

**“DETECCIÓN DE FALLAS EN SISTEMAS DE DISTRIBUCIÓN A PARTIR DE  
SEÑALES CON PÉRDIDA DE INFORMACIÓN POR MEDIO DE  
METODOLOGÍAS DE RECONSTRUCCIÓN DE SEÑALES DISPERSAS”**



**UNIVERSIDAD POLITÉCNICA SALESIANA  
SEDE QUITO**

**CARRERA:  
INGENIERÍA ELÉCTRICA**

**Trabajo de titulación previo a la obtención del título de  
INGENIERO ELÉCTRICO**

**TEMA:  
“DETECCIÓN DE FALLAS EN SISTEMAS DE DISTRIBUCIÓN A PARTIR DE  
SEÑALES CON PÉRDIDA DE INFORMACIÓN POR MEDIO DE  
METODOLOGÍAS DE RECONSTRUCCIÓN DE SEÑALES DISPERSAS”**

**AUTOR:  
DIEGO JAVIER PONCE ANDRADE**

**DIRECTOR:  
MILTON GONZALO RUIZ MALDONADO**

**Quito, febrero 2021**

Diego Javier Ponce Andrade

**“DETECCIÓN DE FALLAS EN SISTEMAS DE DISTRIBUCIÓN A PARTIR DE SEÑALES CON PÉRDIDA DE INFORMACIÓN POR MEDIO DE METODOLOGÍAS DE RECONSTRUCCIÓN DE SEÑALES DISPERSAS”**

Universidad Politécnica Salesiana, Quito – Ecuador 2021

Ingeniería Eléctrica

Breve reseña histórica e información de contacto.



**Diego Javier Ponce Andrade** (Y'1990 – M'04), se graduó del Colegio Experimental Técnico 'Don Bosco' en la ciudad de Quito, graduándose de bachiller en especialidad de Electricidad - Electrónica. Actualmente trabaja en la Empresa Eléctrica Quito como electricista en el área de Comercialización. [dponcea@est.ups.edu.ec](mailto:dponcea@est.ups.edu.ec)



Dirigido por:

**Milton Gonzalo Ruiz Maldonado** (Y'1987-M'01), se graduó de la Universidad Politécnica Salesiana en 2012 como Ingeniero Electrónico y en 2015 como Ingeniero Eléctrico; Recibió su M Sc. en Redes de Comunicaciones en la Pontificia Universidad católica del Ecuador; Sus intereses de investigación están en comunicaciones verdes, infraestructura de medición avanzada, red inteligente, redes inalámbricas, gestión de energía. Es profesor de la

Universidad Politécnica Salesiana, Ecuador y parte del Grupo de Investigación GIREI. [mruizm@ups.edu.ec](mailto:mruizm@ups.edu.ec)

Queda prohibida, salvo excepción prevista en la ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con la autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos o investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

©2021 Universidad Politécnica Salesiana

QUITO - ECUADOR

## DECLARATORIA DE COAUTORÍA DEL DOCENTE TUTOR

Yo, Milton Gonzalo Ruiz Maldonado declaro que bajo mi dirección y asesoría fue desarrollado el trabajo de titulación “*Detección de fallas en sistemas de distribución a partir de señales con pérdida de información por medio de metodologías de reconstrucción de señales dispersas*” realizado por Diego Javier Ponce Andrade, obteniendo un producto que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana para ser considerado como trabajo final de titulación.

Quito D.M., febrero de 2021



.....  
Milton Gonzalo Ruiz Maldonado

C.C.: 1714409065

## **CESIÓN DE DERECHOS DE AUTOR**

Yo, Diego Javier Ponce Andrade, con documento de identificación N° 1718450321, manifiesto mi voluntad y cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor del trabajo de grado/titulación intitulado: *“Detección de fallas en sistemas de distribución a partir de señales con pérdida de información por medio de metodologías de reconstrucción de señales dispersas”*, mismo que ha sido desarrollado para optar por el título de: Ingeniero Eléctrico, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia, suscribo este documento en el momento que hago entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito, D.M., febrero de 2021

A handwritten signature in blue ink that reads "Diego Ponce". The signature is stylized with loops and flourishes.

.....  
Diego Javier Ponce Andrade

C.C.: 1718450321

## *INDICE GENERAL*

INTRODUCCIÓN .....	2
SENSADO COMPRIMIDO .....	5
2.1 Matching pursuit .....	8
2.2 Propiedad de isometría restringida.....	9
SISTEMA PARA ENSAYOS .....	9
IMPLEMENTACIÓN DEL MODELO MATEMÁTICO.....	11
4.1 Planteamiento del problema.....	11
4.2 Metodología .....	11
ANÁLISIS DE RESULTADOS .....	12
5.1 Caso A.....	12
5.2 Caso B .....	15
5.3 Caso C .....	16
CONCLUSIONES .....	18
6.1 Trabajos futuros .....	19
REFERENCIAS.....	19
7.1 Matriz de Estado del Arte .....	22
7.2 Resumen de Indicadores .....	24

## ***INDICE DE FIGURAS***

Figura 1. Esquema de detección. [Autoría propia] .....	3
Figura 2. Esquema de sensado comprimido.....	5
Figura 3. Diagrama Unifilar S/E Cotocollao.....	9
Figura 4. Reconstrucción día 1, índice 1.....	12
Figura 5. Reconstrucción día 1, índice 5.....	13
Figura 6. Comparación de índices de reconstrucción, Fase A. ....	13
Figura 7. Caso 1, 90% de datos.....	14
Figura 8. Caso 1, 70% de datos.....	14
Figura 9. Día 2, 70% de datos .....	15
Figura 10. Día 2, 90% de datos .....	15
Figura 11. Día 5, 90% de datos .....	15
Figura 12. Día 1, 90% de datos.....	15
Figura 13. Día 5, 70% de datos.....	16
Figura 14. Corriente de falla, falla trifásica. ....	16
Figura 15. Resultados de reconstrucción. ....	16
Figura 16. Gráficas de umbrales de op. normal. ....	17
Figura 17. Puntos de fallo .....	17
Figura 18. Detección fallida.....	18
Figura 19. Detección sobre reconstrucciones no satisfactorias.....	18
Figura 20. Resumen e indicador de la temática - Estado del arte .....	24
Figura 21. Indicador de formulación del problema - Estado del arte.....	25
Figura 22. Indicador de solución - Estado del arte .....	25

## ***INDICE DE TABLAS***

Tabla 1. Matching Pursuit .....	8
Tabla 2. Relés S/E Cotocollao N 19.....	10
Tabla 3. Pseudocódigo implementado .....	11
Tabla 4. Cantidad de datos por cada nivel. ....	12
Tabla 5. Resultados de detección, cambios en el nivel de reconstrucción.....	13
Tabla 6. Umbral variable, caso 2 .....	14
Tabla 7. Matriz de estado del arte .....	22



# “DETECCIÓN DE FALLAS EN SISTEMAS DE DISTRIBUCIÓN A PARTIR DE SEÑALES CON PÉRDIDA DE INFORMACIÓN POR MEDIO DE METODOLOGÍAS DE RECONSTRUCCIÓN DE SEÑALES DISPERSAS”

## Resumen

La necesidad imperiosa por detectar fallas en sistemas de distribución es aún un desafío para las empresas distribuidoras en todo el mundo, sin embargo, la existencia de mejores tecnologías de comunicación y almacenamiento podrían facilitar la tarea antes mencionada, por otro lado, el almacenar grandes cantidades de datos puede significar un problema en sistemas donde el espacio tanto físico como virtual o en la nube son limitados. Para lidiar con este problema se propone en la necesidad de un método que permita adquirir menores cantidades de datos para luego por medio de técnicas de reconstrucción de señales la información recolectada puede ser fácilmente reconstruida y aquellas señales reconstruidas pueden ser sometidas a diversas técnicas de análisis que a la postre arrojan información sobre la existencia de fallas además de caracterizar las mismas. La presente investigación trabaja en la reconstrucción de señales dispersas y en un método para la detección de fallas además de caracterizar las mismas, al mismo tiempo ejecuta un análisis comparativo frente a diversa cantidad de datos utilizados para la tarea mencionada. Finalmente, el documento valida el uso de la metodología planteada haciendo uso de señales reales de un sistema de distribución local.

**Palabras Clave:** Distribución, Identificación de Fallas, pérdida de señal, sensado comprimido, señal dispersa.

## Abstract

The imperative need to detect faults in distribution systems is still a challenge for distribution companies around the world, however, the existence of better communication and storage technologies could facilitate the aforementioned task, on the other hand, storing large quantities of data can mean a problem in systems where both physical and virtual space or in the cloud are limited. To deal with this problem, the need for a method that allows to acquire smaller amounts of data is proposed and then by means of signal reconstruction techniques, the collected information can be easily reconstructed and those reconstructed signals can be subjected to various analysis techniques that in the end they provide information on the existence of faults in addition to characterizing them. The present investigation works in the reconstruction of dispersed signals and in a method for the detection of faults in addition to characterizing them, at the same time it executes a comparative analysis against the diverse amount of data used for the aforementioned task. Finally, the document validates the use of the proposed methodology using real signals from a local distribution system.

**Keywords:** Compressed sensing, Distribution, fault identification, loss of signal, sparse signal.

# 1 Introducción

Con los avances actuales, las tareas de mantenimiento de diversos componentes han cambiado, volviéndolas de tipo predictivo y que están basadas en la condición; para ello es fundamental el uso de monitoreo de los componentes fundamentales de la red y para ello es necesaria la rápida transmisión de la información que resulta clave para la gestión y mantenimiento inteligente. La gran cantidad de información tiene que ser manejada con rápidas tasas de muestreo, para ello hay grandes necesidades de métodos que permitan reducir la carga de datos que se deben almacenar y transmitir [1].

