

INFLUENCIA DE LA VARIACIÓN EN LA CARGA Y DEL TAMAÑO DE LA ZONA EN LA PRECISIÓN DE UN LOCALIZADOR DE FALLAS PARA CIRCUITOS DE DISTRIBUCIÓN

GERMÁN ANDRÉS MORALES ESPAÑA

Ingeniero Electricista

Investigador Grupo GISEL

Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones

Universidad Industrial de Santander.

german.morales.e@gmail.com

HERMANN RAÚL VARGAS TORRES

Ingeniero Electricista, Dr.

Profesor Asociado

Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones

Universidad Industrial de Santander.

hrvargas@uis.edu.co

JUAN JOSÉ MORA FLÓREZ

Ingeniero Electricista, Ph.D.

Profesor Auxiliar

Programa de Ingeniería Eléctrica

Universidad Tecnológica de Pereira.

jjmora@utp.edu.co

Fecha Recepción: 12/02/2007

Fecha Aceptación: 21/05/2007

RESUMEN

Un tema de creciente interés para los operadores de red y para los usuarios, es la calidad de la energía eléctrica. El producto mismo y la atención al cliente son los principales aspectos considerados. La calidad del producto, significa satisfacer condiciones de calidad de onda (o de la potencia), y de continuidad del servicio de energía eléctrica. Este último aspecto es el considerado cuando se aborda el problema de localización de fallas.

En este artículo se presenta un análisis de un método de localización de fallas para sistemas de distribución, desarrollado con un clasificador basado en vectores de soporte. Este localizador se entrena con datos tomados a condición nominal y se presenta un análisis de la influencia de la variación en la carga del sistema de potencia y simultáneamente su capacidad de mantener altos índices de precisión para reconocer una zona de falla cada vez más pequeña.

Mediante un ejemplo de aplicación con el modelo de un sistema real, se muestra como el localizador propuesto es altamente efectivo, obteniéndose para el caso monofásico, que es el más exigente, aciertos de precisión promedio superiores al 90% en la localización de la zona en falla.

PALABRAS CLAVE: Localización de fallas, sistemas de distribución, clasificadores, máquinas de soporte vectorial.

ABSTRACT

A recent and interesting study topic to utilities engineers and customers has been the electric power quality. The product itself and the customer support are the main aspects considered. The product quality means satisfy requirements of wave quality and service continuity. This last aspect is the one considered when the fault location problem is taken into account.

This paper shows an analysis of a fault location method applied to power distribution systems, developed with a classifier based in support vectors machines. This fault locator is trained using fault data from nominal conditions and tested considering the influence of load variations. Also its capability to maintain high performance indexes where the power system is sub-divided in a increasing number of zones is checked.

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 mean precision scores above 90% to locate the faulted zone, in case of single phase faults to ground, which is the most difficult case proposed.

KEY WORDS: Fault location, power distribution systems, classifiers, support vectors.

1. INTRODUCCIÓN

La calidad de la energía eléctrica se ha convertido en un tema de estudio de gran interés para los operadores de red y para los usuarios, y de ahí que la actividad investigativa en este campo haya experimentado un fuerte avance en la última década. Entre los aspectos más importantes de la calidad se tienen en cuenta, la forma de onda, la continuidad del servicio y la atención al cliente [3]. La importancia actual de estos aspectos está asociada a que la participación del capital privado en el sector eléctrico obliga a establecer pautas de remuneración e índices mínimos de calidad. La calidad del producto, significa satisfacer condiciones de calidad de onda (o de la potencia), y de continuidad. Este último aspecto es el considerado cuando se aborda el problema de localización de fallas [10].

Las investigaciones en localización de falla se han enfocado en los sistemas de transmisión, donde por las características homogéneas de la línea, medición en ambos terminales y la disponibilidad de más equipos, permiten localizar el sitio de falla con una alta precisión. Finalmente, el problema de localización de fallas en sistemas de distribución, es un problema complejo y aún no está resuelto [8].

La localización de fallas en sistemas de distribución es más complicada, por la complejidad debida a la presencia de conductores no homogéneos, cargas intermedias, derivaciones laterales y desbalance del sistema y de la carga. Adicionalmente, en estos sistemas solo se cuenta con medidas en la subestación, y algunas veces, del modelo simplificado del sistema [13]. Muchas de las propuestas se relacionan con los métodos clásicos de localización, que utilizan las medidas de tensión y corriente en la subestación, para estimar la reactancia. Ésta se relaciona con la distancia al sitio de falla a partir del uso del modelo. Los problemas de estos métodos son la necesidad de un buen modelo del sistema y la múltiple estimación del sitio de falla, debido a que la distancia,

asociada con la reactancia estimada, puede coincidir con muchos sitios en un sistema ramificado [1][7][11][15]. Para contribuir con la solución del problema de la localización de fallas, en este artículo se propone una técnica de clasificación basada en máquinas de soporte vectorial, para reducir la incertidumbre asociada con la localización de la falla. Adicionalmente, se realiza un análisis de la precisión del método y su capacidad para localizar fallas en zonas cada vez más pequeñas y considerando simultáneamente la variación de la carga en el sistema de distribución. Esta alternativa sólo emplea las medidas de tensión y corriente en la subestación.

Como contenido del artículo, en la sección dos se describe la metodología propuesta para implementar y probar el localizador de fallas. En el numeral tres, se presenta una breve descripción del clasificador basado en máquinas de soporte vectorial. Las pruebas con un sistema prototipo y diferentes alternativas de zonificación del sistema y de las variaciones de la carga propuestas, junto con el análisis de los resultados, se muestran en el numeral cuatro. Finalmente, en la última parte se presentan las conclusiones derivadas de esta investigación.

