	4 A-C-GND 8 C-GND 23 A-B GND
58		Test8	14 C-GND 17 A-C 13 B-C
59		Test9	12 A-B-GND 13 B-C-GND 18 B-GND
60	4	Test10	3 A-B 15 A-B 24 A-B 1 A-C 16 A-C
61		Test11	5B-GND 7 A-B-GND 11 A-B-C-GND 13 A-B-GND
62		Test12	5 A-B-C-GND 22 A-B-GND 18 A-B 21 A-B
63		Test13	6 B-GND 13 A-B-C-GND 15 B-C-GND 5A-B 11 A-C
64	5	Test14	1 A-B-GND 17 A-C-GND 20 B-C GND 23 A-C 24 A-C
65		Test15	4 C-GND 7 A-B-GND 8 A-C-GND 10 A-B GND 21 A-B

Tabla B2. Otros escenarios de simulación de la red para prueba del Algoritmo

Apéndice C: Descripción de los archivos de datos de la REC

Descripción de los archivos de datos de la REC

Esta red fue simulada en diferentes escenarios, enumerados en la Tabla B1. El primero de ellos sin ningún tipo de fallas. Posteriormente se simularon los 10 tipos de fallas que pueden presentarse en la REC y que se mencionaron previamente, Tabla 1.

Cada una de las simulaciones proporciona un archivo tipo texto con 72 columnas, y 5,000 filas, las cuales contienen los datos del comportamiento en voltaje de la red. Cada columna representa una línea (fase) de un nodo y cada nodo está compuesto por tres líneas. En resumen se tienen 24 nodos con 3 líneas cada uno, denominadas A, B y C. Los nodos se encuentran organizados de manera ascendente (Nodo 1, Nodo 2, Nodo 3... Nodo 24). La Figura C1 muestra gráficamente la organización para 7 nodos y 39 filas. La columna de tiempo indica el instante en que se inicia la lectura de las 72 líneas.




Figura C1. Modelo de la tabla de datos suministrados

Si se escoge un escenario y se efectúa el proceso, el sistema elabora los siguientes pasos:

1. Hace un barrido de los 24 nodos, tomando, procesando y guardando información de cada línea; en total 72 líneas. Para esta labor gasta un tiempo de 1 ms.
2. El paso 1 lo repite hasta llegar al milisegundo 5,000. Al final habrá procesado y almacenado la información de 360,000 muestras.

120,000 muestras de las líneas A
 120,000 muestras de las líneas B
 120,000 muestras de las líneas C.

El nombre de algunos archivos está estructurado de manera a dar información sobre las fallas y los nodos, y otros. Por ejemplo el archivo “*Datos5F16-7-20-2-5.txt*” se indica que: existen 5 fallas en los nodos 16, 7, 20,2 y 5.

Si se hace una revisión del archivo “*FallasRedElectrica.txt*”, el cual contiene la información del tipo de falla presente en cada nodo, nos informa la falla correspondiente a cada nodo involucrado en ese archivo.

Un ejemplo para este caso puede ser la descripción es la siguiente:

16 A-GND 7 A-B-C-GND 20 C-GND 2 A-C 5 C-GND

Esta información significa que en el nodo 16 hay una falla de la línea “A” a GND; en el nodo 7 las líneas A, B y C se encuentran GND; en el nodo 20 la línea “C” a GND; en el nodo 2 existe una falla línea a línea entre A y C, y, en el nodo 5 hay una falla de la línea “C” a GND.

La Tabla muestra un listado de escenarios organizados para las diferentes pruebas.

Apéndice D: Código para el análisis de Onduleta

```

%1. capturar el archivo de datos
clc

Matriz=load('Datos1F3.txt', 'v1');
Matriz0f=load('Datos0fallas.txt', 'v1');
[f,e]=size(Matriz);
[g,d]=size(Matriz0f);
%Seleccionar columna para analizar resultado

j=72
for i=1:3:j

A=Matriz(4001:4301,i);
B=Matriz(4001:4301,i+1);
C=Matriz(4001:4301,i+2);
A1=Matriz0f(4001:4301,i);
B1=Matriz0f(4001:4301,i+1);
C1=Matriz0f(4001:4301,i+2);
end
M=[A B C]

Subplot (3,1,1); waveA=cwt(A,1:7,'haar','3Dplot'); title('Onduleta línea A')
Subplot (3,1,2); waveB=cwt(B,1:7,'haar','3Dplot'); title('Onduleta línea B')
Subplot (3,1,3); waveC=cwt(C,1:7,'haar','3Dplot'); title('Onduleta línea C')
waveA1=cwt(A1,1:7,'haar'); title('Onduleta línea A1')
waveB1=cwt(B1,1:7,'haar'); title('Onduleta línea B1')
waveC1=cwt(C1,1:7,'haar'); title('Onduleta línea C1')

