Reducción del tamaño de la zona bajo falla para determinar el desempeño de un localizador de fallas basado en vectores de soporte y aplicado a sistemas de distribución

Reduction of Size of the Under Fault Zone to Determine the Performance of a Fail Locator Based on Support Vectors and Applied to Distribution Systems

Juan José Mora Flórez

Ingeniero Electricista y Magíster en Ingeniería Eléctrica de Universidad Industrial de Santander (Colombia), Magíster en Tecnologías de la Información de la Universitat de Girona (España). Actualmente es docente programa en Ingeniería Eléctrica de la Universidad Tecnológica de Pereira.

jjmora@utp.edu.co

GERMÁN MORALES ESPAÑA

Ingeniero Electricista y estudiante de la Maestría en Ingeniería Eléctrica en la Universidad Industrial de Santander. Investigador del grupo de investigación en Sistemas de Energía Eléctrica (GISEL), de la misma universidad germanmora@uis.edu.co

Sandra Milena Pérez Londoño

Ingeniera Electricista y Magíster en Ingeniería Eléctrica de la Universidad Tecnológica de Pereira. Docente del Programa de Ingeniería Eléctrica en la Universidad Tecnológica de Pereira.

saperez@utp.edu.co

Clasificación del artículo: investigación

Fecha de aceptación: 30 de abril de 2007

Fecha de recepción: 15 de septiembre de 2006

Palabras clave: Localización de fallas, sistemas de distribución, clasificadores, vectores de soporte. Key words: Fault location, power distribution systems, classifiers, support vectors.

RESUMEN

Este artículo presenta una nueva alternativa para resolver el problema de localización de fallas en sistemas de distribución de energía eléctrica, a partir de la utilización de los algoritmos de aprendizaje representados por los clasificadores. Se analiza el desempeño de un localizador de fallas basado en una técnica de clasificación con vectores de soporte; el desempeño se prueba mediante la variación de la exigencia del clasificador para reconocer cada

vez una zona de falla más pequeña. Un ejemplo de aplicación con el modelo de un sistema real muestra que el localizador propuesto es altamente efectivo para resolver el problema, por lo que se obtienen aciertos superiores al 97% en la localización del nodo en falla, en el caso más exigente.

ABSTRACT

This paper shows a new perspective to solve the fault location problem in power distribution syste-

* * *

ms, by using learning algorithms here represented by classifiers. The performance of a support vector based fault locator, applied to power distribution systems, is analyzed there; it is tested by means of the exigency variation to recognize small faulted zones. From an application example which uses a model taken from a real power system, it is shown how the proposed approach is highly effective to solve the problem, having scores above 97% to locate the faulted node, in the most difficult case proposed.

1. Introducción

La calidad de energía eléctrica suele evaluarse en dos grandes áreas: en el suministro y en la atención al cliente. A la vez, la calidad del suministro se mide en función de dos variables: la forma de onda y la continuidad; este último aspecto es el considerado cuando se aborda el problema de localización de fallas [1] [2].

El problema de localización de fallas no es nuevo. Sin embargo, las investigaciones realizadas en esta área han abordado el tema en sistemas de transmisión y, a su vez, han considerado las características homogéneas de la línea, así como la posibilidad de contar con mediciones en ambos terminales; por otra parte, la disponibilidad de más equipos permiten localizar los sitios de falla con alta precisión. Por el contrario, el problema de localización de fallas en sistemas de distribución es complejo y aún no está resuelto [3] [4].

La complejidad de la localización de fallas en sistemas de distribución se debe principalmente a la presencia de conductores no homogéneos, cargas intermedias, derivaciones laterales, compensación capacitiva y desbalances del sistema y la carga. Además, estos sistemas sólo cuentan con medidas en la subestación y, algunas veces, con el modelo simplificado del sistema [5] [6]. Los principales esfuerzos de investigación se han orientado a los métodos clásicos de localización de falla, que estiman la reactancia a partir de las medidas de tensión y corriente en la sub-

estación; la reactancia se relaciona con la distancia al sitio de falla a partir del uso del modelo. Sin embargo, los problemas de estos métodos son:

- La necesidad de disponer de un buen modelo del sistema.
- La múltiple estimación del sitio de falla, dado que la distancia asociada con la reactancia estimada puede coincidir con muchos sitios en un sistema ramificado. Algunos de los más importantes métodos basados en la estimación de la reactancia se presentan en [5] [7-10].

Como contribución a la solución de este problema, en este artículo se propone complementar los métodos clásicos de localización mediante una técnica de clasificación basada en vectores de soporte, para reducir la incertidumbre asociada a la localización de la falla y así evitar el problema de la múltiple estimación [11-12]. Para localizar la zona de falla, esta alternativa sólo usa las medidas de tensión y corriente en la subestación. El artículo también plantea un análisis del método y su capacidad de localizar fallas en zonas cada vez más pequeñas, para así poder mantener altos índices de desempeño.