2. METODOLOGÍA PARA LA APLICACIÓN DE UN CLASIFICADOR AL PROBLEMA DE LA LOCALIZACIÓN DE FALLAS

En este numeral se presenta la metodología propuesta para localizar la región probable de falla y la posterior aplicación del clasificador. El proceso está dividido en cinco etapas generales que se explican a continuación:

2.1 ZONIFICACIÓN DE LA RED

El criterio de zonificación debe estar fundamentado en la división del sistema de potencia, de tal manera que la identificación de una zona como la más probable de falla, permita al equipo de mantenimiento de la red, reducir el tiempo de localización de la falla. 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. Los criterios de zonificación por tanto son la topología de la red, la localización de las protecciones, la longitud de los alimentadores, la importancia del ramal, la disponibilidad de datos de fallas para entrenar el clasificador y finalmente las prácticas de la empresa.

En este caso se presentan varias alternativas de zonificación para mostrar el desempeño del clasificador ante los diferentes escenarios propuestos.

2.2 ADQUISICIÓN DE LA BASE DE DATOS DE FALLA

Cuando un evento de falla ocurre en el sistema de potencia, se debe tener la posibilidad de registrar tanto las señales de tensión como de corriente, medidas en la subestación. A partir del registro de las señales de falla, se debe crear una base de datos, en la cual cada registro esté identificado con el tipo de falla y la localización de la misma.

La base de datos puede ser obtenida con una combinación de registros de falla reales, o con el uso de un software especializado para realizar simulaciones con un circuito base, modelado con los parámetros del circuito real. Para este caso particular se realizó una simulación extensiva de fallas empleando Matlab® y "Alternative Transients Program -ATP" [12]. Las resistencias de falla para simulación están en un rango entre 0 y 40 Ω [6].

2.3 PRE-PROCESAMIENTO DE LA SEÑAL

La etapa de pre-procesamiento de la señal está asociada con la obtención del conjunto de descriptores, que representan la falla. Cada conjunto de descriptores está asociado con una etiqueta que corresponde a la zona en la cual ocurrió la falla. Los descriptores empleados 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 (X_f), la reactancia corregida a partir de la estimada en la primera barra (X_{cr}) y la frecuencia (f), para valores tanto de línea como de fase.

En este artículo se consideraron únicamente descriptores que fueran de fácil obtención para que la propuesta no esté condicionada por las limitaciones de equipos. Los descriptores aquí presentados, se calculan de una manera 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. En esta selección se analizan las combinaciones de descriptores que conforman el conjunto de entrenamiento que posibilitan una clasificación adecuada y por ende la localización correcta de la zona en la cual ocurre la falla. En este artículo se presentan los resultados para las combinaciones de dos, tres y cuatro descriptores.

A partir de las pruebas de cada posible combinación de descriptores, se selecciona el conjunto con el cual los 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).

Para el clasificador se aplicó una estrategia de entrenamiento del tipo supervisado, con el cual se obtuvieron resultados adecuados para resolver el problema planteado. En el entrenamiento del localizador basado en máquinas de soporte vectorial, se utilizó la validación cruzada y la búsqueda en malla, para encontrar el mejor valor de la constante de penalización C y del parámetro σ del "kernel" RBF, que se describen en el numeral 3 de este documento y en [9].

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 empleados para el proceso de entrenamiento. Los datos de prueba tienen que corresponder a los mismos descriptores y deben 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).

$$\text{Precisión} = \frac{\# \text{ registros clasificados correctamente}}{\# \text{ total de registros}} \quad (1)$$

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 resolver el problema de la localización de fallas.

3. CLASIFICADORES BASADOS EN MÁQUINAS DE SOPORTE VECTORIAL

Para problemas de clasificación simples, la teoría estadística de aprendizaje puede identificar con alta

precisión los factores a tener en cuenta para un aprendizaje exitoso, pero las aplicaciones reales demandan el uso de modelos y algoritmos mas complejos (ej. redes neuronales, técnicas Bayesianas, etc), que son difíciles de analizar.

Las máquinas de soporte vectorial, a diferencia del método Bayesiano presentan la ventaja de no requerir ningún tipo de hipótesis sobre la densidad de probabilidad de los rasgos, mientras que sobre las redes neuronales ofrecen la ventaja de ser convenientes en términos de la dimensionalidad del problema. Como se verá más adelante, la arquitectura de las máquinas de soporte vectorial (Acrónimo en inglés SVM), sólo depende de la constante de penalización C , y el parámetro σ de la función kernel para el caso de una de función de base radial (Acrónimo en inglés RBF), tal como se muestra en la sección 3.3 [5]. Esta facilidad de configuración evita la selección de requerimientos sobre parámetros exclusivos de arquitectura, tales como número de nodos y capas, tipo de conexión entre capas, entre otros.

3.1 CLASIFICACIÓN LINEAL

Los clasificadores basados en máquinas de soporte vectorial están basados en hiperplanos que separan los datos de entrenamiento en dos subgrupos que poseen cada uno una etiqueta propia. En medio de todos los posibles planos de separación entre las dos clases etiquetadas como y ($y \in \{-1, +1\}$), existe un único hiperplano de separación óptimo (OSH), de forma que la distancia entre el hiperplano óptimo y el patrón de entrenamiento más cercano sea máxima, con la intención de forzar la generalización de la máquina de aprendizaje [5][16]. De forma que el OSH se expresa tal como se presenta en (2).

$$P_0 : \langle \bar{w}, \bar{x} \rangle + b = 0$$

Donde, n datos de entrenamiento n -dimensionales corresponden a x_i ; $1/|w|$ es la distancia entre cualquiera de los planos al OSH y b es un término independiente. En este problema, se desea maximizar el margen, tal como se presenta en la figura 1.