```

Apéndice E: Código del algoritmo Hilbert –Fuzzy c Means


```

clear;
clc;
close all;

% Cargamos el archivo
A1 = load('Datos5F20-14-24-6-1.txt');
A2 = load('Test10.txt');
A = [A1,A2(:,2:end)];

% Obtenemos la señal analitica por Hilbert
TransHilbert = [hilbert(A(:,2:end))];
[nf,nc] = size(TransHilbert);

% Dos clases: falla a tierra / no falla a tierra
x = [];
y = [];
z = [];
for aux_n = 1:(24*2)
    x = [x;PhaseShiftDot2(:,(aux_n-1)*3+1)];
    y = [y;PhaseShiftDot2(:,(aux_n-1)*3+2)];
    z = [z;PhaseShiftDot2(:,(aux_n-1)*3+3)];
end
[center,U,obj_fcn] = fcm([(x),(y),(z)],2);

%representación tridimensional de los custers

title('Agrupamiento de la Derivada de la Fase de acuerdo al Radio '), grid ON; h = get(gca,
'title'); set(h, 'FontSize', 14);
xlabel('\delta\phi_A(t)/\delta t'); j = get(gca, 'xlabel'); set(j, 'FontSize', 14);
ylabel('\delta\phi_B(t)/\delta t'); k = get(gca, 'ylabel'); set(k, 'FontSize', 14);
zlabel('\delta\phi_C(t)/\delta t'); l = get(gca, 'zlabel'); set(l, 'FontSize', 14);

%representación temporal de las fallas a tierra
clase_cf = (sum(center(1,:).^2)<sum(center(2,:).^2))+1;
if clase_cf == 1
    I = index1;
else
    I = index2;
end
falla = zeros(1,(24*2)*(5000-No-1));
falla(I) = 1;
%se obtiene la matriz del anterior vector
fallas_m = [];
for n_nodo = 1:(24*2)
    fallas_m = [fallas_m ; falla((n_nodo-1)*(5000-No-1)+1:n_nodo*(5000-No-1))];
end
% representación usando image
fallas_m_g(:, :, 1) = not(fallas_m);
fallas_m_g(:, :, 2) = not(fallas_m);
fallas_m_g(:, :, 3) = not(fallas_m);

Ift = find(sum(fallas_m')>0); % indices de los nodos con fallas a tierra

Inf = find(sum(fallas_m')==0); % indices de los nodos sin fallas a tierra

[theta,phi,rho] = cart2sph(x,y,z);

Theta = []; Phi = []; Rho=[];
for aux_n = 1:(24*2)
    Theta = [Theta,theta((aux_n-1)*4949+1:(aux_n)*4949)];
    Phi = [Phi,phi((aux_n-1)*4949+1:(aux_n)*4949)];
    Rho = [Rho,rho((aux_n-1)*4949+1:(aux_n)*4949)];
end

Theta_f = Theta.*fallas_m';
naux = length(sum(Theta));
Maux = zeros(1,naux);
Theta_ff = min(sum(-abs(Theta_f))./sum(fallas_m'),Maux)

[X,Y,Z] = sph2cart(Theta_ff,Phi_ff,(Phi_ff~=0 | Theta_ff~=0));