Una de las mejores formas de reducir la carga de datos es por medio de la compresión de las señales la cual se ha estudiado bajo diversos métodos que incluyen el sensado comprimido, la transformada de Wavelet, la codificación aritmética y de Hoffman, por nombrar algunas [2].

En el caso del sensado comprimido, su funcionamiento consiste en la representación de baja señal de la original, que permite la preservación de la información principal original; luego la señal original se reconstruye por medio de algoritmos de optimización por convergencia, esto también puede ser usado para la detección de fallas en sistemas complejos [1].

Para lidiar con el problema de la detección efectiva de fallas en sistemas, se han propuesto diversas alternativas, incluyendo técnicas avanzadas del procesamiento de las señales, inteligencia artificial, aprendizaje de máquinas y que han sido combinadas con las técnicas tradicionales de detección,

con buenos resultados. La detección en línea de fallas tiene que hacer frente a dos problemáticas, la primera es la forma de obtener los datos requeridos por medio de elementos de sensado adecuados. La segunda limitación consiste en la gran necesidad computacional y de comunicación para obtener la rápida detección de las fallas más comunes en sistemas eléctricos [3], [4].

Pero la correcta detección de las fallas tiene varias ventajas entre las que se incluyen la reducción del tiempo de corte del suministro de energía, también hay mejora de la confiabilidad, seguridad y eficiencia del sistema, así como la satisfacción de los clientes, para ello se requiere automatización y sistemas de comunicación avanzados, todo ello para permitir un rápido despeje de las fallas. Es importante destacar que los sistemas de transmisión y distribución, en especial aquellos que tienen larga extensión en sus líneas, son más propensos al medioambiente y los eventos fortuitos y por tanto resultan más susceptibles a la existencia de fallas [5]–[7]

Tradicionalmente la detección de las fallas consiste en la clasificación y la estimación de la localización, tal detección se realiza en función de las características que se pueden extraer en el procesamiento de las señales, posterior a ello se puede activar un clasificador cuando la falla es efectivamente detectada. Tanto los clasificadores como los detectores de falla deben ser capaces de detectar si el sistema se encuentra en estado normal y en falla, en las redes eléctricas ello permite la minimización de los daños asociados a cortocircuitos, normalmente se usan señales de voltaje y corriente para la detección de fallas [8], [9]. La figura 1 muestra un esquema de




Figura 1. Esquema de detección. [Autoría propia]

un sistema eléctrico completo y un método de detección en distribución.

Las fallas en los sistemas de transmisión han recibido más atención de parte de los investigadores debido a que el impacto que tienen las fallas en estas redes es mayor y además los tiempos que serían requeridos para la inspección física y consecuente detección serían elevados, que contrasta con la extensión de las líneas y subtransmisión. Sin embargo, las líneas de distribución han tomado significativa relevancia en especial para las compañías distribuidoras que forman parte de un mercado competitivo, de tal forma de aumentar la disponibilidad del servicio hacia los consumidores [10].

En la practica el costo de un localizador de fallas para transmisión es elevado y no resulta atractivo para las compañías encargadas de la distribución de electricidad en función del costo-beneficio por lo cual es necesario encontrar alternativas que sean efectivas con un costo competitivo para diversos mercados y que se ajuste a la realidad de

las líneas de distribución de la energía, tanto para las fallas permanentes como las temporales. En el caso de un sistema de distribución debido a su extensión existen variaciones en lo que respecta a la precisión del localizador, la velocidad de respuesta, la velocidad de la transmisión de los datos al centro o centros de control, así como la ventana requerida de datos de análisis y, el nivel de filtrado que se deberá realizar a las señales obtenidas de la red [10].

En [11] se propone un método de detección basado en un modelo ARMA (modelo auto regresivo de media móvil) el cual considera además un despliegue óptimo de PMUs con restricciones de contingencia, observabilidad y redundancia y la señal seleccionada para análisis es la corriente y la información más relevante es la matriz de conectividad. En [12] por otro lado, se usa una variante del modelo antes indicado denominado ARIMA y se analiza primordialmente la señal de voltaje adquirida en los diferentes registradores del sistema.

Otros métodos ampliamente utilizados para la detección de falla primordialmente en sistemas de transmisión son aquellos que contemplan el uso de las transformadas de Fourier y Wavelet. El disponer de información de la falla en uno o ambos extremos de la línea en falla facilita las tareas de análisis espectral de la señal durante la falla por la presencia de armónicos, ambas técnicas pueden ser utilizadas para clasificación y locación de fallas [13]–[16]

La implementación de los métodos antes mencionados también toman importancia al ser combinados con técnicas de optimización ligadas al despliegue de los equipos de medición seleccionados o PMU tal como se indica en [17] en donde se realiza un despliegue óptimo de unidades de medida y se hace uso de Wavelets para los fines pertinentes [18].

El crecimiento sostenido de técnicas más avanzadas como es el caso de sistemas de lógica difusa o incluso inteligencia artificial han permitido implementar algoritmos más complejos para la detección e identificación de fallas, el uso de datos históricos de operación normal de un sistema permiten parametrizar de mejor manera los métodos mencionados [19], [20].

En [6] se propone un método basado en sensado comprimido que está basado en el uso de la reconstrucción de caídas de voltaje, corrientes de falla y con una matriz de impedancia redimensionada. Con el vector de corriente estimado, se puede tener dificultad para reconocer la ocurrencia de la falla, para ello se recurre al aprendizaje de máquina; los voltajes deben ser sincronizados para un adecuado funcionamiento del método. Los resultados muestran que el algoritmo

localiza fallas simples, con una necesidad limitada de dispositivos de medición en la red.

Los investigadores de [21] proponen el uso de sensado comprimido bayesiano (BCS) para reconstruir la corriente de falla de secuencia cero con el fin de detección fallas de fase a tierra en líneas aéreas, híbridas y cables. Para ello emplea un factor de medición de la energía. La reconstrucción es llevada a cabo con una cantidad limitada de muestreo lo que reduce la necesidad de almacenar la información.

La aproximación por sensado comprimido es también empleada en [22] con el fin de la identificación de eventos de falla de arco en sistemas DC, específicamente en generación fotovoltaica. Se indica que el sensado es empleado para la comparación de la corriente en condiciones normales y de falla, que reconoce las variaciones en frecuencias elevadas, mostrando las barreras computacionales existentes y la simplificación de las operaciones de cálculo, así como el uso de herramientas estadísticas para el análisis del perfil de potencia y la rápida detección de arcos.

Otra forma de detectar fallas e identificarlas es la propuesta en [23], en este caso se trata de una aplicación de redes neuronales para eventos anómalos en redes de transmisión. Los investigadores han establecido una metodología que permite identificar la mejor estructura para detectar fallas en la red de transmisión, determinando la cantidad de neuronas que deben existir en la capa escondida y la segunda capa de neuronas en forma tal que la detección se realice empleando los datos fasoriales de corriente y voltaje.

Para poder complementar la reconstrucción de las señales por medio de sensado comprimido, la propuesta de [24] es la generación de un algoritmo acorde a la existencia de fallas en líneas de transmisión y distribución, como un paso clave para la correcta representación de las señales, esto se emplea para realizar una clasificación de las fallas que se presentan, por medio de las señales de corriente de las tres fases.

De acuerdo con [25] las ventajas del uso del sensado comprimido en la detección de fallas incluyen que debido a que los parámetros de la falla se obtienen directamente por el algoritmo, no hay problemas asociados a la estimación múltiple de la localización de la falla. En este caso se requiere conocer los valores de las cargas en todo momento para actualizar la matriz de impedancia, para ello utiliza medidores inteligentes de energía, evaluando todas las fallas en paralelo, lidiando bien con el ruido y con diferentes resistencias de falla.

La presente investigación propone un método de detección de fallas en base a un registro de datos que haya podido sufrir una pérdida de datos o se hayan adquirido con sistemas con frecuencia de muestreo inferior a la esperada para las tareas en mención. El método trabaja sobre señales reconstruidas y un algoritmo que detecta violaciones de umbral mismo que es calculado en base a la información disponible para cada día. La principal diferencia radica en que no se requiere un conocimiento extenso de la red y sus cargas dados que el método trabaja sobre señales adquiridas, pero no necesariamente en línea.

En adelante el documento se organiza de modo que la sección 2 aborda la reconstrucción de señales dispersas, la

sección 3 esquematiza el sistema usado para pruebas, la sección 4 es una revisión del método planteado mientras que la sección 5 aborda el análisis de resultados. Finalmente, la sección 6 muestra conclusiones y trabajos futuros.

## 2 Sensado Comprimido

La técnica correspondiente al sensado comprimido tiene pasos que se ejecutan en forma sucesiva según lo que se puede observar en la figura 2, esto es, se recibe la señal de fuente, para ser representada en forma esparcida, luego se realiza un proceso de medición para luego ser obtenida la señal reconstruida. La señal se representa en forma dispersa usando determinada técnica de dispersión. Luego, las señales se representan desde una gran a una pequeña dimensión linealmente usando una matriz de medición que no tiene relación con el procedimiento disperso. Para completar el proceso, un pequeño número de mediciones se adquieren y luego, las mediciones permiten la reconstrucción adecuada de las señales de fuente [9], [26].




Figura 2. Esquema de sensado comprimido.