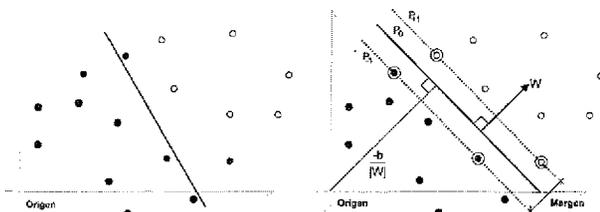


Figura 1. Hiperplanos que separan correctamente los datos. El OSH de la derecha tiene un mayor margen de separación entre clases, por lo tanto se espera una mejor generalización.

La función decisión $f_{w,b}(x_i) = y_i$, se puede definir como el signo que resulta de evaluar un dato en la ecuación del OSH (2), tal como se presenta en la ecuación (3).

$$f_{w,b}(x_i) = \text{sign}(\langle \bar{w}, \bar{x}_i \rangle + b) \quad (3)$$

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

3.2 CLASIFICACIÓN CON MARGEN DÉBIL

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

Con el objeto de definir de forma única el hiperplano óptimo (forma canónica), se deben añadir las restricciones, tal como se presenta en la ecuación (5).

$$\xi_i \geq 0, \forall i \quad (4)$$

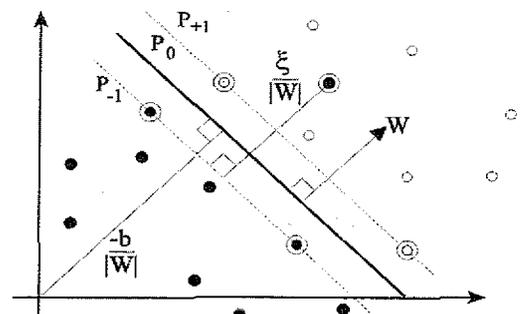


Figura 2. Hiperplano de separación permitiendo ruido

$$y_i(\langle \bar{w}, \bar{x}_i \rangle + b) \geq 1 - \xi_i, \forall i \quad (5)$$

3.3 CASO NO LINEAL

Los clasificadores basados máquinas de soporte vectorial 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 luego construye un OSH sobre este último, cuya representación en el espacio de entrada es una función de separación no lineal, tal como se representa gráficamente en la figura 3.

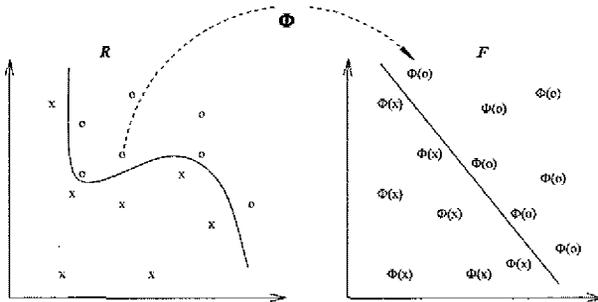


Figura 3. Transformación del espacio de entrada en otro de dimensión más alta donde las clases tienen una separación lineal.

La generalización de la máquina de soporte vectorial 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 el "kernel" (Φ), que relaciona los datos de entrada $x_i \in R^N$ con un espacio de mayor dimensión y en el cual esté definido el producto punto, conocido como espacio característico (F), tal como se define en la ecuación (6) [4].

$$\Phi : R^N \rightarrow F \quad (6)$$

Así, de la función en la ecuación (2), la cual depende del producto punto de los vectores en el espacio de entrada, se obtiene una función que depende del producto punto de los vectores en el espacio característico, tal como se presenta en la ecuación (7).

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

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

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

Considerando que (F) es de alta dimensión, el lado derecho de la ecuación (8) es costosa en términos computacionales, sin embargo existe una función "kernel" (k), que se puede evaluar eficazmente y demostrar que corresponde a un trazado de (Φ) en un espacio que abarca todos los productos punto [2]. Los kernels más utilizados son el polinomial presentado en la ecuación (9), el de función de base radial (RBF) en (10) y el sigmoide en (11).

$$k(\bar{u}, \bar{v}) = (\langle \bar{u}, \bar{v} \rangle + c)^d \quad (9)$$

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

$$k(\bar{u}, \bar{v}) = \tanh(\kappa \langle \bar{u}, \bar{v} \rangle + \Theta) \quad (11)$$

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).

$$\min_{w,b} \frac{1}{2} \langle w, w \rangle + C \sum_{i=1}^N \xi_i \quad (12)$$

Utilizando los multiplicadores de Lagrange y el teorema dual de Wolfe, se obtiene el problema de optimización dado por (13).

$$\max_{\alpha} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j k(\bar{x}_i, \bar{x}_j) \quad (13)$$

Sujeto a:

$$0 \leq \alpha_i \leq C, \forall i \text{ y } \sum_{i=1}^N \alpha_i y_i = 0$$

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

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

$$f(\bar{x}) = \text{sign} \left(\sum_{i,j=1}^N (\alpha_i y_i k(x_i, x)) + b \right) \quad (15)$$

Para resolver el problema de multclasificación (más de dos clases), se construye una función clasificadora global a partir de un conjunto de funciones biclasificadoras. Existen técnicas de descomposición y reconstrucción que permiten a los clasificadores basados en SVM manejar problemas de multclasificación con mayor simplicidad y/o menor tiempo de respuesta que una SVM generalizada para multclasificación [14].