```

```

falla_A = [-1, 0, 0];
falla_B = [0, -1, 0];
falla_C = [0, 0, -1];

falla_m_c(1,:) = (X-falla_A(1)).^2+(Y-falla_A(2)).^2+(Z-falla_A(3)).^2;
falla_m_c(2,:) = (X-falla_B(1)).^2+(Y-falla_B(2)).^2+(Z-falla_B(3)).^2;
falla_m_c(3,:) = (X-falla_C(1)).^2+(Y-falla_C(2)).^2+(Z-falla_C(3)).^2;

[M, Index] = min(falla_m_c);
Index_aux = zeros(1,length(M));
Index_aux(Ift) = ones(1,length(Ift));
Index = Index.*Index_aux;
Maux = (1:length(Index))';
Maux(:,2) = Index';
Maux;

Inft_f = [((Inft-1)*3+1)', ((Inft-1)*3+2)', ((Inft-1)*3+3)'] ;
Inft_f = Inft_f';
Inft_f = Inft_f(:);
N_nodos = length(Inft);
PhaseShiftDot_ll = PhaseShiftDot2(:,Inft_f); % Solamente se usan los nodos sin fallo a
tierra
PhaseShiftDot_ll(1:No,:) = zeros(No,N_nodos*3);
PhaseShiftDot_ll((end-No+1):end,:) = zeros(No,N_nodos*3);

x = [];
y = [];
z = [];
for aux_n = 1:N_nodos
    x = [x;PhaseShiftDot_ll(:,(aux_n-1)*3+1)];
    y = [y;PhaseShiftDot_ll(:,(aux_n-1)*3+2)];
    z = [z;PhaseShiftDot_ll(:,(aux_n-1)*3+3)];
end

x = abs(x); y = abs(y); z = abs(z);

%se obtiene la matriz del anterior vector
[theta,phi,rho] = cart2sph(x,y,z);

% [center,U,obj_fcn] = fcm((x.^2+y.^2+z.^2).^4,2,10);
[center,U,obj_fcn] = fcm(rho.^18,2,10);

%representación tridimensional de los clusters con falla a tierra
figure;
title('Agrupación de la Derivada de la Fase sin Transitorios '), grid ON; h = get(gca,
'title'); set(h, 'FontSize', 14);
xlabel('\delta\phi_A(t)/\delta t'); j = get(gca, 'xlabel'); set(j, 'FontSize', 14);
ylabel('\delta\phi_B(t)/\delta t'); k = get(gca, 'ylabel'); set(k, 'FontSize', 14);
zlabel('\delta\phi_C(t)/\delta t'); l = get(gca, 'zlabel'); set(l, 'FontSize', 14);
maxU = max(U);
index1 = find(U(1,:) == maxU);
index2 = find(U(2, :) == maxU);
line(x(index1),y(index1),z(index1),'linestyle','none',...
'marker','*', 'color','g');
line(x(index2),y(index2),z(index2),'linestyle','none',...
'marker','*', 'color','r');

view(240,30);

%Representación de los radios de los datos con falla línea-línea

%representación temporal de las fallas a tierra
clase_cf = (sum(center(1,:).^2)<sum(center(2,:).^2))+1;
if clase_cf == 1
    I = index1;
else

```

```

    I = index2;
end
falla = zeros(1,N_nodos*(5000-No-1));
falla(I) = 1;
%se obtiene la matriz del anterior vector

fallas_f = [];
for n_nodo = 1:N_nodos
    fallas_f = [fallas_f ; falla((n_nodo-1)*(5000-No-1)+1:n_nodo*(5000-No-1))];
end
% representación usando image
fallas_m_g = [];
fallas_m_g(:, :, 1) = not(fallas_f);
fallas_m_g(:, :, 2) = not(fallas_f);
fallas_m_g(:, :, 3) = not(fallas_f);
%figure; image(fallas_m_g); grid on;

%
% % volvemos a considerar todos los nodos
% fallas_m = [];
% for n_nodo = 1:N_nodos
%     fallas_m = [fallas_m ; falla((n_nodo-1)*(5000-No-1)+1:n_nodo*(5000-No-1))];
% end

fprintf('Fallas:\n')
for aux_prin = n/2+1:n
    switch principal(aux_prin,2)
        case 1,
            fprintf('\t%d: falla línea A-GND\n',aux_prin-n/2');
        case 2,
            fprintf('\t%d: falla línea B-GND\n',aux_prin-n/2');
        case 3,
            fprintf('\t%d: falla línea C-GND\n',aux_prin-n/2');
        case 4,
            fprintf('\t%d: falla líneas AB-GND\n',aux_prin-n/2');
        case 5,
            fprintf('\t%d: falla líneas AC-GND\n',aux_prin-n/2');
        case 6,
            fprintf('\t%d: falla líneas BC-GND\n',aux_prin-n/2');
        case 7,
            fprintf('\t%d: falla líneas ABC-GND\n',aux_prin-n/2');
    end
    switch principal(aux_prin,3)
        case 1,
            fprintf('\t%d: falla líneas A-B\n',aux_prin-n/2');
        case 2,
            fprintf('\t%d: falla líneas A-C\n',aux_prin-n/2');
        case 3,
            fprintf('\t%d: falla líneas B-C\n',aux_prin-n/2');
    end
end
end

```

Apéndice F: Efectos del ruido sobre una señal.