En el segundo apartado de este documento se describe la metodología propuesta para implementar y probar el localizador de fallas y en el tercero se presenta una breve descripción del clasificador basado en vectores de soporte. Las pruebas con un sistema prototipo, las diferentes alternativas de zonificación del sistema y el análisis de los resultados

se muestran en el cuarto apartado. Finalmente, en la última parte se presentan las conclusiones derivadas de esta investigación.

Metodología para la aplicación de un clasificador al problema de la localización de fallas

A continuación se presenta la metodología propuesta para localizar la región probable de falla y la aplicación posterior del clasificador. El proceso está dividido en cinco etapas generales que se presentan en el diagrama 1.

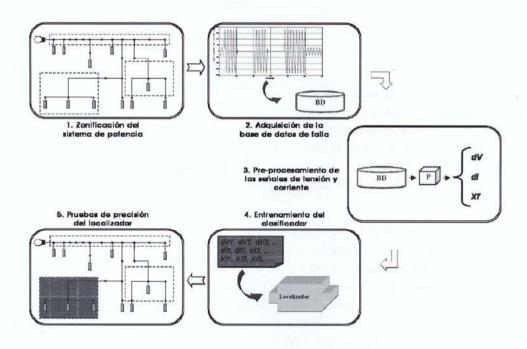


Diagrama 1. Etapas metodológicas para la aplicación del localizador de fallas basado en técnicas de clasificación

2.1. Zonificación de la red

Dado que se propone la utilización de un método de clasificación, el problema es más sencillo si el sistema de potencia se divide en zonas a las que se asigna un conjunto de descriptores de entrada¹. El criterio de zonificación debe basarse en la división del sistema de potencia, de tal manera que la identificación de una zona como la más probable de falla permita reducir el tiempo de localización de la falla al equipo de mantenimiento de la red.

Como recomendación básica, una zona no debe contener más de un lateral con las mismas fases, para evitar el problema de la múltiple estimación presentada por los métodos clásicos referenciados en la introducción. En consecuencia, los criterios de zonificación son: topología de la red, localización de protecciones, longitud de alimentadores, importancia del ramal, disponibilidad de datos de fallas para entrenar el clasificador y, finalmente, las prácticas de la empresa. En este caso, para mostrar el desempeño del clasificador ante los diferentes

¹ Las clases corresponden a zonas en falla.

escenarios propuestos se presentan varias alternativas de zonificación.

2.2. Adquisición de la base de datos de falla

Es necesario que cuando un evento de falla ocurra en el sistema de potencia puedan registrarse las señales de tensión y corriente medidas en la subestación. A partir de estos registros se debe crearse una base de datos en la cual cada registro se asocie con el tipo de falla y su localización. La base de datos puede ser obtenida mediante una combinación de registros reales de falla o empleando un software especializado para realizar simulaciones con un circuito base que es modelado con los parámetros del circuito real. En este caso se realizó una simulación extensiva de fallas usando Matlab \Re y *Alternative Transients Program* (ATP) [13]. Las resistencias de falla para simulación se encuentran en un rango entre 0 y 40 Ω [14].

2.3. Pre-procesamiento de la señal

Esta etapa consiste en la obtención del conjunto de descriptores que representan la falla. Cada conjunto de descriptores está asociado con una etiqueta que corresponde a la zona donde ocurrió la falla. Los principales descriptores usados se toman de las señales de fase y son la diferencia entre el valor eficaz entre los estados estables de falla y pre-falla de tensión (dV), corriente (dI) y la reactancia vista desde la subestación (Xf). Además de los anteriores descriptores, los valores de línea se emplean para el cálculo de la variación de la tensión (dVL), la corriente (dIL) y la reactancia (XfL).

En este caso se consideraron sólo descriptores de fácil obtención, de tal forma que la propuesta final no esté condicionada por las limitaciones de equipos. Los descriptores aquí presentados se calculan de una forma simple, para evitar la incertidumbre asociada al proceso de estimación de las magnitudes eléctricas.

2.4. Entrenamiento del clasificador

La primera parte de esta etapa es la selección del conjunto de descriptores para el proceso de entrenamiento. Para esta selección se analizan las combinaciones de descriptores constituyentes del conjunto de entrenamiento que posibilitan una clasificación adecuada y, por tanto, la localización correcta de la zona de ocurrencia de la falla. En este caso se presentan los resultados de la combinación de dos, tres y cuatro descriptores; a partir de las pruebas de cada combinación posible de descriptores se selecciona el conjunto cuyos resultados de precisión son más altos. La precisión se usa como medición del desempeño del localizador y se calcula como se muestra en la ecuación (1).

En el clasificador se aplicó una estrategia de entrenamiento del tipo supervisado, con la que se obtuvieron resultados adecuados para resolver el problema planteado. En el entrenamiento del localizador basado en vectores de soporte se utilizó la validación cruzada y la búsqueda en malla, para encontrar el mejor valor de C y del parámetro σ del kernel RBF [15].