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 25kV de "Saskatoon Power and Light" de Saskatchewan, Canadá y presentado en [7]. El diagrama unifilar del sistema se presenta en la figura 4.

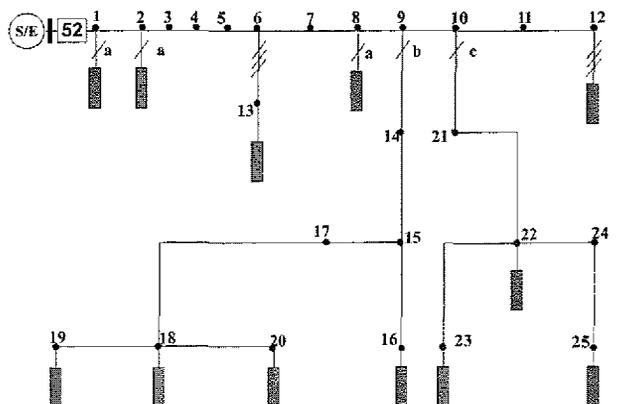


Figura 4. Diagrama unifilar del sistema de pruebas. Este circuito ha sido utilizado además para pruebas de distintos métodos de localización de fallas, tal como se presenta en [11][13].

4.2 DESCRIPCIÓN DE LAS PRUEBAS

Para las pruebas de desempeño del localizador se proponen las diferentes zonificaciones del sistema, de tal forma que haya escenarios exigentes desde el punto de vista de clasificación. A partir de lo anterior, se definen cinco escenarios de zonificación diferentes, en los cuales se aprecia la variación del número de nodos que se tienen por zona y la capacidad de predecir la zona en falla. En la tabla 1 se presentan los escenarios de zonificación propuestos.

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

# de la zonas	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		22, 23	20	16	10
10		24, 25	22	18	11
11			23	19	12
12			24	20	13
13			25	22	15
14				23	16
15				24	18
16				25	19
17					20
18					22
19					23
20					24
21					25

Adicionalmente y considerando que la carga de un sistema varía considerablemente durante la operación, la herramienta de inteligencia artificial se entrena bajo condición de carga nominal y se analiza su sensibilidad ante variaciones $\pm 40\%$ de la carga, para cada una de las zonificaciones propuestas.

Las barras numeradas como 7, 14, 17 y 21 no fueron incluidas debido que en el sistema original, corresponden a la barra aguas abajo de la protección localizada en las barras 6, 9, 15 y 10, respectivamente. Es decir, desde el punto de vista circuital, son el mismo nodo, antes que actúen las protecciones.

Los escenarios propuestos para las pruebas consideran entonces la división del sistema en 7, 10, 13, 16 y 21 zonas, y para cada una de ellas se considera una variación de la carga del 60%, 80%, 125% y 140% de la carga nominal del sistema. Las pruebas se realizan para cada uno de los localizadores, especializado por tipo de falla y considerando que éstos son entrenados sólo con datos de la condición nominal.

Para cada uno de los escenarios de pruebas propuestos y en caso de carga nominal, para falla monofásica, la cantidad de datos de prueba corresponden a 225 registros de falla (24% del total de datos), mientras que los utilizados para prueba son 720 (76% de los datos). Para las pruebas en condiciones diferentes a la nominal, el número de registros de falla es de 1071. Los registros de prueba no son utilizados en el proceso de entrenamiento del localizador.

4.3 RESULTADOS DE LAS PRUEBAS

A continuación se presentan los resultados para las pruebas realizadas al localizador de fallas basado en máquinas de soporte vectorial, ante las circunstancias expuestas en el numeral anterior y con 246 combinaciones diferentes de 2, 3 y 4 descriptores.

La variación de los parámetros C y σ , para la búsqueda en malla se realizó dentro de un intervalo ($C_{min} < C < C_{max}$ y $\sigma_{min} < \sigma < \sigma_{max}$). Mediante pruebas realizadas con diferentes intervalos, se determinó empíricamente que los valores de C_{min} y C_{max} son 2^4 y 2^{32} , respectivamente y los pasos son de 2^4 . De otra parte, los valores de σ_{min} y σ_{max} son 2^{-6} y 2^6 , respectivamente con pasos de 2.

En este numeral, se presentan las pruebas, para las 15 combinaciones cuyos resultados de precisión promedio, ante una variación de carga, son más altas. Sólo se presentan datos para el caso monofásico que es el más crítico y el tipo de falla más frecuente. Sin embargo, para los otros tipos de falla, los resultados de precisión son superiores.

4.3.1 Escenario Uno – Sistema dividido en 7 zonas, ante variación de carga.

Tabla 2. Resultados de las 15 mejores combinaciones de descriptores, con el sistema dividido en 7 zonas y ante variación de la carga