La representación dispersa es el paso inicial para el procesamiento de señales, la idea básica es similar a una descomposición lineal de datos multidimensionales si las señales originales son dispersas, basado en un diccionario de señales. Se puede dividir

las representaciones esparcidas en tres grupos: ortogonales, análisis geométrico multiescalar y un diccionario excesivamente completo. Además el proceso se ve limitado por las leyes de muestreo de Nyquist que indica que la tasa de muestreo necesita ser al menos dos veces la frecuencia de la frecuencia máxima de la señal original [9], [24], [27].

El siguiente paso es la medición que consiste en la proyección lineal que emplea una matriz de mediciones que permite obtener un número determinado de mediciones. La selección de la matriz es fundamental para obtener un vector de mediciones y la reconstrucción. El error obtenido es menor cuando la matriz tiene mayor calidad. La matriz de medición debe satisfacer dos principios básicos, incoherencia y la propiedad isométrica restrictiva. Las matrices pueden ser aleatorias o determinísticas, sabiendo que cada tipo de matriz tiene sus ventajas y desventajas, por lo cual la selección de tal matriz es una problemática sin solución concreta, y su rendimiento podría ser puesto a prueba. En la práctica, lo que se busca es que las matrices sean fáciles de colocarse en algoritmos óptimos y ser apropiada para la mayoría de señales que pueden ser representadas en forma dispersa o comprimida [9], [27].

Se toma entonces ventaja de que muchas señales importantes son dispersas (contienen mucho coeficiente cercanos o iguales a cero en algún dominio), usualmente el proceso arranca con la toma de medidas denominadas mediciones de compresión y que son una combinación lineal ponderada y que termina por convertirse en un sistema sub determinado al tener un menor

número de mediciones de compresión que la cantidad de datos requerida.

Con el fin de encontrar una solución para el problema del sistema sub determinado es posible minimizar la cantidad de elementos diferentes de cero y para ello se creó una función llamada norma  $L_0$  con la cual es posible determinar la cantidad de valores diferentes de 0 de un vector sin embargo para ciertas aplicaciones esta técnica no es funcional o los resultados obtenidos no son los necesarios por ello se ha desarrollado el problema  $L_1$  que puede ser mejor resuelto por medio de programación lineal.

El sensado comprimido difiere de otras teorías clásicas en tres aspectos, el primero de ellos hace referencia a que la teoría clásica e encarga de señales muestreadas infinitamente mientras que el método en estudio se basa en elementos finitos de una señal por medio de proyecciones en matrices de dimensiones claras, en segundo lugar se difiere en el hecho de que en vez de tomar un muestreo en puntos específicos de tiempo en este método se proyecta la señal en una base conocida y finalmente la complejidad de la teoría clásica basada en Nyquist-Shannon es inferior mientras que el sensado comprimido requiere de métodos basados en optimización convexa.

La teoría entonces se centra en que dada una señal  $x \in R^N$ , una matriz de sensado  $M \times N$  llamada  $\Phi$  en donde  $M \ll N$  y un vector de mediciones  $y = \Phi x$  se dice que se puede recuperar la señal a partir del vector de mediciones, en donde la relación de sensado equivale a  $R = M/N$  por tanto  $R$  tomará un valor muy inferior de 1 por lo que en un caso general la recuperación no será factible

sin embargo, la teoría también indica que una señal que admite una representación dispersa en un determinado diccionario puede ser recuperada con alta probabilidad de éxito. Dado lo antes mencionado se dice que  $x = \psi c$  en donde  $\psi$  es un diccionario y  $c$  es un vector de coeficientes dispersos con solo  $S \ll N$  elementos diferentes de cero la señal puede ser sintetizada por medio de  $\hat{x} = \psi \hat{c}$  al obtener una solución para  $\hat{c}$  por medio de un problema de optimización no convexa como se muestra en (1).

$$\hat{c} = \operatorname{argmin} \|c\|_0 \text{ sujeto a } y = \Phi \psi c \quad (1)$$

En donde:

$\|c\|_0$ : es la pseudo norma  $\ell_0$  que contabiliza la cantidad de elementos diferentes de cero presentes en  $\alpha$ , aunque también es posible resolver el problema por medio de una versión relajada como se muestra en (2).

$$\hat{c} = \operatorname{argmin} \|c\|_1 \text{ sujeto a } y = \Phi \psi c \quad (2)$$

Entonces, la recuperación completa de  $x$  es garantizada si  $c$  es suficientemente dispersa y se cumplen ciertas condiciones en la matriz de sensado en donde claramente  $M \geq S$  es una de las condiciones. Donde también es importante mencionar que la norma  $\ell_1$  no tiene preferencia entre componentes largos y pequeños, la norma  $\ell_2$  prefiere elementos pequeños donde sus cuadrados son pequeños respecto de elementos grandes cuyos cuadrados se vuelven enormes por lo que en consecuencia la norma  $\ell_1$  permite ciertos componentes grandes lo cual en cambio está prohibido para la norma  $\ell_2$ .

Existen varios métodos iterativos para la reconstrucción de las señales dispersas.

El método denominado Matching Pursuit busca un átomo presente en un diccionario holográfico que mejor aporte para la definición de la señal a ser proyectada y luego retira su contribución del conjunto de mediciones de la señal con lo cual se puede generar un residuo, el algoritmo iterativo se detiene cuando se alcanza un número determinado de iteraciones o por el contrario la norma  $\ell_2$  es menor a un cierto valor determinado.

También se cuenta con una variación de MP denominada Orthogonal Matching Pursuit que trabaja bajo la misma meta de MP buscando el átomo que mejor representa la estructura de las mediciones, sin embargo, se añade una nueva matriz de medición y se halla la solución por medio de un problema de mínimos cuadrados. Frente a MP se puede mencionar que la cantidad de iteraciones necesarias son menores, se requiere de menos mediciones, tiene un menor tiempo de reconstrucción y genera un menor error, por otro lado, como desventaja se tiene la introducción de un problema de mínimos cuadrados y un mayor costo de implementación.

Una nueva variante se introduce y corresponde a Regularized Orthogonal Matching Pursuit, en este caso se introduce un nuevo paso de regularización con lo cual implícitamente se permite la introducción de más de 1 átomo representativo que permite una mejor estimación en cada paso iterativo, por tanto, la cantidad de iteraciones se reduce, el costo de implementación se reduce y el tiempo necesario para la reconstrucción es inferior. Las desventajas respecto a OMP es radican en la necesidad de más mediciones y que a priori se puede requerir de información no disponible como es el caso de la esparcidad de los datos [28].

Algo importante que se debe considerar para llevar a cabo la reconstrucción de señales dispersas corresponde a las normas utilizadas para el cálculo de residuos así por ejemplo para el caso de la norma  $\ell_0$  corresponde a la cantidad de elementos distintos de cero presentes en un vector. La norma  $\ell_1$  conocida como Manhattan es una excelente manera para medir la distancia entre vectores en donde todos los componentes son ponderados por igual y corresponde a la suma de las magnitudes de los vectores presentes en un espacio y suele denominarse también como taxi dado que corresponde a la distancia a recorrer entre un origen y el destino.

Finalmente, la norma  $\ell_2$  siendo la más popular también llamada norma Euclidiana corresponde a la distancia más corta que existe entre el origen y su destino algo importante a considerar es que dado que sus componentes son elevados al cuadrado durante el cálculo se pueden tener resultados con alteraciones por la presencia de elementos no típicos [29], [30].

## 2.1 Matching pursuit

El método de resolución seleccionado para la presente investigación propone el uso de MP, la metodología puede ser descrita en 8 pasos que responden al uso de los siguientes datos.

$$\Phi \in R^{m \times n} \quad (3)$$

$$\Psi \in R^{n \times 1} \quad (4)$$

$$y = \Phi \cdot x \in R^m \quad (5)$$

$$V = \Phi \cdot \Psi = [V_1, V_2, V_3, \dots, V_L] \in R^{m \times 1} \quad (6)$$

$$Vm_i = \|\Phi_i\|_2 = \sqrt{\sum_{j=1}^m \|\Phi_{j,i}\|^2} \quad (7)$$

La ecuación (3) corresponde a la matriz de medición, (4) representa el diccionario, (5) es el vector de medición

mientras que (6) y (7) tienen relación con el diccionario holográfico.

La tabla 1 muestra los 8 pasos a seguir para completar el método que será utilizado, como se puede observar se requiere de un criterio de parada el mismo que puede darse por estimación esperada o por cantidad total de iteraciones.