2.5. Pruebas de precisión del localizador basado en la técnica de clasificación

Las pruebas de precisión se realizan para estimar el comportamiento de la técnica de clasificación ante datos que no fueron usados en el proceso de entrenamiento. Los datos de prueba deben corresponder a los mismos descriptores y recibir el mismo procesamiento que el realizado para los datos usados en el proceso de entrenamiento. La precisión del método se calcula como se presenta en (1).

Precisión = Número de los resistros clasificados correctamente

Número de registros

La medida de la precisión en el reconocimiento de las zonas en falla es un buen indicador que permite predecir el comportamiento del clasificador ante nuevas situaciones; este parámetro se tomará como indicador para seleccionar la mejor alternativa que permita abordar el problema de localización de fallas.

Clasificadores basado en vectores de soporte

En problemas de clasificación simples, la teoría estadística de aprendizaje puede identificar con precisión los factores por tener en cuenta para un aprendizaje exitoso. No obstante, las aplicaciones reales demandan el uso de modelos y algoritmos más complejos (por ejemplo redes neuronales, técnicas bayesianas, etc.) que son difíciles de analizar.

A diferencia del método bayesiano, las máquinas de soporte vectorial (SVM o Support Vector Machines) tienen la ventaja de no requerir ningún tipo de hipótesis sobre la densidad de probabilidad de los rasgos; asimismo, frente a las redes neuronales son convenientes, en términos de la dimensionalidad del problema. La arquitectura de las SVM sólo depende de la constante de penalización C y del parámetro σ de la función kernel (en el caso RBF), como se muestra en el apartado 3.3 [16]. Esta facilidad de configuración evita la selección de requerimientos sobre parámetros exclusivos de arquitectura, por ejemplo: número de nodos y capas y tipo de conexión entre capas, entre otros característicos de las redes neuronales.

3.1. Clasificación lineal

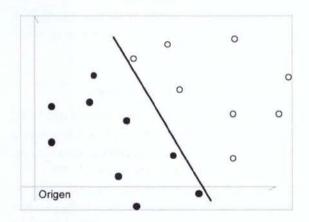
Los clasificadores de soporte vectorial están basados en hiperplanos que separan los datos de entrenamiento en dos subgrupos, cada uno con una etiqueta propia. Entre todos los posibles planos de separación entre las dos clases etiquetadas, $y \in \{-1,+1\}$ existe un único hiperplano de separación óptimo (OSH), de tal forma que la distancia entre el hiperplano óptimo y el patrón de entrenamiento más

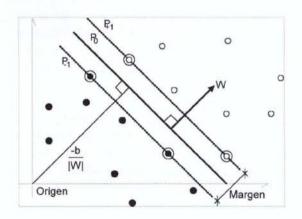
cercano sea máxima, con la intención de forzar la generalización de la máquina de aprendizaje [16-17]. El hiperplano de separación óptimo (P_0) se expresa de la siguiente forma:

$$P_0: (\mathbf{w} \cdot \mathbf{x}) + b = 0 \tag{2}$$

En (2) w es un vector perpendicular al hiperplano (OSH); x son las variables de entrada o conjunto de descriptores $\{x_p, \dots, x_n\}$ y b es el término independiente de la ecuación de un hiperplano.

En este problema se desea maximizar el margen, como se presenta en la gráfica 1.





Gráfica 1. Hiperplanos que separan correctamente los datos. El OSH de la derecha tiene un mayor margen de separación entre clases, luego se espera una mejor generalización

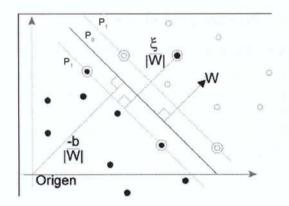
La función de decisión $f_{w,b}(\vec{x}_i) = \vec{y}_i$ puede definirse como el signo que resulta de evaluar un dato en la ecuación del OSH (2), como se presenta en (3).

$$f_{wb}(\mathbf{x}_i) = sign\left[(\mathbf{w} \cdot \mathbf{x}_i) + b \right] \tag{3}$$

Si existe un hiperplano, como se muestra en la gráfica 1, se dice que los datos son *linealmente separables*.

3.2. Clasificación con margen débil

En los casos en que existen datos de entrada erróneos, ruido o alto solapamiento de clases en los datos de entrenamiento, el hiperplano clasificador óptimo se puede afectar. Por esta razón se cambia un poco la perspectiva y se busca el mejor hiperplano clasificador que pueda tolerar ruido en los datos de entrenamiento (gráfica 2), introduciendo la variable de relajación (ξ_i) que se presenta en la ecuación (4).



Gráfica 2. Hiperplano de separación permitiendo ruido

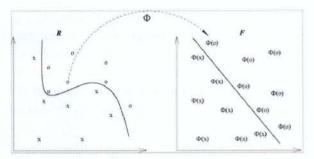
$$\xi_i \ge 0, \forall i$$
 (4)

Para definir en forma única el hiperplano óptimo (forma canónica) se deben añadir las restricciones, como se presenta en (5).