Conjunto de descriptores	Precisión en la prueba					
	Carga al 60% de la nominal	Carga al 80% de la nominal	Carga nominal	Carga al 125% de la nominal	Carga al 140% de la nominal	Promedio
<i>dV, f</i>	0,9449	0,9627	0,9823	0,9486	0,9281	0,9533
<i>dV, dVL, f</i>	0,9206	0,9645	0,9976	0,9430	0,9253	0,9502
<i>dVL, f</i>	0,9393	0,9599	0,9905	0,9328	0,9160	0,9477
<i>dVL, dI, f</i>	0,9066	0,9636	0,9976	0,9458	0,9048	0,9437
<i>dVL, dI, dIL, f</i>	0,9057	0,9599	0,9929	0,9440	0,9029	0,9411
<i>dV, dVL, dIL, f</i>	0,9141	0,9599	0,9905	0,9440	0,8945	0,9406
<i>dV, dVL, dI, f</i>	0,8898	0,9580	0,9976	0,9486	0,9066	0,9401
<i>dVL, dIL, f</i>	0,8982	0,9627	0,9965	0,9356	0,8814	0,9349
<i>dI, f</i>	0,8768	0,9244	0,9740	0,9486	0,9365	0,9321
<i>dV, dIL, f</i>	0,8581	0,9645	0,9976	0,9262	0,8898	0,9273
<i>dV, dI, f</i>	0,8422	0,9477	0,9953	0,9412	0,8945	0,9242
<i>dV, dI, dIL, f</i>	0,8665	0,9468	0,9799	0,9300	0,8954	0,9237
<i>dIL, f</i>	0,8478	0,9346	0,9799	0,9234	0,8973	0,9166
<i>dVL, dI, dIL</i>	0,8049	0,9599	1,0000	0,9244	0,8926	0,9163
<i>dI, dIL, f</i>	0,8366	0,9384	0,9787	0,9225	0,8973	0,9147

4.3.2 Escenario Uno – Sistema dividido en 7 zonas, ante variación de carga.

Tabla 3. Resultados de las 15 mejores combinaciones de descriptores, con el sistema dividido en 10 zonas y ante variación de la carga

Conjunto de descriptores	Precisión en la prueba					
	Carga al 60% de la nominal	Carga al 80% de la nominal	Carga nominal	Carga al 125% de la nominal	Carga al 140% de la nominal	Promedio
<i>dV, f</i>	0,9178	0,9449	0,9586	0,9318	0,9253	0,9357
<i>dV, dVL, f</i>	0,9029	0,9477	0,9610	0,9337	0,9290	0,9349
<i>dVL, f</i>	0,8898	0,9477	0,9645	0,9356	0,9281	0,9332
<i>dVL, dI, f</i>	0,9048	0,9468	0,9764	0,9234	0,9113	0,9325
<i>dVL, dI, dIL, f</i>	0,8954	0,9393	0,9752	0,9281	0,9188	0,9314
<i>dV, dVL, dIL, f</i>	0,9234	0,9486	0,9574	0,9132	0,8898	0,9265
<i>dV, dVL, dI, f</i>	0,9029	0,9328	0,9433	0,9281	0,9178	0,9250
<i>dVL, dIL, f</i>	0,8805	0,9328	0,9598	0,9160	0,9132	0,9204
<i>dI, f</i>	0,8581	0,9309	0,9622	0,9206	0,8590	0,9062
<i>dV, dIL, f</i>	0,8609	0,9328	0,9622	0,9188	0,8553	0,9060
<i>dV, dI, f</i>	0,8534	0,9094	0,9137	0,9010	0,8889	0,8933
<i>dV, dI, dIL, f</i>	0,8543	0,9384	0,9444	0,8889	0,8273	0,8907
<i>dIL, f</i>	0,8478	0,9206	0,9610	0,8786	0,8049	0,8826
<i>dVL, dI, dIL</i>	0,8254	0,9234	0,9586	0,8889	0,7880	0,8769
<i>dI, dIL, f</i>	0,7367	0,8870	0,9468	0,8842	0,8245	0,8558

4.3.3 Escenario Tres – Sistema dividido en 13 zonas, ante variación de carga

Tabla 4. Resultados de las 15 mejores combinaciones de descriptores, con el sistema dividido en 13 zonas y ante variación de la carga

Conjunto de descriptores	Precisión en la prueba					
	Carga al 60% de la nominal	Carga al 80% de la nominal	Carga nominal	Carga al 125% de la nominal	Carga al 140% de la nominal	Promedio
<i>dV, f</i>	0,9066	0,9412	0,9574	0,9337	0,9281	0,9334
<i>dV, dVL, f</i>	0,8889	0,9374	0,9645	0,9290	0,9281	0,9296
<i>dVL, f</i>	0,9010	0,9281	0,9574	0,9290	0,9272	0,9286
<i>dVL, dI, f</i>	0,8880	0,9328	0,9752	0,9281	0,9150	0,9278
<i>dVL, dI, dIL, f</i>	0,8852	0,9328	0,9728	0,9253	0,9188	0,9270
<i>dV, dVL, dIL, f</i>	0,9132	0,9421	0,9586	0,9178	0,8964	0,9256
<i>dV, dVL, dI, f</i>	0,8796	0,9412	0,9669	0,9262	0,9085	0,9245
<i>dVL, dIL, f</i>	0,8861	0,9374	0,9551	0,9122	0,8982	0,9178
<i>dI, f</i>	0,8796	0,9412	0,9610	0,9113	0,8581	0,9102
<i>dV, dIL, f</i>	0,8301	0,9402	0,9634	0,9010	0,8506	0,8971
<i>dV, dI, f</i>	0,8422	0,9393	0,9622	0,9020	0,8282	0,8948
<i>dV, dI, dIL, f</i>	0,8459	0,9421	0,9610	0,8693	0,8142	0,8865
<i>dIL, f</i>	0,8273	0,9393	0,9622	0,8926	0,8095	0,8862
<i>dVL, dI, dIL</i>	0,8226	0,9365	0,9610	0,8870	0,7778	0,8770
<i>dI, dIL, f</i>	0,6909	0,8459	0,9409	0,8721	0,7899	0,8280