Tabla 1. Matching Pursuit

Algoritmo 1: Matching Pursuit	
<b>Paso 1:</b>	<b>Entradas:</b> {(4), (5), (6) y (7)} <b>Salidas:</b> { $\hat{x}$ }
<b>Paso 2:</b>	<b>Inicialización:</b> $r = y$ $t = 1$ $\hat{\theta}_i = 0$ con $i = 1, 2, \dots, n$
<b>Paso 3:</b>	<b>Encontrar</b> $V_{nt} = \arg \max \left( \frac{V' \cdot r}{Vm} \right)$
<b>Paso 4:</b>	<b>Encontrar la contribución del átomo <math>V_{nt}</math> a la definición de la señal</b> $w = \frac{V_{nt}' \times r}{Vm_{nt}^2}$
<b>Paso 6:</b>	<b>Actualizar el residuo</b> $r_t = r_{t-1} - w \cdot V_{nt}$
<b>Paso 5:</b>	<b>Reconstrucción</b> $\hat{\theta}_{nt} = \hat{\theta}_{nt} + w$
<b>Paso 6:</b>	<b>Actualiza la iteración</b> $t = t + 1$
<b>Paso 7:</b>	<b>Criterio de parada</b> $\ r\  > \varepsilon \ y\ $ o $t < T$ Volver al paso si se cumple
<b>Paso 8:</b>	<b>Obtiene el estimado de la señal</b> $\hat{x} = \Psi \cdot \hat{\theta}$

El paso 1 entonces consiste en inicializar el contador de iteraciones además de asignar el residuo con el valor de la medición y un vector de estimación con todos sus valores en 0. El segundo paso compara las columnas del diccionario holográfico para buscar la columna con mayor semejanza al residuo, corresponde al proyecto punto con mayor valor entre la máxima proyección y el residuo. El tercer paso consiste en la normalización



por norma al cuadrado del átomo del diccionario holográfico seleccionado. El cuarto paso es una actualización de residuo, el quinto paso corresponde a la suma del estimado de la señal reconstruida, a continuación, se actualiza el contador en el paso 6. El paso 7 comprueba que no se sobre pase el valor máximo de iteraciones o que la norma del residuo se mantenga sobre un umbral para regresar al paso 2, si el criterio de parada se cumple entonces se alcanza el paso 8 mismo que encuentra la señal reconstruida. Es importante recalcar que el paso 2 no elimina la contribución de un átomo por lo cual un mismo átomo podría ser seleccionado 2 veces con lo cual se incrementan la cantidad de iteraciones necesarias para alcanzar una reconstrucción exitosa [26].

## 2.2 Propiedad de isometría restringida

Se encuentra que, para cada número  $k = 1, 2, \dots$  se puede definir una constante relacionada con la isometría  $\delta_k$

de una matriz  $\Phi$  con el número más pequeño que cumpla con (8).

$$(1 - \delta_{S_k})\|x\|_{l_2}^2 \leq \|\Phi x\|_{l_2}^2 \leq (1 + \delta_k)\|x\|_{l_2}^2 \quad (8)$$

Para un orden  $k$  se dice que la matriz cumple la propiedad si  $\delta_k$  se encuentra muy cercana a 1, se dice que si una matriz cumple con el teorema no existe un modo posible de que suceda un fallo de reconstrucción, se posibilita una reconstrucción tan buena como si se conociese en detalle la ubicación de los elementos mayores [31].

## 3 Sistema para ensayos

La S/E Cotocollao No. 19 ubicada en el Norte de Quito cuenta con 3 transformadores de distintos niveles de tensión. El transformador 1 MEIDENSHA ubicado entre las barras de 138 kV y 46 kV cuenta con una potencia nominal máxima de 100 MVA y tres devanados, el transformador 2 ABB ubicado en la barra de 138 kV supe de potencia a los primarios E, D, F,

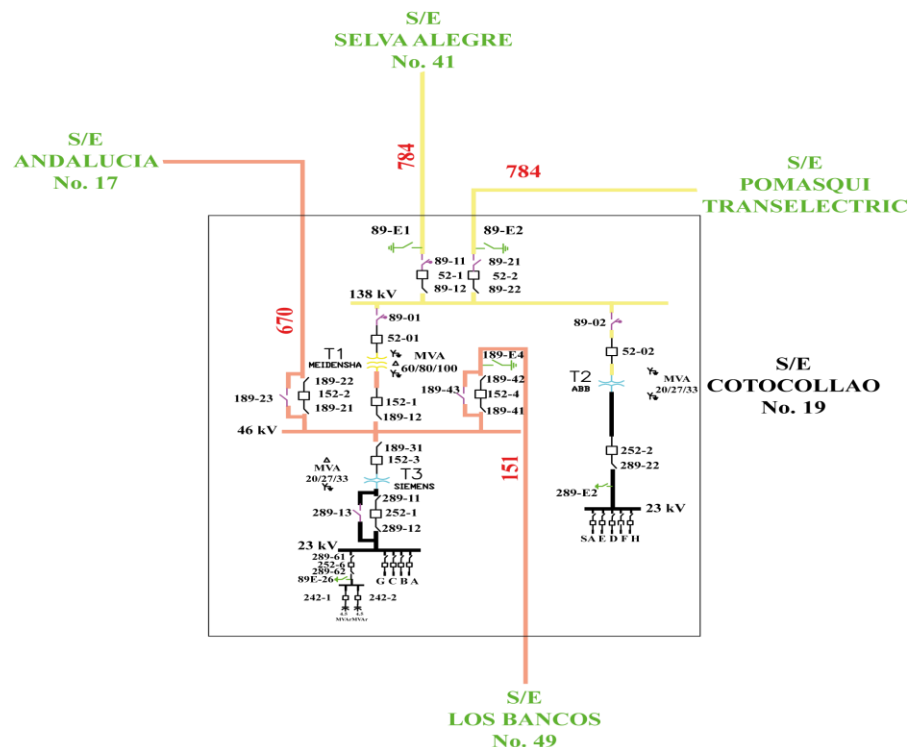


Figura 3. Diagrama Unifilar S/E Cotocollao.

y H además de entregar potencia a los servicios auxiliares de la subestación cuenta con una potencia nominal de 33 MVA y tensión de 23 kV en su lado de baja tensión.

Finalmente, el transformador 3 Siemens conectado en la barra de 46 kV supe de potencia a los primarios G, C, B, A y adicionalmente realiza la interconexión con un sistema de compensación capacitivo que en conjunto suma 9 MVAR, tanto los primarios como el sistema de compensación están suplidos por un voltaje de 23kV.

Por otro lado, la S/E Cotocollao cuenta con múltiples enlaces hacia otras subestaciones tanto de TRANSELECTRIC como de la Empresa Eléctrica Quito. Iniciando por las líneas de 138 kV, el primer enlace se realiza con la S/E Pomasqui TRANSELECTRIC con una longitud de 17.73 km mientras que el segundo enlace para este nivel de tensión se realiza con la S/E Selva Alegre No. 41 de la Empresa Eléctrica Quito con una longitud total de 8.48 km. Por otro lado, la S/E Cotocollao también cuenta con enlaces a nivel de 46kV desde la barra que se enlaza con el Transformador 1. Dichos enlaces corresponden en primer lugar a una línea de 6.64 km con la S/E El Bosque No. 15 sin embargo a los 3.65 km se realiza una derivación de 900 metros con la S/E Andalucía No. 17 y finalmente se realiza un enlace de 48.55 km hacia la S/E Los Bancos No. 49. Los relés instalados en la S/E se muestran en la tabla 2.

Tabla 2. Relés S/E Cotocollao N 19

Equipo	Conexión
Relé 7SJ645	L/T Selva Alegre
REL670-ABB	L/T Selva Alegre
Relé D60-GE	L/T Selva Alegre

Relé 7SJ645	L/T Pomasqui
REL670-ABB	L/T Pomasqui
Relé D60-GE	L/T Pomasqui
Relé 7SJ645	L/T Los bancos
Relé D60-GE	L/T Los bancos
Relé 7SJ645	L/T El bosque
Relé D60-GE	L/T El bosque
Relé 7SJ645	Alimentación 138kV T1
Relé 7SJ645	Alimentación 46kV T1
Relé 7UT613	Transformador 1
Relé 7PA22 86-T1	Transformador 1
Relé 7SJ645	Alimentación 138kV T2
Relé 7SJ645	Alimentación 46kV T3
Relé 7SJ645	Alimentación 23kV T3
Relé 7UM622	Transformador 3
Relé 7PA22 86-T3	Transformador 3
Relé REB670-ABB Corriente	Barra 138kV
Relé 7PA22 86-B1	Barra B1 138kV
Relé REB670-ABB Corriente	Barra 46kV
Relé 7PA22 86-B2	Barra B2 46kV
Relé 7SJ645	Alimentación capacitores
Relé 7SJ622	Primario 252-A
Relé 7SJ622	Primario 252-B
Relé 7SJ622	Primario 252-C
Relé 7SJ622	Primario 252-E
Relé 7SJ622	Primario 252-G
Relé 7SJ622	Primario 252-F
Relé 7SJ622	Primario 252-D

La figura 3 muestra el esquema unifilar de la S/E Cotocollao y sus respectivos enlaces con las subestaciones antes mencionadas, se ilustran también los

correspondientes dispositivos de protección para cada enlace.

## 4 Implementación del modelo matemático

### 4.1 Planteamiento del problema

El presente documento investigativo busca realizar un estudio para la detección de fallos a partir del uso de señales obtenidas por medio de técnicas de reconstrucción de señales dispersas. El subcapítulo que continúa muestra la metodología para alcanzar el objetivo planteado. Para el estudio de los diferentes casos se ha accedido a información histórica de corriente varios primarios de la subestación Cotocollao, el nivel de voltaje de los primarios corresponde a 23 kV y la medición se ha realizado aguas debajo de la subestación por lo cual las señales de corriente obtenida tienen semejanza con una curva de demanda. El evento a ser detectado y clasificado corresponde a desconexiones del servicio.

Por otro lado, el ensayo contempla la pérdida de datos porcentuales que van desde un 10% hasta un 50% de pérdida de datos, esto hace referencia a que el algoritmo sustrae los datos del conjunto total para simular la pérdida de datos o una frecuencia de datos inferior a la deseada.

### 4.2 Metodología

Se ha implementado una metodología para la detección e identificación de fallas basado en el sensado de señales de corriente, para ello el algoritmo analiza los valores mínimo promedio de las señales bajo análisis y luego en función de ello asigna un nivel de umbral que al ser rebasado por los valores de la señal entonces se asigna la detección de una

falla, una vez detectada se inicia un proceso de clasificación o identificación de la falla para lo cual se analiza si el comportamiento se repite en cada una de las fases y al ser un análisis temporal también se determina en qué día se da la falla. Cabe mencionar y recalcar que la señal que analiza el algoritmo proviene de un proceso de reconstrucción por sensado comprimido. La tabla 3 muestra el pseudocódigo implementado.