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \ge 1 - \xi_i, \forall i$$
 (5)

3.3. Caso no lineal

Los clasificadores basados en vectores de soporte no lineales tienen la posibilidad de mapear el espacio de entrada en otro de representación de dimensión alta. En este nuevo espacio los datos son linealmente separables y pueden construir un OSH sobre él; su representación en el espacio de entrada es una función de separación no lineal (gráfica 3).



Gráfica 3. Los clasificadores basados en vectores de soporte no lineales mapean el espacio de entrada en otro de representación de dimensión alta y luego construyen un OSH sobre este último, cuya representación en el espacio de entrada es una función de separación no lineal

La generalización de la SVM a funciones de decisión no lineales consiste en mapear el espacio de entrada sobre un espacio de representación de dimensión alta usando una función no lineal elegida a priori. Esta función es la $kernel(\Phi)$, que traza los datos de entrada $\overline{x_i} \in R^N$ en otro espacio de mayor dimensión en el que esté definido el producto punto, conocido como espacio característico (F), como se define en (6) [18].

$$\Phi: \mathbb{R}^{N} \to F \tag{6}$$

Así, de la función en la ecuación (2), que depende del producto punto de los vectores en el espacio de entrada, se pasa a una función g(x), que depende del producto punto de los vectores en el espacio característico, como se presenta en (7).

$$g(\vec{x}) = \langle \Phi(\vec{w}), \Phi(\vec{x}) \rangle + b$$
 (7)

A continuación se debe definir una función (k) que sea el producto punto de los vectores en el espacio característico, como se presenta en (8).

$$k(\vec{u}, \vec{v}) = \langle \Phi(\vec{u}), \Phi(\vec{v}) \rangle$$
 (8)

Si se considera que (F) es de alta dimensión, el lado derecho de la ecuación (8) es costoso en términos computacionales. Sin embargo, existe una función kernel (K) que se puede evaluar eficazmente y se puede demostrar que un trazado de (Φ) corresponde a un espacio que comprende todos los productos punto [19]. Los kernels más utilizados son el polinomial (9), el de función de base radial (RBF) presentado en (10), y el sigmoide, presentado en (11).

$$k(\overrightarrow{u},\overrightarrow{v}) = \left(\langle \overrightarrow{u},\overrightarrow{v} \rangle + c\right)^d \tag{9}$$

$$k(\vec{u}, \vec{v}) = e^{\left(-\frac{\|\vec{u}-\vec{v}\|^2}{\sigma^2}\right)}$$
 (10)

$$k(\vec{u}, \vec{v}) = \tanh(\kappa(\vec{u}, \vec{v}) + \Theta)$$
 (11)

En resumen, el hiperplano óptimo en forma canónica de margen débil se halla solucionando el problema de optimización restringida dado por la ecuación (12), sujeto a (4) y (5).

$$\min_{w,b} \frac{1}{2} (\mathbf{w} \cdot \mathbf{w}) + C \sum_{i=1}^{n} \xi_i$$
 (12)

En (12) *C* es una constante de penalización al problema de minimización. Si se utilizan los multiplicadores de *Lagrange* y el teorema dual de *Wolfe* se obtiene el problema final de optimización (problema de optimización cuadrática):

$$\max_{\alpha} \sum_{i=1}^{N} \alpha_{i} - \frac{1}{2} \sum_{i,j=1}^{N} \alpha_{i} \alpha_{j} y_{i} y_{j} k \left(\vec{x}_{i}, \vec{x}_{j} \right)$$
 (13)

Sujeto a:
$$0 \le \alpha_i \le C, \forall i \text{ y } \sum_{i=1}^N \alpha_i y_i = 0$$

La ecuación del OSH y la función decisión puede expresarse como (14) y (15).

$$g(\bar{x}) = \sum_{i,j=1}^{N} (\alpha_i y_i k(\bar{x}_i, \bar{x})) + b$$
 (14)

$$f(\bar{\mathbf{x}}) = \operatorname{sign}\left(\sum_{i,j=1}^{N} (\alpha_{i} y_{j} k(\bar{\mathbf{x}}_{i}, \bar{\mathbf{x}})) + b\right)$$
 (15)

Para resolver el problema de multiclasificación (más de dos clases), a partir de un conjunto de funciones biclasificadoras se construye una función clasificadora global. Técnicas disponibles de descomposición y reconstrucción permiten a los clasificadores basados en vectores de soporte manejar problemas de multiclasificación con mayor simplicidad y/o menor tiempo de respuesta que una SVM generalizada para multiclasificación [12].

4. Pruebas y resultados

4.1. Sistema prototipo de pruebas

El sistema de distribución seleccionado para las pruebas es el modelo de un alimentador de 25 kV de *Saskatown Power and Light* de *Saskatchewan* (Canadá), presentado en [5]. El diagrama unifilar del sistema se presenta a continuación.

El circuito del diagrama 2 ha sido utilizado para pruebas de distintos métodos de localización de fallas [13] [20].