4.3.5 Escenario Cuatro – Sistema dividido en 16 zonas, ante variación de carga

Tabla 5. Resultados de las 15 mejores combinaciones de descriptores, con el sistema dividido en 16 zonas y ante variación de la carga

Conjunto de descriptores	Precisión en la prueba					
	Carga al 60% de la nominal	Carga al 80% de la nominal	Carga nominal	Carga al 125% de la nominal	Carga al 140% de la nominal	Promedio
<i>dV, f</i>	0,8936	0,9262	0,9291	0,9132	0,9094	0,9143
<i>dV, dVL, f</i>	0,8898	0,9188	0,9350	0,9094	0,9104	0,9127
<i>dVL, f</i>	0,8749	0,9216	0,9350	0,9076	0,9076	0,9093
<i>dVL, dI, f</i>	0,8646	0,9169	0,9504	0,9094	0,9048	0,9092
<i>dVL, dI, dIL, f</i>	0,8805	0,9150	0,9326	0,9094	0,9057	0,9087
<i>dV, dVL, dIL, f</i>	0,8693	0,9122	0,9326	0,9010	0,8992	0,9029
<i>dV, dVL, dI, f</i>	0,8581	0,9216	0,9350	0,9048	0,8814	0,9002
<i>dVL, dIL, f</i>	0,8319	0,9169	0,9480	0,9094	0,8889	0,8990
<i>dI, f</i>	0,8534	0,9197	0,9326	0,8954	0,8721	0,8946
<i>dV, dIL, f</i>	0,8226	0,9216	0,9350	0,8721	0,8217	0,8746
<i>dV, dI, f</i>	0,8189	0,9178	0,9385	0,8702	0,8142	0,8719
<i>dV, dI, dIL, f</i>	0,8142	0,9206	0,9362	0,8665	0,7918	0,8659
<i>dIL, f</i>	0,8105	0,9160	0,9350	0,8655	0,7862	0,8626
<i>dVL, dI, dIL</i>	0,8039	0,9169	0,9362	0,8655	0,7852	0,8616
<i>dI, dIL, f</i>	0,6116	0,8665	0,9551	0,8235	0,7367	0,7987

4.3.5 Escenario cinco – Sistema dividido en 21 zonas (1 nodo por zona), ante variación de carga

Tabla 6. Resultados de las 15 mejores combinaciones de descriptores, con un nodo por zona y ante variación de la carga

Conjunto de descriptores	Precisión en la prueba					
	Carga al 60% de la nominal	Carga al 80% de la nominal	Carga nominal	Carga al 125% de la nominal	Carga al 140% de la nominal	Promedio
<i>dV. f</i>	0,8982	0,9384	0,9527	0,9160	0,9020	0,9214
<i>dV. dVL. f</i>	0,8982	0,9318	0,9527	0,9150	0,9038	0,9203
<i>dVL. f</i>	0,8824	0,9253	0,9527	0,9234	0,9150	0,9198
<i>dVL. dI. f</i>	0,8926	0,9318	0,9598	0,9122	0,9020	0,9197
<i>dVL. dI. dIL. f</i>	0,8889	0,9328	0,9563	0,9178	0,9020	0,9195
<i>dV. dVL. dIL. f</i>	0,8926	0,9365	0,9574	0,9150	0,8945	0,9192
<i>dV. dVL. dI. f</i>	0,8749	0,9328	0,9598	0,9141	0,8880	0,9139
<i>dVL. dIL. f</i>	0,8749	0,9328	0,9598	0,9141	0,8852	0,9133
<i>dI. f</i>	0,8786	0,9318	0,9574	0,8992	0,8599	0,9054
<i>dV. dIL. f</i>	0,8291	0,9318	0,9574	0,8796	0,8226	0,8841
<i>dV. dI. f</i>	0,7880	0,9281	0,9622	0,8758	0,8198	0,8748
<i>dV. dI. dIL. f</i>	0,7993	0,9290	0,9574	0,8777	0,7918	0,8710
<i>dIL. f</i>	0,7983	0,9253	0,9563	0,8702	0,7703	0,8641
<i>dVL. dI. dIL</i>	0,7871	0,9272	0,9574	0,8711	0,7759	0,8638
<i>dI. dIL. f</i>	0,6116	0,9057	0,9764	0,8366	0,7208	0,8102

4.4 ANÁLISIS DE RESULTADOS

A partir de las pruebas se puede observar, como la precisión disminuye, para el caso de una zonificación determinada, a medida que varía la carga del sistema entre el intervalo de 0,6 a 1,4 veces la carga nominal, y entrenando el localizador SVM con datos tomados a la carga nominal. En la figura 5 se presenta una comparación gráfica de los valores presentados en la tabla 2, para el caso de los mejores resultados en una zonificación de siete zonas.

De la misma manera, en los diferentes escenarios de zonificación, se aprecia como el desempeño del localizador

disminuye en la medida que el problema se hace más exigente, es decir, cuando hay más zonas con menos nodos en cada una de ellas. En la figura 6 se puede apreciar el comportamiento del promedio de la precisión del localizador para cada zonificación, con las mejores combinaciones de descriptores.

El descriptor que mejor comportamiento tiene para la localización de la falla, es la frecuencia (*f*), debido a su independencia de la carga del sistema. Esta afirmación se ve sustentada en los resultados obtenidos, en los cuales, en la mayoría de combinaciones que presentan mejores resultados está contenido este descriptor.