Tabla 3. Pseudocódigo implementado

#### Algoritmo 1: Detección de fallas

```

Paso 1: Entradas: {base_datos, sub, porc, const., días, prims}
Paso 2: Salidas: {diaF, faseF, Tipo}

Paso 3: Inicialización:
sub ← caso a estudiar (1, 2)
porc ← porcentaje de pérdida de datos (1, 2, 3, 4, 5, 6)
const ← constante para cálculo de umbral (1.3, 1.4, 1.5)
dias ← diassub.mat
prims ← primssub.mat
cont = 0
contA = 1
contB = 1
contF = 0
Falla = ['no_falla', 'monofasica', 'bifasica', 'trifasica']
FFases = ['A', 'B', 'C']
fase = [0 0 0]

Paso 4: Importación de datos
Para i=1 hasta i=dias
Para j=1 hasta j=3
xmpa ← rec_dia_sub_i_j_porc.mat
sFA(todos, contA) ← xmpa
minimosA(contA) ← min(xmpa)
contA = contA + 1
Fin para j
Si prims=2
Para j=4 hasta j=6
xmpa ← rec_dia_sub_i_j_porc.mat
sFB(todos, contB) ← xmpa
minimosB(contB) ← min(xmpa)
contB = contB + 1
Fin para j
Fin Si

```

**Fin para  $i$**

**Paso 5:** **Cálculo de umbrales**  
 $mA \leftarrow \text{promedio}(\text{minimos}A)$   
 $\text{thr}A = mA * \text{const}$   
 $mB \leftarrow \text{promedio}(\text{minimos}B)$   
 $\text{thr}B = mB * \text{const}$

**Paso 6:** **Detección de fallos**  
 $[\text{dia}Fi, \text{dia}Fj] \leftarrow \text{encontrar}(sFA < \text{thr}A)$   
 $\text{fas} \leftarrow \text{unicos}(\text{dia}Fj)$

**Paso 5:** **Cálculo de día con falla**  
**Para  $k=1$  hasta  $k=\text{días}$**   
**Si  $\text{dia}Fj(\text{final}) \geq (k*3-2)$  y  $\text{dia}Fj(\text{final}) \leq (k*3)$**   
 $\text{dia}F \leftarrow k$   
**Fin Si**  
**Fin para  $k$**

**Paso 6:** **Determinación de fases y tipo de falla**  
**Si  $\text{unicos}(\text{fas} \neq 0)$  y  $\text{tamaño}(\text{fas}) \leq 3$**   
Tipo = Falla( $\text{tamaño}(\text{fas})+1$ )  
**Para  $l=1$  hasta  $\text{tamaño}(\text{fas})$**   
**Si  $\text{fas}(i) = (\text{dia}Fj*3-2)$**   
 $\text{fase}(1)=1$   
**Sino Si  $\text{fas}(i) = (\text{dia}Fj*3-1)$**   
 $\text{fase}(2)=1$   
**Sino**  
 $\text{fase}(3)=1$   
**Fin Si**  
**Fin para  $l$**   
**Para  $m=1$  hasta  $m=3$**   
**Si  $\text{fase}(m) == 1$**   
 $\text{contf} = \text{contf} + 1$   
 $\text{faseF}(\text{contf})$   
 $\leftarrow \text{FFases}(m)$   
**Fin Si**  
**Fin para  $m$**   
**Fin Si**

**Paso 7:** **Muestra resultados**  
 $\text{Muestra}(\text{dia}F, \text{faseF}, \text{Tipo})$

**Paso 8:** **Termina**

Tabla 4. Cantidad de datos por cada nivel.

Índice de reconstrucción	Cantidad de datos usados
1	50%
2	60%
3	70%
4	80%
5	90%
6	100%

## 5 Análisis de resultados

### 5.1 Caso A

Una vez iniciado los ensayos con el algoritmo planteado se procede a revisar las señales obtenidas después del proceso relacionado al sensado comprimido de modo tal que, por ejemplo, la figura 4 muestra los resultados obtenidos con un índice de reconstrucción igual a 1, es notorio que las señales obtenidas no resultan útiles en absoluto dado el nivel de ruido que presenta.




Figura 4. Reconstrucción día 1, índice 1.

Por otro lado, la tabla 3 muestra la cantidad de datos utilizados en cada nivel de reconstrucción, término que será utilizado en adelante para hacer mención a la cantidad de datos implementada por el método de reconstrucción de señal dispersa utilizado.

Por otro lado, las señales mostradas en la figura 5 ilustra el mismo día, pero con un índice de reconstrucción superior con lo cual la señal mejora y es posible utilizarla en el algoritmo de detección. Es comprensible que el método utilizado para la reconstrucción de la señal dispersa trabaje mejor con una mayor cantidad de información dado que los

datos perdidos son menos. El tener señales ruidosas como la observada en la figura 5 en comparación con la mostrada en la figura 6 afectan negativamente en tareas de análisis futuras.




Figura 5. Reconstrucción día 1, índice 5.

De manera análoga y con el fin de mostrar la variación entre los índices mencionados la figura 6 muestra la fase A frente al índice 1 y al índice 5 en donde se puede apreciar que la información de análisis es la adecuada para el segundo caso y serán las mismas las implementadas en cada día y cada fase del sistema.




Figura 6. Comparación de índices de reconstrucción, Fase A.

Una vez analizado el sistema bajo la consideración de que el umbral de disparo se coloca en un valor de 1.5 veces el mínimo promedio de las señales analizadas (valor seleccionado en función del análisis realizado con diferentes valores de umbral), la tabla 4 expone los resultados obtenidos para los 2 casos estudiados. Se logra notar que

para el primer caso la cantidad de datos implementada en las tareas de reconstrucción no implican una alteración significativa dado que la falla es significativa, sin embargo, para el segundo caso la situación es diferente al notar que tan sólo los casos en los cuales se utiliza el 90 y 100% de los datos de las señales se consigue la detección de la anomalía en la red.

Tabla 5. Resultados de detección, cambios en el nivel de reconstrucción.

Índice de reconstrucción	Detección Caso 1	Detección Caso 2
1	Sí	No
2	Sí	No
3	Sí	No
4	Sí	No
5	Sí	Sí
6	Sí	Sí

Debido a las deficiencias presentes en el segundo caso se propone la variación el nivel del umbral de detección con el fin de conseguir mejores resultados, cabe destacar que el primer caso no es expuesto a este análisis dado que los resultados obtenidos son adecuados. La tabla 5 muestra los resultados obtenidos al ensayar 2 contantes de umbral adicionales, los resultados mostrados como parciales son debido a que la anomalía es detectada pero el tipo y fases afectadas no son detectadas por completo mientras que los resultados mostrados como inconsistentes son ensayos en los cuales se detectan anomalías en la red pero las mismas no corresponden ni a día ni al tipo de anomalía que se sabe sucede, así por ejemplo se detectan fallas en el día 3.

Tabla 6. Umbral variable, caso 2

Índice de reconstrucción	Constante de umbral 1.5	Constante de umbral 1.4	Constante de umbral 1.3
1	No	No	Inconsistente
2	No	No	Inconsistente
3	No	Sí, parcial	Sí, parcial
4	No	No	Inconsistente
5	Sí	Sí	Sí
6	Sí	Sí	Sí

La figura 7 muestra los resultados de la detección para el caso 1 día en el cual se presenta una desconexión de las 3 fases del primario por alguna anomalía. En la gráfica se puede ver que notablemente el umbral de detección es violado por las señales. La figura en mención corresponde a una señal con un 10% de pérdida de señal. El umbral seleccionado para la detección corresponde a un valor de  $-47.62$ , es importante recalcar que el valor negativo se presenta debido a un offset ingresado para acoplar la señal al método de reconstrucción utilizado, el mismo que requiere del conteo de cruces por cero al tratarse de valores de corriente vistos desde la subestación y tomados como valores rms no se disponen de cruces por cero naturales por lo que el introducir el offset mencionado permite que dichos cruces por cero existan y con ello el método de reconstrucción implementado pueda obtener resultados válidos y óptimos. Cabe destacar también que el valor de umbral es calculado automáticamente por el método planteado y se selecciona el 10% de pérdida dado que es el mínimo porcentaje de pérdida que fue puesto en estudio.

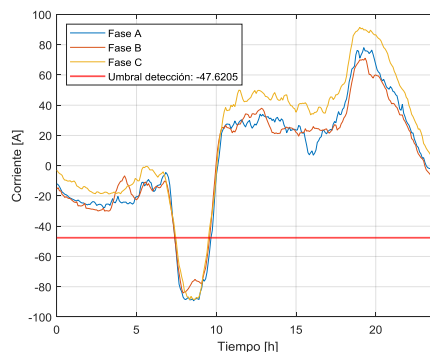


Figura 7. Caso 1, 90% de datos

Por otro lado, al analizar el mismo caso, pero con tan solo el 70% de información ingresada al algoritmo de reconstrucción de señal el resultado de detección es idéntica y acertada, sin embargo, el umbral de detección cambia en función de que la señal es más ruidosa. Se puede notar que ahora el umbral de detección se coloca en  $-52.36$  como lo muestra la figura 8.




Figura 8. Caso 1, 70% de datos.