4.2. Descripción de las pruebas

Diferentes zonificaciones del sistema son propuestas para realizar las pruebas de desempeño del localizador, de tal forma que existan escenarios exigentes desde el punto de vista de clasificación. Se definen cinco escenarios de zonificación diferentes; en ellos se aprecia la variación del número de nodos por zona y la capacidad de predecir la zona en falta. En la tabla 1 se muestran los escenarios de zonificación propuestos.

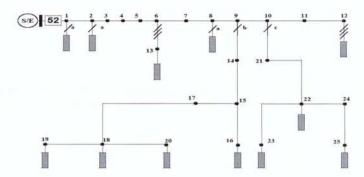


Diagrama 2. Diagrama unifilar del sistema de pruebas

Número de zona –	Escenarios de clasificación para localización de fallas								
	Uno	Dos	Tres	Cuatro	Cinco				
1	1, 2, 3, 4	1, 2	1, 2	1. 2	1				
2	5, 6, 13	3, 4	3, 4	3, 4	2				
3	8, 9, 10, 11, 12	5,6,13	5,6,13	5,6	3				
4	15, 16	8,9	8,9	13	4				
5	18, 19, 20	10,11,12	10,11	8,9	5				
6	22, 23	15, 16	12	10,11	6				
7	24, 25	18, 19	15, 16	12	8				
8		20	18, 19	15	9				
9	100	22, 23	20	16	10				
10	100	24, 25	22	18	1.1				
11			23	19	12				
12			24	20	13				
13			0.5	22	1.5				
14				23	16				
15				24	18				
16				25					
1.7					20				
18					22				
19					23				
20					24				
21					25				

Tabla 1. Listado de barras de las zonas en cada uno de los cinco escenarios de prueba propuestos

Las barras números 7, 14, 17 y 21 no fueron incluidas, porque en el sistema original corresponden a las barras aguas abajo de la protección localizada en las barras 6, 9, 15 y 10, respectivamente. En otras palabras, desde el punto de vista circuital son el mismo nodo, antes que actúen las protecciones.

Para cada escenario, la cantidad de datos de entrenamiento corresponden a 225 registros de falla (24% del total de datos); asimismo, los datos utilizados para prueba fueron 720 (el 76% de los datos). Los registros de prueba no fueron utilizados en el proceso de entrenamiento del localizador.

4.3. Resultados de las pruebas

A continuación se presentan los resultados de las pruebas realizadas al localizador de fallas basado en MSV, en las circunstancias expuestas en el apartado anterior. Se seleccionó el caso monofásico por ser el más crítico y la falla más frecuente; para los otros tipos de falla los resultados de precisión son superiores al 98%.

En las tablas 2 a 6 se muestran los resultados para todas las posibles combinaciones de grupos de dos, tres o cuatro descriptores, en caso del sistema dividido en siete, diez, trece, dieciséis y veintiuna zonas. Esta combinación de descriptores se realiza

para determinar el mejor conjunto de entrada para la localización de la falta mediante el indicador de precisión. Los resultados de precisión para cada caso se obtienen de la aplicación de la ecuación (1).

4.3.1. Escenario 1. Sistema dividido en siete zonas

Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba
dV, dVL	0,9792	dIL, XfL	0,9944	dVL, dl, Xf	0,9986	dV, dVL, dIL, Xf	0,9917
dV, dI	0,9819	Xf, XfL	1,0000	dVL, dl, XfL	1,0000	dV, dVL, dIL, XfL	0,9972
dV, dIL	0,9667	dV, dVL, dI	0,9819	dVL, dIL, Xf	1,0000	dV, dVL, Xf, XfL	1,0000
dV, Xf	1,0000	dV, dVL, dIL	0,9819	dVL, dIL, XfL	0,9903	dV, dI, dIL, Xf	1,0000
dV, XfL	0,9889	dV, dVL, Xf	0,9986	dVL, Xf, XfL	0,9931	dV, dl, dlL, XfL	0,9875
dVL, dl	0,9903	dV, dVL, XfL	0,9806	dl, dlL, Xf	1,0000	dV, dI, Xf, XfL	1,0000
dVL, dIL	0,9361	dV, dl, dlL	0,9806	dl, dlL, XfL	0,9986	dV, dIL, Xf, XfL	0,9944
dVL, Xf	0,9889	dV, dI, Xf	1,0000	dl, Xf, XfL	1,0000	dVL, dl, dlL, Xf	1,0000
dVL, XfL	0,9972	dV, dI, XfL	0,9861	dIL, Xf, XfL	1,0000	dVL, dl, dlL, XfL	1,0000
dl, dlL	0,9750	dV, dIL, Xf	1,0000	dV, dVL, dl, dlL	0,9819	dVL, dl, Xf, XfL	1,0000
dl, Xf	1,0000	dV, dIL, XfL	0,9903	dV, dVL, dI, Xf	0,9972	dVL, dIL, Xf, XfL	1,0000
dl, XfL	0,9903	dV, Xf, XfL	0,9986	dV, dVL, dI, XfL	0,9875	dl, dlL, Xf, XfL	1,0000
dIL, Xf	1,0000	dVL, dl, dlL	0,9792				