Escenario: Datos3F24-11-13

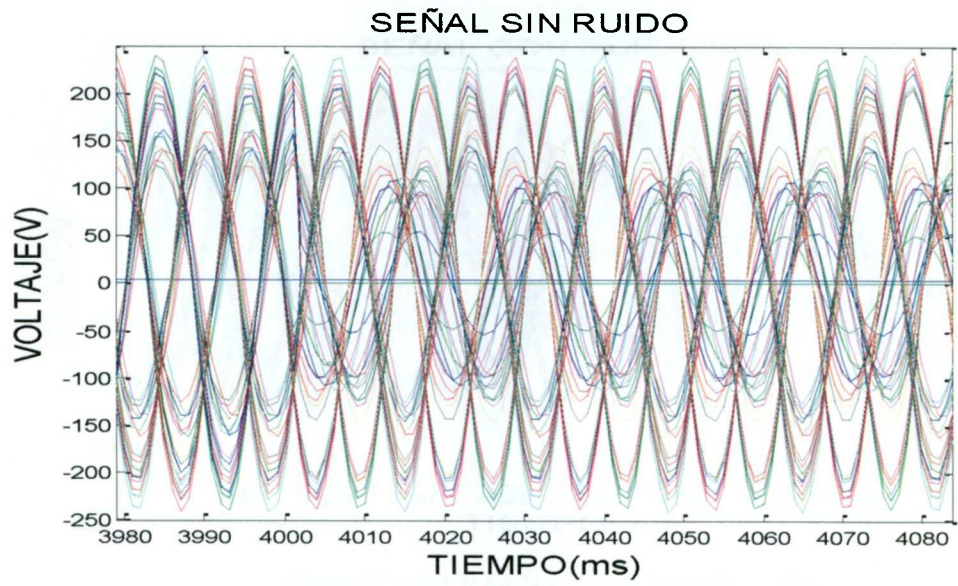


Figura F1. Señal de los 24 nodos sin ruido




Figura F2. Señal de los 24 nodos con ruido de +/- 10%




Figura F3. Señal de los 24 nodos con ruido de +/- 20%

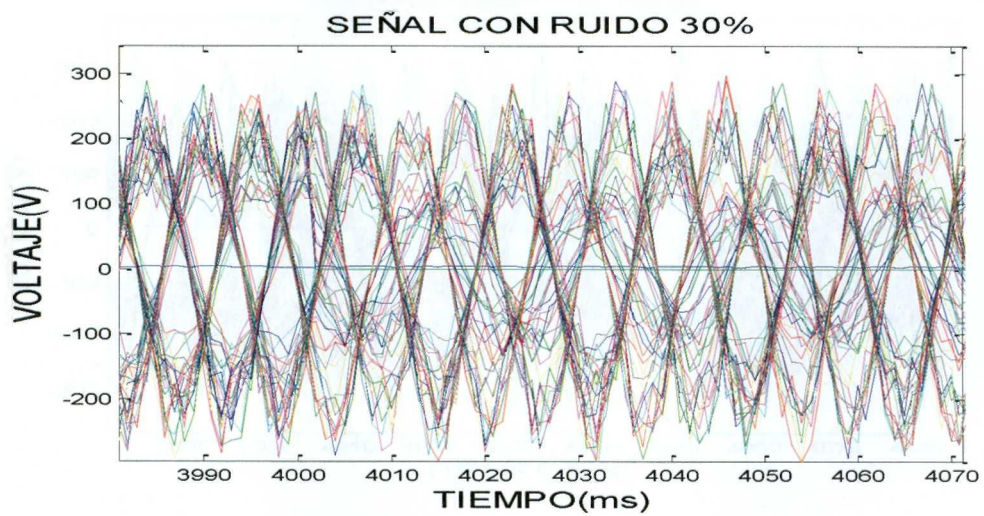


Figura F4. Señal de los 24 nodos con ruido de +/- 30%




Figura F5. Señal de los 24 nodos con ruido de +/- 40%




Figura F6. Señal de los 24 nodos con ruido de +/- 50%




Figura F7. Señal de los 24 nodos con ruido de +/- 60%




Figura F8. Señal de los 24 nodos con ruido de +/- 70%

Tecnológico de Monterrey, Campus Monterrey



30002007356272

<http://biblioteca.mty.itesm.mx>