Al revisar un día aleatorio respecto al umbral seleccionado se puede notar que efectivamente el valor calculado es un valor alejado de los mínimos localizados en días de operación nominal. La figura 9 muestra el segundo día de los 13 que se analizan en total se puede observar que el valor de umbral es el mismo para todos los días, pero únicamente los días que violan el umbral son los notificados.




Figura 9. Día 2, 70% de datos




Figura 11. Día 5, 90% de datos

De manera análoga la figura 10 ilustra lo mencionado en el párrafo anterior, pero con una mayor claridad dado que la cantidad de datos utilizados para la reconstrucción de datos es superior.




Figura 10. Día 2, 90% de datos

El valor de detección de umbral para estos casos se coloca en torno a -20.35 sin embargo al analizar el día 2 se puede apreciar que la distancia entre un valor mínimo en condición normal no está alejada del valor de umbral tal como lo muestra la figura 12.




Figura 12. Día 1, 90% de datos.

## 5.2 Caso B

Por otro lado, al analizar el segundo caso que corresponde al mes de agosto y donde la falla sucede en solamente 2 fases se puede observar que al igual que en el caso anterior al trabajar con el 90% de los datos para la reconstrucción. La figura 11 muestra la detección de la falla mientras que la figura 13 muestra el segundo día bajo análisis en este segundo conjunto de datos.

Como se pudo observar en la tabla 3 y 4 la variación de la cantidad de los datos utilizados para las tareas de reconstrucción ocasiona que la señal obtenida sea ruidosa y contenga una cantidad considerable de ruido, dado que el valor umbral no se sitúa en un valor alejado de los mínimos, ocasiona falsos positivos o en su defecto la omisión de casos de fallo.

La figura 13 ilustra el día 2 considerando el 70% de datos para la reconstrucción,

la figura es clara al mostrar que el algoritmo no sería capaz de distinguir entre violaciones de umbral ocasionado por una falla y aquellos datos falsos resultantes de un proceso de reconstrucción deficiente. Así como posibles violaciones que no son detectadas por la deficiente reconstrucción, en el caso del día 5 se da la detección, pero es parcial dado que solo detecta anomalía en 1 de las fases.




Figura 13. Día 5, 70% de datos.

Otro factor a destacar radica en el hecho de que la existencia de ruido altera también el cálculo del valor umbral de detección. Al colocar el umbral en un valor más alejado de los mínimos reales, habrá mayor posibilidad de errores.

### 5.3 Caso C

Revisados los casos anteriores se puede observar la detección de desconexiones en primarios vistos desde el punto de conexión en la subestación correspondiente. Otro caso interesante de revisar radica en la presencia de valores anómalos dada la existencia de una falla cuyo efecto inmediato radica en la alteración de las magnitudes eléctricas principales.

De tal manera la presente observación corresponde a una falla de tipo trifásica y la variable observada corresponde a la

corriente en las 3 fases en donde después de presentarse la falla sus valores se modifican al igual que la forma de onda sinusoidal como se puede observar en la figura 14, los datos presentados fueron obtenidos de un modelo de 15 barras modificado de la IEEE y las señales corresponden a una falla ocurrida en su línea más larga mediante simulación.

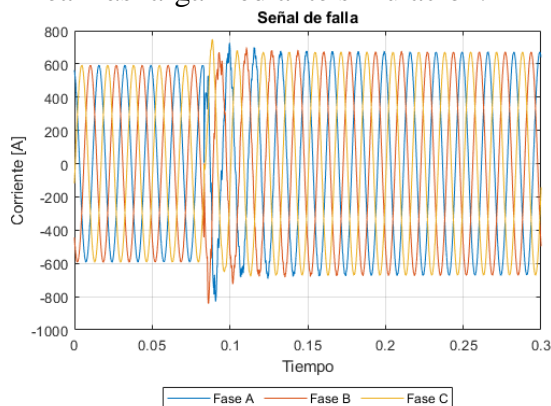


Figura 14. Corriente de falla, falla trifásica.

Debida a la cantidad de datos recolectada por el sistema de ensayos se reduce la zona de búsqueda a un lapso que transcurre entre los 0.06 y los 0.12 segundos esto con el fin de reducir los tiempos de máquina requeridos para procesar la información. Se realiza un análisis similar a lo observado en los casos A y B con lo cual la figura 15 muestra los resultados de reconstrucción con diferentes cantidades de datos usados (perdidos).




Figura 15. Resultados de reconstrucción.



Aún con la reducción de datos expuesta la cantidad de mediciones tomadas corresponde a 3000 puntos con sus respectivas marcas de tiempo con el respectivo análisis de cada fase. Se puede observar que la cantidad de pérdida de datos desde la cual se puede obtener una señal aprovechable para análisis debe ser menor al 20% sin embargo, aquello implica que en un universo de 3000 datos por fase la cantidad de datos que puede ser perdida corresponde a 600 lecturas.

Se calcula un umbral en función de los valores mínimos y máximos de las señales previo a los 0.06 segundos en donde se visualiza una condición de prefalla. Dichos umbrales son graficados para los casos con pérdidas del 20%, 10% y sin pérdida de datos para visualizar la existencia de una falla.




Figura 16. Gráficas de umbrales de op. normal.

Es claro que los umbrales de condición de operación normal son violados sin embargo este análisis es relativo dado que se podrían presentar pequeñas fluctuaciones de corriente que podría ser tomadas como falsos positivos por lo cual se vuelve necesario ingresar una constante adicional para alterar estos umbrales.

La figura 17 muestra los puntos más alejados de los umbrales seleccionados para cada una de las fases en donde se puede observar que dichos puntos son los que se presentan en los picos de señal después de ocurrida la falla en las 3 fases, la ocurrencia de una falla trifásica se explica entonces por la violación de umbral por parte de las 3 señales de corriente, además de ello los puntos máxima corriente suceden en puntos similares sin llegar a suceder en el mismo instante dado el desfase existente entre las fases de un sistema de este tipo.




Figura 17. Puntos de fallo

Los umbrales presentados en la figura 17 corresponden a los presentados en la figura 16 aumentados en un 25% lo cual puede ya ser entendido como una falla y no un cambio normal de operación. La señal utilizada corresponde a aquella en la que se procesan los datos con una pérdida del 20% de datos con lo cual se valida que el método planteado también es funcional para eventos de sobrecorriente derivadas de una falla.

Por otro lado, la figura 18 muestra una detección fallida al haber puntos que superan el umbral de detección antes de la ocurrencia de la falla que ahora conocemos sucede cercano a los 0.09 segundos, las señales mostradas son aquellas recuperadas con el 30% de pérdida de datos haciendo uso de matching pursuit.




Figura 18. Detección fallida

Si bien es cierto las detecciones de 2 de las fases suceden en el tiempo cercano al son visibles violaciones en puntos anteriores a la ocurrencia de la falla. Esto demuestra que se podría utilizar señales con mayor pérdida de datos (30% de pérdida de información) sin embargo, la detección de anomalías se vuelve más complicada y se podrían presentar falsos positivos.

Se propone entonces el usar la misma señal ruidosa como referencia para el cálculo del umbral de operación nominal, lo cual permite encontrar de mejor manera la existencia de una operación anómala, aunque esto limita la introducción de un umbral para separar las condiciones normales de las presentadas durante falla, la figura 19 muestra lo mencionado como contraste a la figura 18 en donde el cálculo de umbral se realiza en una señal con una reconstrucción satisfactoria.

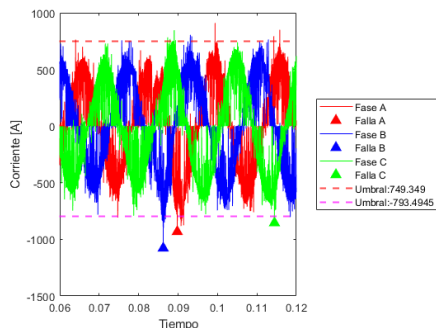


Figura 19. Detección sobre reconstrucciones no satisfactorias.

Es evidente entonces que el algoritmo es capaz de trabajar sobre señales de tipo promedio, así como señales transitorias las primeras ideales para detección de desconexiones en horizontes de análisis de minutos u horas mientras que las segundas ideales para detección de fallas con horizontes de estudio en el orden de milisegundos o fracciones de segundos. Se contrasta la cantidad de datos de los 2 primeros casos con 288 observaciones por día de estudio comparado con el tercer caso en el cual 60 milisegundos de análisis se componen por 3000 observaciones.

Expuesto lo anterior es posible notar que el método planteado brinda la posibilidad de detectar fallos en sistemas de distribución a partir de información que puede haber sufrido pérdida de datos bien sea por daños en la red de comunicaciones, frecuencia de muestreo insuficiente, pérdida de datos desde el sistema de almacenamiento entre otros casos. Métodos basados en transformadas de Wavelets o Fourier requieren de señales ideales con presencia de armónicos o incluso ondas viajeras para realizar el análisis de pequeña señal, el método planteado brinda robustez dado que se basa en la reconstrucción de señales. Por tanto, el método es menos sensible a la ausencia de porciones de señal y también es menos sensible a fallos en la implementación con equipos cuya capacidad de muestreo o almacenamiento es reducida al igual que en casos en los cuales la estructura de comunicación puede generar ausencia de datos.

## 6 Conclusiones

Se valida la aplicación de un algoritmo para la detección de fallas sobre datos

adquiridos de un sistema de distribución sobre las cuales se han simulado pérdidas de señal o datos, la reconstrucción se ensaya con pérdidas de datos entre 10 y 50 por ciento del total de datos. En ambos casos se logra determinar el día de ocurrencia de falla además del tipo de falla.