Tabla 2. Resultados de precisión en la prueba con un sistema dividido en siete zonas

4.3.2. Escenario 2. Sistema dividido en diez zonas

Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba
dV, dVL	0,9683	dIL, XfL	0,9667	dVL, dl, Xf	0,9722	dV, dVL, dIL, Xf	0,9694
dV, dl	0,9597	Xf, XfL	0,9778	dVL, dl, XfL	0,9667	dV, dVL, dIL, XfL	0,9708
dV, dIL	0,9444	dV, dVL, dI	0,9597	dVL, dIL, Xf	0,9694	dV, dVL, Xf, XfL	0,9778
dV, Xf	0,9708	dV, dVL, dIL	0,9597	dVL, dIL, XfL	0,9708	dV, dl, dlL, Xf	0,9764
dV, XfL	0,9625	dV, dVL, Xf	0,9722	dVL, Xf, XfL	0,9708	dV, dl, dlL, XfL	0,9694
dVL, dI	0,9681	dV, dVL, XfL	0,9681	dl, dlL, Xf	0,9778	dV, dI, Xf, XfL	0,9667
dVL, dIL	0,9125	dV, dl, dlL	0,9486	dl, dlL, XfL	0,9681	dV, dIL, Xf, XfL	0,9722
dVL, Xf	0,9667	dV, dl, Xf	0,9778	dl, Xf, XfL	0,9778	dVL, dl, dlL, Xf	0,9778
dVL, XfL	0,9167	dV, dI, XfL	0,9653	dIL, Xf, XfL	0,9778	dVL, dl, dlL, XfL	0,9639
dl, dlL	0,9583	dV, dIL, Xf	0,9750	dV, dVL, dI, dIL	0,9597	dVL, dl, Xf, XfL	0,9778
dl, Xf	0,9778	dV, dIL, XfL	0,9611	dV, dVL, dI, Xf	0,9750	dVL, dIL, Xf, XfL	0,9778
dl, XfL	0,9681	dV, Xf, XfL	0,9778	dV, dVL, dI, XfL	0,9736	dl, dlL, Xf, XfL	0,9736
dIL, Xf	0,9778	dVL, dl, dlL	0,9569				

Tabla 3. Resultados de precisión en la prueba con un sistema dividido en diez zonas

4.3.3. Escenario 3. Sistema dividido en trece zonas

Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba
dV, dVL	0,9681	dIL, XfL	0,9750	dVL, dI, Xf	0,9778	dV, dVL, dIL, Xf	0,9750
dV, dI	0,9569	Xf, XfL	0,9750	dVL, dl, XfL	0,9667	dV, dVL, dIL, XfL	0,9778

Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba
dV, dIL	0,9458	dV, dVL, dI	0,9569	dVL, dIL, Xf	0,9778	dV, dVL, Xf, XfL	0,9764
dV, Xf	0,9778	dV, dVL, dIL	0,9597	dVL, dIL, XfL	0,9708	dV, dI, dIL, Xf	0,9708
dV, XfL	0,9667	dV, dVL, Xf	0,9778	dVL, Xf, XfL	0,9778	dV, dI, dIL, XfL	0,9736
dVL, dl	0,9486	dV, dVL, XfL	0,9681	dl, dlL, Xf	0,9778	dV, dI, Xf, XfL	0,9736
dVL, dIL	0,9264	dV, dI, dIL	0,9583	dl, dlL, XfL	0,9764	dV, dIL, Xf, XfL	0,9778
dVL, Xf	0,9778	dV, dI, Xf	0,9778	dl, Xf, XfL	0,9778	dVL, dl, dlL, Xf	0,9750
dVL, XfL	0,9431	dV, dI, XfL	0,9667	dIL, Xf, XfL	0,9778	dVL, dl, dlL, XfL	0,9778
dl, dlL	0,9542	dV, dIL, Xf	0,9764	dV, dVL, dI, dIL	0,9583	dVL, dl, Xf, XfL	0,9778
dl, Xf	0,9778	dV, dIL, XfL	0,9778	dV, dVL, dI, Xf	0,9750	dVL, dIL, Xf, XfL	0,9778
dl, XfL	0,9764	dV, Xf, XfL	0,9778	dV, dVL, dI, XfL	0,9667	dl, dlL, Xf, XfL	0,9750
dIL, Xf	0,9778	dVL, dI, dIL	0,9042				

Tabla 4. Resultados de precisión en la prueba con un sistema dividido en trece zonas