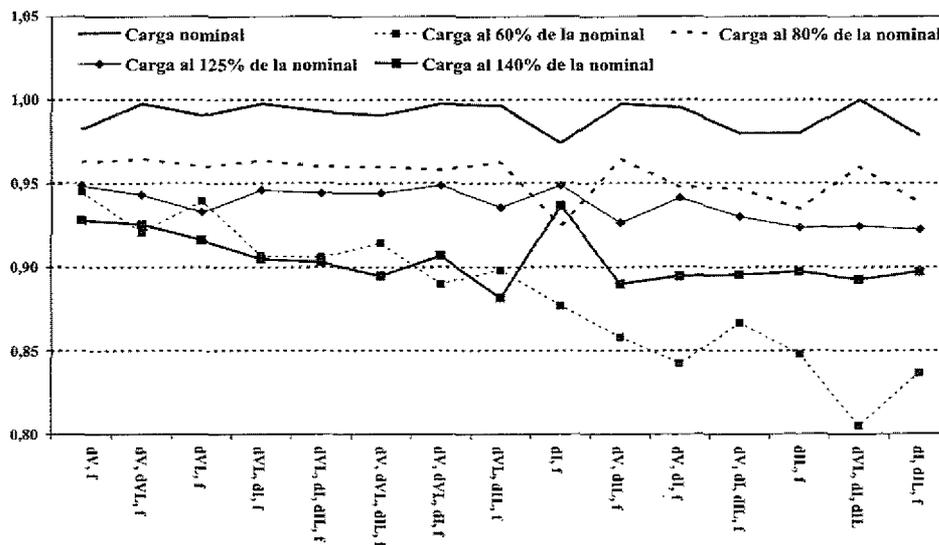


Figura 5. Gráfico comparativo de la precisión para las mejores combinaciones de descriptores, en el caso de una zonificación de siete zonas, en caso de falla monofásica.

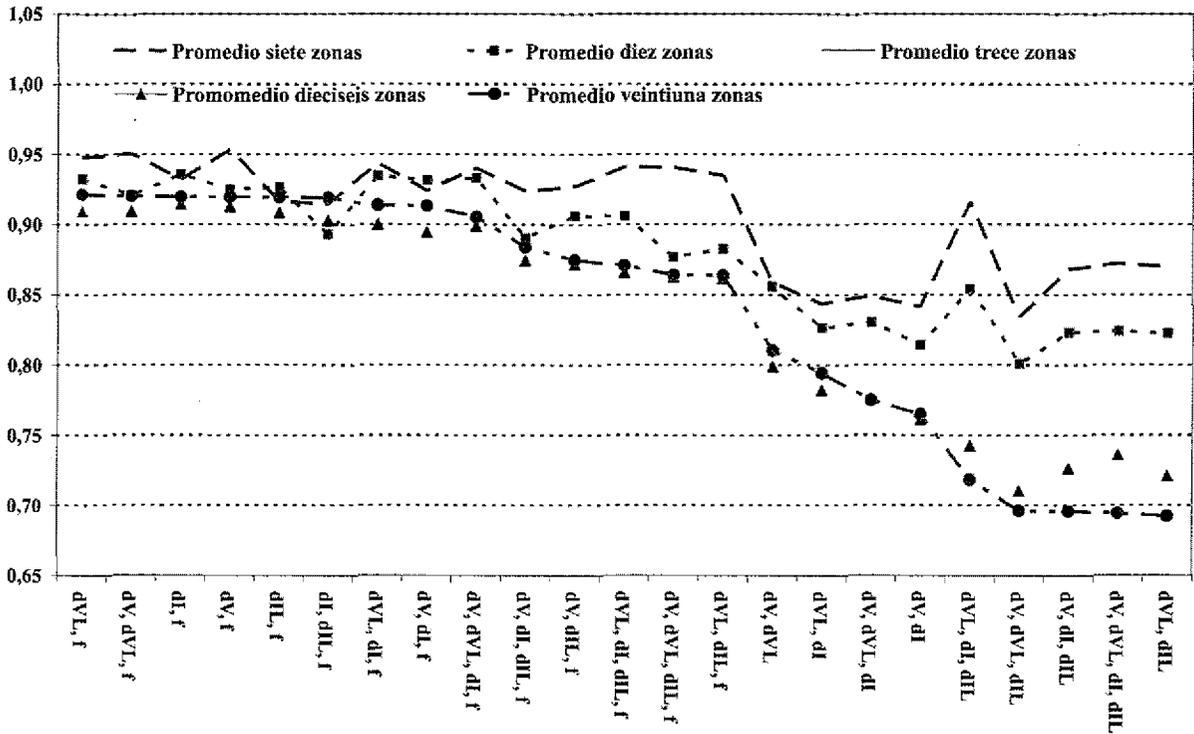


Figura 6. Gráfico comparativo de la precisión promedio para todas las zonificaciones y para las mejores combinaciones de descriptores, en caso de falla monofásica.

De otra parte, los descriptores que presentan un menor desempeño son los asociados con la reactancia del sistema (X_f) y (X_{cr}). Éstos se ven influenciados de forma desfavorable con el cambio de carga, ya que para prueba en las condiciones nominales, muestran excelentes resultados, mientras que ante la variación de la carga, estos descriptores no tienen alta precisión para hallar la zona bajo falla.

Los descriptores asociados con la variación de la corriente y la tensión entre los estados de falla y pretalla, tanto de línea como de fase (dI , dV , dIL , dVL), presentan buenos resultados de precisión. Éstos, combinados con la frecuencia, presentan los resultados de precisión más altos para cada uno de los casos analizados, alcanzando promedios mayores al 90% para el caso monofásico, que es el que aquí se presenta por ser el que tiene los resultados de precisión más bajos, comparado con los otros tipos de fallas.