Se valida la capacidad de estudiar varios días para cada caso con lo cual se ha planteado el algoritmo de detección para calcular el valor de umbral para la detección de la falla el primer caso cuenta con un total de 13 días mientras que el segundo caso tiene 8 días con 1 día de falla en cada caso. Teniendo una falla trifásica y una falla bifásica correspondientemente al caso.

No solo la cantidad de datos tiene influencia sobre la capacidad de detección del algoritmo, varios casos de sensibilidad son estudiados al variar la constante de cálculo del umbral de detección y así entender cómo dicha constante mejora o empeora la capacidad de detección del algoritmo.

La implementación de reconstrucción por medio de técnicas adecuadas para señales dispersas permite realizar un análisis de la cantidad mínima de datos necesarios para obtener buenos resultados en tareas de detección de fallos basado en el uso de límites.

Implementar un sistema automático de selección de umbrales de detección le brinda al método la posibilidad de adaptarse a diferentes sistemas y le otorga dinamismo en su implementación. El uso de varios días para el estudio permite por otro lado mejorar la certeza del método.

Los métodos de reconstrucción de señales dispersas se desenvuelven de

mejor manera cuando se analizan conjunto de datos reducidos dado que al aumentar significativamente la cantidad de datos en análisis, los tiempos de máquina requeridos son extensos y poco eficientes.

## 6.1 Trabajos futuros

Se propone la inclusión de estudios de pequeña señal que hagan uso de señales provenientes de la reconstrucción por medio de técnicas con señales dispersas.

La presente investigación es base frente a la posibilidad de ensayar diferentes técnicas de reconstrucción de señales dispersas, se puede entonces ensayar su rendimiento a posterior en tareas de detección de fallos o anomalías en la red.

## 7 Referencias

- [1] Y. Ma *et al.*, “A new fault diagnosis method based on convolutional neural network and compressive sensing,” *J. Mech. Sci. Technol.*, vol. 33, no. 11, pp. 5177–5188, 2019.
- [2] J. Inga-Ortega, E. Inga-Ortega, C. Gómez, and R. Hincapié, “Electrical load curve reconstruction required for demand response using compressed sensing techniques,” *2017 IEEE PES Innov. Smart Grid Technol. Conf. - Lat. Am. ISGT Lat. Am. 2017*, vol. 2017-Janua, pp. 1–6, 2017.
- [3] A. Raza, A. Benrabah, T. Alquthami, and M. Akmal, “A review of fault diagnosing methods in power transmission systems,” *Appl. Sci.*, vol. 10, no. 4, 2020.
- [4] M. Jamil, S. K. Sharma, and R. Singh, “Fault detection and classification in electrical power transmission system using artificial neural network,” *Springerplus*, vol. 4, no. 1, 2015.
- [5] A. A. Awelewa, P. O. Mbamaluikem,

- and I. A. Samuel, "Artificial Neural Networks for Intelligent Fault Location on the 33-Kv Nigeria Transmission Line," *Int. J. Eng. Trends Technol.*, vol. 54, no. 3, pp. 147–155, Dec. 2017.
- [6] M. Majidi, M. Etezadi-Amoli, and M. Sami Fadali, "A Novel Method for Single and Simultaneous Fault Location in Distribution Networks," *IEEE Trans. Power Syst.*, vol. 30, no. 6, pp. 3368–3376, Nov. 2015.
- [7] M. Ruiz and I. Montalvo, "Electrical faults signals restoring based on compressed sensing techniques," *Energies*, vol. 13, no. 8, 2020.
- [8] L. Teklić, B. Filipović-Grčić, and I. Pavičić, "Artificial neural network approach for locating faults in power transmission system," *IEEE EuroCon 2013*, no. July, pp. 1425–1430, 2013.
- [9] H. Yin, J. Li, Y. Chai, and S. X. Yang, "A survey on distributed compressed sensing: theory and applications," *Front. Comput. Sci.*, vol. 8, no. 6, pp. 893–904, 2014.
- [10] M. M. Saha, J. Izykowski, and E. Rosolowski, *Fault Location on Power Networks*, vol. 48. 2010.
- [11] D. Carrión, J. W. González, G. J. López, and I. A. Isaac, "Alternative fault detection method in electrical power systems based on ARMA model," *2019 FISE-IEEE/CIGRE Conf. - Living Energy Transition, FISE/CIGRE 2019*, 2019.
- [12] D. P. M. De Souza, E. Da Silva Christo, and A. R. Almeida, "Location of faults in power transmission lines using the ARIMA method," *Energies*, vol. 10, no. 10, pp. 1–12, 2017.
- [13] A. Abdollahi and S. Seyedtabaai, "Comparison of fourier & wavelet transform methods for transmission line fault classification," *PEOCO 2010 - 4th Int. Power Eng. Optim. Conf. Progr. Abstr.*, no. June, pp. 579–584, 2010.
- [14] D. Das, N. K. Singh, and A. K. Sinha, "A comparison of fourier transform and wavelet transform methods for detection and classification of faults on transmission lines," *2006 IEEE Power India Conf.*, vol. 2005, pp. 620–626, 2005.
- [15] T. Takagi, Y. Yamakoshi, M. Yamaura, R. Kondow, and T. Matsushima, "Development of a New Type Fault Locator Using the One-Terminal Voltage and Current Data," *IEEE Power Eng. Rev.*, vol. PER-2, no. 8, pp. 59–60, 1982.
- [16] F. Vigolvinho Lopes, B. Fernandes Kusel, and K. Melo Silva, "Traveling Wave-Based Fault Location on Half-Wavelength Transmission Lines," *IEEE Lat. Am. Trans.*, vol. 14, no. 1, pp. 248–253, 2016.
- [17] D. Carrión, J. W. González, I. A. Issac, and G. J. López, "Optimal fault location in transmission lines using hybrid method," *2017 IEEE PES Innov. Smart Grid Technol. Conf. - Lat. Am. ISGT Lat. Am. 2017*, vol. 2017-Janua, pp. 1–6, 2017.
- [18] S. M. Brahma, "Fault location scheme for a multi-terminal transmission line using synchronized voltage measurements," *IEEE Trans. Power Deliv.*, vol. 20, no. 2 II, pp. 1325–1331, 2005.
- [19] R. Perez, C. Vásquez, and A. Viloria, "An intelligent strategy for faults location in distribution networks with distributed generation," *J. Intell. Fuzzy Syst.*, vol. 36, no. 2, pp. 1627–1637, 2019.
- [20] R. Perez *et al.*, "Fault diagnosis on electrical distribution systems based on fuzzy logic," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes*

- Artif. Intell. Lect. Notes Bioinformatics*), vol. 10942 LNCS, pp. 174–185, 2018.
- [21] J. Guo, L. Tian, Y. Hou, and Y. Gao, “Application of Bayesian compressed sensing theory in single -phase-to-ground fault line selection of distribution network,” in *2017 IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific)*, 2017, pp. 1–6.
- [22] W. Fenz, S. Thumfart, R. Yatchak, H. Roitner, and B. Hofer, “Detection of Arc Faults in PV Systems Using Compressed Sensing,” *IEEE J. Photovoltaics*, vol. 10, no. 2, pp. 676–684, 2020.
- [23] C. W. Asbery and Y. Liao, “Electric Transmission System Fault Identification Using Artificial Neural Networks,” *2019 Int. Energy Sustain. Conf. IESC 2019*, 2019.
- [24] S. Shi, B. Zhu, S. Mirsaedi, and X. Dong, “Fault Classification for Transmission Lines Based on Group Sparse Representation,” *IEEE Trans. Smart Grid*, vol. 10, no. 4, pp. 4673–4682, 2019.
- [25] M. Majidi, A. Arabali, and M. Etezadi-Amoli, “Fault Location in Distribution Networks by Compressive Sensing,” *IEEE Trans. Power Deliv.*, vol. 30, no. 4, pp. 1761–1769, 2015.
- [26] J. A. Rodríguez De Sarrazin, “Estudio de los Algoritmos de reconstrucción en Compressed Sensing.”
- [27] I. Orović, V. Papić, C. Ioana, X. Li, and S. Stanković, “Compressive Sensing in Signal Processing: Algorithms and Transform Domain Formulations,” *Math. Probl. Eng.*, vol. 2016, 2016.
- [28] J. A. Rodríguez De Sarrazin, “Estudio de los Algoritmos de reconstrucción en Compressed Sensing,” Universidad de los Andes.
- [29] A. P. L. Polo, R. H. R. Coral, J. A. Q. Sepúlveda, and A. L. R. Vélez, “Sparse signal recovery using orthogonal matching pursuit (OMP),” *Ing. e Investig.*, vol. 29, no. 2, pp. 112–118, 2009.
- [30] S. Kumar, “Illustrated Compressed Sensing,” p. 517, 2014.
- [31] C. Sensing, C. Sensing, and E. C. Sensing, “Introducción a la teoría del Compressive Sensing.”