4.3.4. Escenario 4. Sistema dividido en dieciséis zonas

Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba
dV, dVL	0,9681	dIL, XfL	0,9750	dVL, dl, Xf	0,9764	dV, dVL, dIL, Xf	0,9722
dV, dl	0,9583	Xf, XfL	0,9750	dVL, dl, XfL	0,9778	dV, dVL, dIL, XfL	0,9750
dV, dIL	0,9597	dV, dVL, dI	0,9569	dVL, dIL, Xf	0,9778	dV, dVL, Xf, XfL	0,9778
dV, Xf	0,9556	dV, dVL, dIL	0,9597	dVL, dIL, XfL	0,9764	dV, dI, dIL, Xf	0,9764
dV, XfL	0,9764	dV, dVL, Xf	0,9722	dVL, Xf, XfL	0,9778	dV, dI, dIL, XfL	0,9708
dVL, dl	0,9569	dV, dVL, XfL	0,9681	dl, dlL, Xf	0,9778	dV, dI, Xf, XfL	0,9736
dVL, dIL	0,9236	dV, dI, dIL	0,9722	dl, dlL, XfL	0,9764	dV, dIL, Xf, XfL	0,9778
dVL, Xf	0,9778	dV, dI, Xf	0,9778	dl, Xf, XfL	0,9778	dVL, dl, dlL, Xf	0,9569
dVL, XfL	0,9750	dV, dI, XfL	0,9778	dIL, Xf, XfL	0,9778	dVL, dl, dlL, XfL	0,9750
dl, dlL	0,9556	dV, dIL, Xf	0,9764	dV, dVL, dI, dIL	0,9583	dVL, dI, Xf, XfL	0,9778
dl, Xf	0,9778	dV, dIL, XfL	0,9778	dV, dVL, dI, Xf	0,9750	dVL, dIL, Xf, XfL	0,9778
dl, XfL	0,9764	dV, Xf, XfL	0,9778	dV, dVL, dI, XfL	0,9667	dl, dlL, Xf, XfL	0,9778
dIL, Xf	0,9778	dVL, dl, dlL	0,9597				

Tabla 5. Resultados de precisión en la prueba con un sistema dividido en dieciséis zonas

4.3.5. Escenario 5. Sistema dividido en veintiún zonas, un nodo por zona

Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba	Conjunto de descriptores	Precisión en la prueba
dV, dVL	0,9389	dIL, XfL	0,9583	dVL, dl, Xf	0,9722	dV, dVL, dIL, Xf	0,9653
dV, dl	0,9597	Xf, XfL	0,9750	dVL, dl, XfL	0,9667	dV, dVL, dIL, XfL	0,9611
dV, dIL	0,9694	dV, dVL, dI	0,9597	dVL, dIL, Xf	0,9778	dV, dVL, Xf, XfL	0,9778
dV, Xf	0,9736	dV, dVL, dIL	0,9569	dVL, dIL, XfL	0,9611	dV, dI, dIL, Xf	0,9764
dV, XfL	0,9681	dV, dVL, Xf	0,9764	dVL, Xf, XfL	0,9708	dV, dI, dIL, XfL	0,9639
dVL, dl	0,9681	dV, dVL, XfL	0,9583	dl, dlL, Xf	0,9778	dV, dI, Xf, XfL	0,9750
dVL, dIL	0,9569	dV, dI, dIL	0,9583	dl, dlL, XfL	0,9681	dV, dIL, Xf, XfL	0,9708

dIL, Xf	0,9750	dVL, dl, dlL	0,9569				
dl, XfL	0,9597	dV, Xf, XfL	0,9778	dV, dVL, dI, XfL	0,9708	dl, dlL, Xf, XfL	0,977
dl, Xf	0,9778	dV, dIL, XfL	0,9764	dV, dVL, dI, Xf	0,9708	dVL, dIL, Xf, XfL	0,9708
dl, dlL	0,8889	dV, dIL, Xf	0,9681	dV, dVL, dI, dIL	0,9583	dVL, dI, Xf, XfL	0,9778
dVL, XfL	0,9375	dV, dI, XfL	0,9583	dIL, Xf, XfL	0,9625	dVL, dI, dIL, XfL	0,9569
dVL, Xf	0,9667	dV, dI, Xf	0,9778	dl, Xf, XfL	0,9750	dVL, dl, dlL, Xf	0,9778

Tabla 6. Resultados de precisión en la prueba con un sistema altamente zonificado. Un nodo por zona

4.4. Análisis de resultados

Los resultados de las pruebas en los diferentes escenarios de zonificación (tablas 2 a 6) permiten apreciar que el desempeño del localizador disminuye a medida que el problema se hace más exigente, es decir, cuando hay más zonas con menos nodos en cada una de ellas. Como se observa en la tabla 2, cuando el circuito se divide en siete zonas, con algunas combinaciones de descriptores se obtiene un desempeño en la prueba del 100% (ninguna de las 720 fallas fue identificada en una zona errónea). Cuando se aumenta el número de zonas los errores aumentan; sin embargo, los resultados menos satisfactorios siempre son superiores al 88%, con un promedio general del 97,27%.

En promedio, las combinaciones de descriptores de mejor desempeño son aquellas en las que está presente la reactancia de la falla vista desde la subestación (Xf). En este caso, las combinaciones con mejores resultados promedio son dI-Xf, dV-dI-Xf, dV-dVL-Xf-XfL y dVL-dI-Xf-XfL; su desempeño promedio es del 98,22%. El peor promedio se registra con la combinación de dVL-dIL, con la cual el desempeño es del 93,11%.