Finalmente, los resultados de las pruebas de los tipos de fallas bifásicas, bifásica a tierra y trifásicas no se presentan en este documento, debido a limitaciones de espacio. Sin embargo, los resultados son superiores a los aquí presentados, y es posible encontrar combinaciones con resultados promedios superiores al 98 % de precisión.

5. CONCLUSIONES

Se ha presentado una metodología para localizar fallas en sistemas de distribución utilizando máquinas de soporte vectorial. Se caracteriza el sistema en estado de falla con unos descriptores que se utilizaron para entrenar y validar el localizador ante diferentes escenarios de variación del tamaño de la zona y la carga del sistema.

Los resultados obtenidos, muestran el alto desempeño del método aquí propuesto, pudiendo compararse con los métodos clásicos que estiman la distancia a la falla. El localizador de fallas entrenado con aproximadamente el 24 % de los datos tomados de la condición nominal, muestra muy buenos resultados, en los diferentes escenarios, incluso en la prueba más exigente que asigna una zona a cada uno de los nodos del sistema de prueba y con variaciones de carga de $\pm 40\%$ de la carga nominal. Finalmente, con ayuda de esta metodología se puede reducir el tiempo de restauración del sistema fallado, aumentando los índices que miden la continuidad del servicio de energía eléctrica y reduciendo, por consiguiente, los pagos por compensaciones debidas a la deficiente calidad del servicio.

6. BIBLIOGRAFÍA

- [1] Aggarwal, Aslan & Johns (1997). "An interactive approach to fault location on overhead distribution lines with load taps". IEE Developments in Power System Protection. Conference Publication No. 434.1997, pp 184-187.
- [2] Bernhard & Smola (2002). "Learning with Kernels Support Vector Machines, Regularization, Optimization and Beyond". The MIT Press, Cambridge. 2002.
- [3] Bollen (2000). "Understanding Power Quality Problems: Voltage Sags and Interruptions". IEEE Press. 2000.
- [4] Boser, Guyon & Vapnik (1992). "A training algorithm for optimal margin classifier". Proceedings of the 5th ACM Workshop on Computational Learning Theory. Pag:144-152. 1992.
- [5] Burges (1998). "A tutorial on support vector machines for pattern recognition". Data Mining and Knowledge Discovery, 1998. Pag: 121-167.
- [6] Dagenhart (2000). "The 40- Ground-Fault Phenomenon" IEEE Transactions on Industry Applications, vol. 36, no. 1, pages 30-32, 2000.
- [7] Das (1998). "Determining the Locations of Faults in Distribution Systems". Tesis doctoral, University of Saskatchewan. Saskatoon, Canada. 1998.
- [8] IEEE Std C37.114 (2004). "IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines" Power System Relaying Committee 2004.
- [9] Lin, Chang & Hsu (2004). "A Practical Guide to Support Vector Classification". National Taiwan University, 2004.
- [10] Mora (2003). "Voltage Sag Characterization and Classification for Diagnosis in Electric Power Quality Domain", Master dissertation. University of Girona, España. 2003.
- [11] Mora, Muñoz & Carrillo (2005). "Técnicas algorítmicas de localización de fallas como alternativa para reducir el efecto de las salidas en sistemas de potencia - Una revisión". III Internacional Symposium of Power Quality. Bogotá, Colombia, Nov. 2005.
- [12] Mora, Melendez & Bedoya (2006). "Extensive Events Database Development using ATP and Matlab to Fault Location in Power Distribution Systems". In CD proceedings of 2006 IEEE PES Transmission and Distribution Conference and Exposition: Latin America. IEEE Catalog Number 06EX1340C. ISBN 1-4244-0288-3.
- [13] Mora, Pérez & Carrillo (2006). "Fault location in power distribution systems using ANFIS nets and current patterns" In CD proceedings of 2006 IEEE PES Transmission and Distribution Conference and Exposition: Latin America. IEEE Catalog Number 06EX1340C. ISBN 1-4244-0288-3.
- [14] Morales & Gómez (2005). "Estudio e implementación de una herramienta basada en máquinas de soporte vectorial aplicada a la localización de fallas en sistemas de distribución". Universidad Industrial de Santander. 2005.
- [15] Novosel, Hart & Myllymaki (1998). "System for locating faults and estimating fault resistance in distribution networks with tapped loads". 1998. US Patent number 5,839,093.
- [16] Vapnik (2000). "The nature of Statistical Learning Theory" Second Edition, Springer Verlag, 2000.

7. AUTORES

GERMÁN ANDRÉS MORALES ESPAÑA

Ingeniero Electricista. Investigador del Grupo de Investigación en Sistemas de Energía Eléctrica- GISEL. Universidad Industrial de Santander.
E-mail: german.morales.e@gmail.com

HERMANN RAÚL VARGAS

Ingeniero Electricista y Master en Ingeniería Eléctrica de Universidad Industrial de Santander. Colombia. Doctor de la Universidad Pontificia Comillas en España. Actualmente es docente de la Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones de la Universidad Industrial de Santander.
E-mail: hrvargas@uis.edu.co

JUAN JOSÉ MORA FLÓREZ

Ingeniero Electricista y Master en Ingeniería Eléctrica de Universidad Industrial de Santander. Colombia. Doctor por la Universitat de Girona en España. Actualmente es docente del Programa de Ingeniería Eléctrica, Universidad Tecnológica de Pereira.
E-mail: jjmora@utp.edu.co