## 7.1 Matriz de Estado del Arte

Tabla 7. Matriz de estado del arte

DETECCIÓN DE FALLAS EN SISTEMAS DE DISTRIBUCIÓN A PARTIR DE SEÑALES CON PÉRDIDA DE INFORMACIÓN POR MEDIO DE METODOLOGÍAS DE RECONSTRUCCIÓN DE SEÑALES DISPERSAS																			
ITEM	DATOS	TÍTULO DEL ARTÍCULO	CITAS	TEMÁTICA				FORMULACIÓN DEL PROBLEMA FUNCIONES OBJETIVO			RESTRICCIONES DEL PROBLEMA			PROPUESTAS PARA RESOLVER EL PROBLEMA			SOLUCIÓN PROPUESTA		
				Métodos para la localización de fallas	Señales dispersas	Sensado comprimido	Fallas en redes de distribución	Sensado comprimido	Señales adquiridas de sistemas reales	Detección de falla	Tipo de falla	Fallas en sistemas de distribución	Cantidad de pérdida de información	Sensibilidad del sistema	Obtención de valores de umbral	Uso de diferentes pérdidas de datos	Variación de constante para umbral	Sensado comprimido	Búsqueda de violaciones de umbral
1	2019	A new fault diagnosis method based on convolutional neural network and compressive sensing	2	✗	□	□	✗	□	□	✗	✗	✗	□	□	□	□	□	□	□
2	2017	Electrical load curve reconstruction required for demand response using compressed sensing techniques	18	□	✗	✗	□	✗	□	□	□	✗	□	□	□	✗	□	□	□
3	2020	A review of fault diagnosing methods in power transmission systems	6	✗	□	□	✗	□	□	✗	✗	✗	□	□	□	□	□	□	□
4	2015	Fault detection and classification in electrical power transmission system using artificial neural network	84	✗	□	□	✗	□	□	✗	✗	✗	□	□	□	□	□	□	□
5	2017	Artificial Neural Networks for Intelligent Fault Location on the 33-Kv Nigeria Transmission Line	6	✗	□	□	✗	□	□	✗	✗	✗	□	□	✗	□	□	✗	✗
6	2014	A Novel Method for Single and Simultaneous Fault Location in Distribution Networks	74	✗	□	□	✗	□	□	✗	✗	✗	□	□	✗	□	□	✗	□
7	2020	Electrical faults signals restoring based on compressed sensing techniques	1	✗	✗	✗	✗	□	□	✗	□	✗	□	□	□	✗	✗	□	□
8	2013	Artificial neural network approach for locating faults in power transmission system	9	✗	□	□	✗	□	□	✗	✗	✗	□	□	✗	□	□	□	□
9	2014	A survey on distributed compressed sensing: theory and applications	11	✗	✗	✗	□	✗	□	□	□	□	✗	□	□	✗	✗	□	□

10	2010	Fault Location on Power Networks	683	✗	□	□	✗	□	□	✗	✗	✗	□	□	□	□	□	□	□	✗			
11	2019	Alternative fault detection method in electrical power systems based on ARMA model	1	✗	□	□	□	□	□	✗	✗	□	□	□	□	□	□	□	□	✗	✗		
12	2017	Location of faults in power transmission lines using the ARIMA method	14	✗	□	□	□	□	□	✗	✗	□	□	□	□	□	□	□	□	✗	✗		
13	2010	Comparison of fourier & wavelet transform methods for transmission line fault classification	33	✗	□	□	✗	□	□	✗	✗	✗	□	□	□	□	□	□	□	□	✗	✗	
14	2006	A comparison of fourier transform and wavelet transform methods for detection and classification of faults on transmission lines	65	✗	□	□	✗	□	□	✗	✗	✗	□	□	□	□	□	□	□	□	✗	✗	
15	1982	Development of a New Type Fault Locator Using the One-Terminal Voltage and Current Data	787	✗	□	□	□	□	□	✗	✗	□	□	□	□	□	□	□	□	□	✗	✗	
16	2016	Traveling Wave-Based Fault Location on Half-Wavelength Transmission Lines	29	✗	□	□	□	□	□	✗	✗	□	□	□	□	□	□	□	□	□	✗	✗	
17	2017	Optimal fault location in transmission lines using hybrid method	24	✗	□	□	□	□	□	✗	✗	□	□	□	□	□	□	□	□	□	✗	✗	
18	2005	Fault location scheme for a multi-terminal transmission line using synchronized voltage measurements	201	✗	□	□	□	□	□	✗	✗	□	□	□	□	□	□	□	□	□	✗	✗	
19	2019	An intelligent strategy for faults location in distribution networks with distributed generation	26	✗	□	□	✗	□	□	✗	✗	✗	□	□	□	□	□	□	□	□	✗	✗	
20	2018	Fault diagnosis on electrical distribution systems based on fuzzy logic	25	✗	□	□	✗	□	□	✗	✗	✗	□	□	□	□	□	□	□	□	✗	✗	
21	2016	Application of Bayesian compressed sensing theory in single -phase-to-ground fault line selection of distribution network	343	✗	✗	✗	□	□	□	✗	✗	□	□	□	□	□	□	□	□	✗	✗	✗	□
22	2020	Detection of Arc Faults in PV Systems Using Compressed Sensing	0	✗	✗	✗	□	□	✗	✗	✗	□	□	□	□	✗	✗	✗	□	□	□	□	
23	2019	Electric Transmission System Fault Identification Using Artificial Neural Networks	1	✗	✗	✗	□	□	□	✗	✗	□	□	□	□	□	□	□	□	✗	□	□	□
24	2018	Fault Classification for Transmission Lines Based on Group Sparse Representation	4	✗	□	□	✗	□	□	✗	✗	□	□	✗	□	□	□	□	□	□	✗	✗	□
25	2014	Fault Location in Distribution Networks by Compressive Sensing	14	✗	✗	✗	□	□	□	✗	✗	□	□	□	□	✗	✗	✗	□	□	□	✗	
26	-	Estudio de los Algoritmos de reconstrucción en Compressed Sensing	0	✗	✗	✗	□	✗	□	□	□	□	✗	□	□	□	□	□	□	✗	✗	□	□
27	2016	Compressive Sensing in Signal Processing: Algorithms and Transform Domain Formulations	43	✗	✗	✗	□	✗	□	□	□	□	✗	□	□	□	□	□	□	✗	✗	□	□
28	-	Estudio de los Algoritmos de reconstrucción en Compressed Sensing	-	□	✗	✗	□	✗	□	□	□	□	✗	□	□	□	□	□	□	□	✗	□	□
29	2009	Sparse signal recovery using orthogonal matching pursuit (OMP)	4	□	✗	✗	□	✗	□	□	□	□	□	□	□	□	□	□	□	✗	□	✗	□

30	2014	Illustrated Compressed Sensing	-	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
31	2008	Introducción a la teoría del Compressive Sensing	1	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
				<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
				26	13	13	13	8	1	23	22	12	5	1	3	6	5	13	5	13	13

## 7.2 Resumen de Indicadores

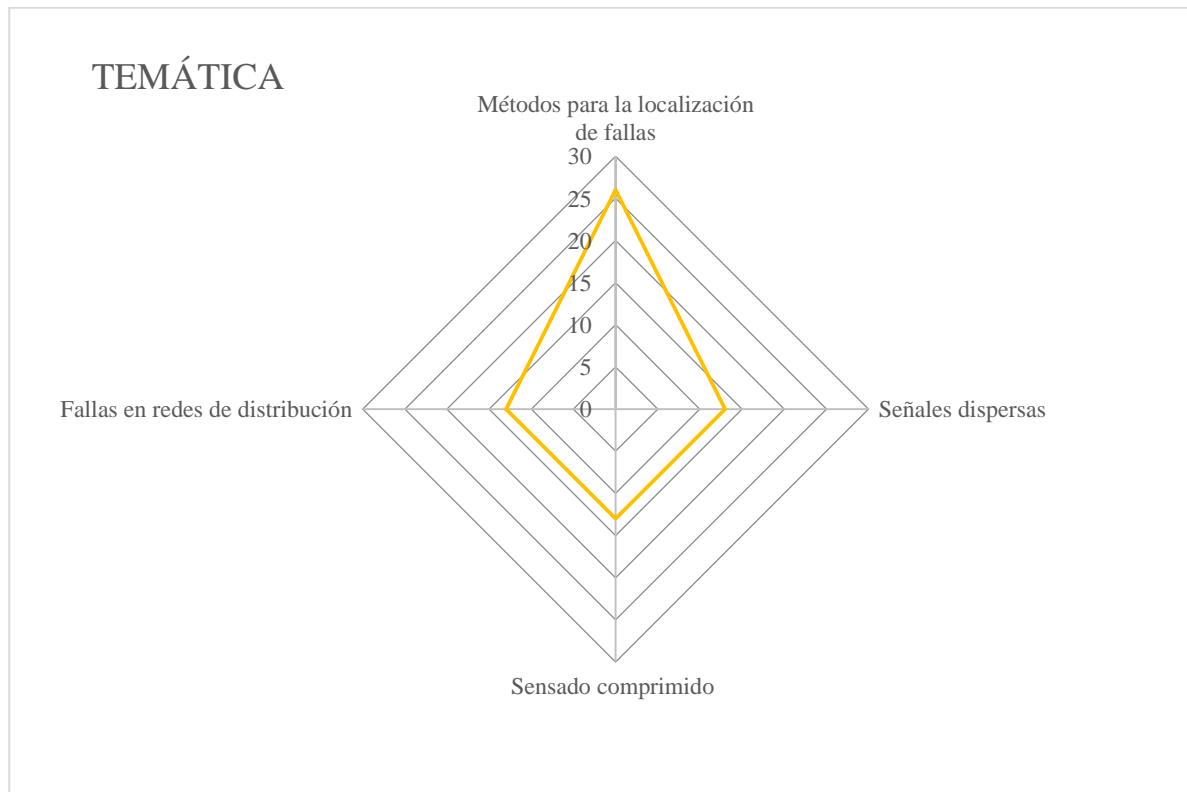



Figura 20. Resumen e indicador de la temática - Estado del arte





**Figura 21.** Indicador de formulación del problema - Estado del arte



**Figura 22.** Indicador de solución - Estado del arte