Finalmente, en los resultados se puede observar que el aumento de descriptores en la entrada no siempre genera un mejor desempeño del localizador; la combinación *dI-Xf* es la mejor, pero otras que incluyen este par de descriptores tienen un desempeño inferior. Este es un aspecto que aún se encuentra en discusión en el campo de los clasificadores basados en vectores de soporte.

5. Conclusiones

- Se ha presentado un localizador de fallas para sistemas de distribución basado vectores de soporte. Luego de caracterizar el sistema se presentan los descriptores utilizados para entrenar y validar el localizador ante diferentes escenarios.
- Los resultados obtenidos muestran el alto desempeño del método aquí propuesto para estimar la localización de la falla. El localizador desarrollado registra buenos resultados en diferentes escenarios, incluso en la prueba más exigente que asigna una zona a cada uno de los nodos del sistema de prueba.
- Mediante este tipo de aplicaciones puede reducirse el tiempo de restauración del sistema fallado al aumentar el valor de los índices que miden la continuidad del servicio de energía eléctrica y, en consecuencia, al reducir los pagos por compensaciones debidas a la deficiente calidad del servicio.

Referencias bibliográficas

- Bollen, M. (2000). "Understanding Power Quality Problems: Voltage Sags and Interruptions". IEEE Press.
- [2] Mora, J. (2003). Voltage Sag. Characterization and Classification for Diagnosis in Electric Power Quality Domain. Master Thesis. Tutor J. Colomer. University of Girona, Spain.
- [3] IEEE Std C37.114. (2004). IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines. Power System Relaying Committee.
- [4] Saha, M., Rosolowski E. (2002). Method and Device of Fault Location for Distribution Networks, 2002. US Patent number 6,483,435 B2.

- [5] Das, R. (1998). Determining the Locations of Faults in Distribution Systems. Canada, 206 p. Doctoral dissertation, University of Saskatchewan Saskatoon.
- [6] Phadke, A., Horowitz, S. (1995). Power System Relaying. Research Studies Press. Baldock, England.
- [7] Girgis, A., Fallon, C., Lubkerman, D. (1993). "A Fault Location Technique for Rural Distribution Feeders". *IEEE Transactions on Industry and Applications*. Vol. 26, pp. 1170-1175.
- [8] Novosel, D., Hart, D., Myllymaki J. (1998). System for Locating Faults and Estimating Fault Resistance in Distribution Networks with Tapped Loads. US Patent number 5,839,093.
- [9] Aggarwal, R. K., Aslan, Y., and Johns, A. T. (1997). "An Interactive Approach to Fault Location on Overhead Distribution Lines with Load Taps". *IEEE Developments in Power System Protection*. Conference Publication (434), pp. 184-187.
- [10] Son Choi, M., Lee, S., Lee, D. and Jin, B. (2004). "A New Fault Location Algorithm Using Direct Circuit Analysis for Distribution Systems". *IEEE Transactions* on Power Systems, pp. 35-41.
- [11] Mora, J. (2006). Localización de faltas en sistemas de distribución de energía eléctrica usando métodos basados en el modelo y métodos basados en el conocimiento. Tesis Doctoral. University of Girona, Spain.
- [12] Gómez, A., Morales, G. (2005). Estudio e implementación de una herramienta basada en máquinas de soporte vectorial aplicada a la localización de fallas en

- sistemas de distribución. Trabajo de grado Universidad Industrial de Santander.
- [13] Mora, J., Meléndez, J., Bedoya, J. (August 2006). "Extensive Events Database Development Using ATPU and Matlab to Fault Location in Power Distribution Systems". Proceedings of 2006 IEEE PES Transmission and Distribution Conference and Exposition, Caracas, 2006.
- [14] Dagenhart, J. B. (2000). "The 40- Ground-Fault Phenomenon". *IEEE Transactions on Industry Ap*plications, Vol. 36 (1), pp. 30-32.
- [15] Lin, C., Chang, C., and Hsu, C. (2004). A Practical Guide to Support Vector Classification. National Taiwan University.
- [16] Burges, C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition. Data Mining and Knoledge Discovery, pp. 121-167.
- [17] Vapnik, V. (2000). The Nature of Statistical Learning Theory. 2nd ed., Springer Verlag.
- [18] Boser, B., Guyon, I., Vapnik, V. (1992). "A Training Algorithm for Optimal Margin Classifier". Proc V ACM Workshop on Computational Learning Theory, pp. 144-152.
- [19] Smola, B. (2002). Learning with Kernels Support Vector Machines, Regularization, Optimization and Beyond. The MIT Press, Cambridge.
- [20] Mora, J., Meléndez, J., Carrillo, G. (2006). Comparison of Impedance Based Fault Location Methods for Power Distribution System. Electric Power System Research (accepted paper).