



Revista Facultad de Ingeniería Universidad de Antioquia

ISSN: 0120-6230

revista.ingenieria@udea.edu.co

Universidad de Antioquia
Colombia

Morales España, Germán; Barrera Cárdenas, René; Vargas Torres, Hermann Raúl
Ubicación única de fallas en sistemas de distribución por medio de zonas con SVM
Revista Facultad de Ingeniería Universidad de Antioquia, núm. 47, marzo, 2009, pp. 187-196
Universidad de Antioquia
Medellín, Colombia

Disponible en: <http://www.redalyc.org/articulo.oa?id=43004717>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica
Red de Revistas Científicas de América Latina, el Caribe, España y Portugal
Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

Ubicación única de fallas en sistemas de distribución por medio de zonas con SVM

Unique localization of faults in distribution systems by means of zones with SVM

Germán Morales España, René Barrera Cárdenas, Hermann Raúl Vargas Torres*

Grupo de Investigación en Sistemas de Energía Eléctrica (GISEL), Escuela de Ingenierías Eléctrica Electrónica y Telecomunicaciones, Universidad Industrial de Santander (UIS), carrera 27 calle 9, Bucaramanga, Colombia

(Recibido el 6 de noviembre de 2007. Aceptado el 6 de noviembre de 2008)

Resumen

Este artículo presenta una nueva metodología para localizar fallas en sistemas de distribución por medio de una técnica de inteligencia artificial –Máquinas de Soporte Vectorial– (SVM). El método de localización de la falla se basa en la división del sistema eléctrico en zonas, acotando cada vez más la región donde ésta se encuentra. La ventaja sobre los métodos clásicos de distancia consiste en una única estimación del sitio de falla para sistemas ramificados. Un ejemplo de aplicación con el modelo de un sistema real muestra que la metodología propuesta es altamente efectiva para resolver el problema, donde se consideran variaciones de carga de $\pm 40\%$ de la carga nominal.

----- *Palabras clave:* Descriptores, inteligencia artificial, localización de fallas, múltiple estimación, sistemas de distribución, SVM, zonas.

Abstract

This paper presents a new methodology for localizing faults in distribution systems by means of an artificial intelligence technique –Support Vector Machine– (SVM). This methodology divides the electrical system into different zones order to pinpoint the region where the fault exists with accuracy. The advantage over classical distance methods is the unique estimation of the fault's locus in branches systems. An example using a real system model shows that the proposed methodology is highly effective finding the fault localization. In such example load changes of $\pm 40\%$ from nominal load are considered.

----- *Keywords:* Descriptors, artificial intelligence, fault's localization, multiple estimation, distribution systems, SVM, zones.

Autor de correspondencia: teléfono: + 57 + 7 + 634 40 00 ext 27 12, fax: + 57 + 7 + 635 96 22, correo electrónico: abarrera@uis.edu.co (R. Barrera)

Introducción

En los últimos años, el estudio de la calidad de la energía eléctrica ha tomado gran auge. En calidad de energía eléctrica se tienen en cuenta, la forma de onda, la continuidad del suministro y la atención al cliente. Localizar fallas es un tema que está directamente relacionado con la continuidad del suministro. En este marco, el problema de localización de fallas se posiciona como uno de los más importantes, dado que las interrupciones significan pérdidas de dinero básicamente por dos razones:

- El tiempo de no operación o suspensión de la producción.
- Multas impuestas a empresas de energía eléctrica por incumplimiento de las regulaciones establecidas (Sobrepaso de índices de Duración Equivalente de las interrupciones del Servicio –DES– y Frecuencia Equivalente de las interrupciones del Servicio –FES–, para el caso colombiano).

Por tanto, es necesario conocer de manera rápida y confiable el lugar donde ha ocurrido la falla, para establecer medidas que solucionen o mitiguen su impacto en la calidad de energía eléctrica, cumpliendo así con las normas especificadas por las comisiones de regulación. Pueden existir fallas permanentes y transitorias, y un localizador de fallas proporcionará información para ambos tipos de falla. Generalmente, las fallas transitorias causan un menor daño y no se pueden localizar con una simple inspección. Ante estas fallas, los localizadores permiten detectar puntos débiles del sistema de potencia y tomar acciones correctivas para evitar mayores daños debido a reincidencias de la falla (se puede mejorar considerablemente el índice FES). Cuando ocurre una falla permanente, se requiere un rápido aislamiento, reparación y restauración del servicio. En los sistemas de distribución existe un sistema de protección con relés que típicamente hace una correcta y rápida desconexión, el restablecimiento del servicio se puede acelerar considerablemente si se determina con exactitud razonable la ubicación de la falla (mejora del índice DES). La localiza-

ción de fallas no es un problema nuevo. Sin embargo, las investigaciones que se han realizado en esta área recaen sobre los sistemas de transmisión donde las características homogéneas de la línea, la medición en ambos terminales y la disponibilidad de más equipos, permiten localizar el sitio de falla con alta precisión. La localización en sistemas de distribución es más problemática, por la complejidad debida a la presencia de conductores no homogéneos, cargas intermedias, laterales y desbalance del sistema y de la carga. Algunas veces solo se cuenta con el modelo simplificado del sistema [1], además de tener medidas únicamente en la subestación. Muchas de las soluciones propuestas por varios autores 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, porque la distancia asociada con la reactancia estimada puede coincidir con muchos sitios en un sistema ramificado [2-7]. El problema de localización de fallas en sistemas de distribución, es complejo y aún no está resuelto [8]. Para contribuir con la solución del problema de la localización de fallas, en este artículo se propone una técnica de clasificación basada en vectores de soporte, para reducir la incertidumbre asociada con la localización de la falla. Se trabajan las SVM debido a que han mostrado un buen desempeño en comparación con otras herramientas de clasificación [9]. Adicionalmente, se realiza un análisis de la precisión del método y su capacidad para localizar fallas en zonas cada vez más pequeñas en el sistema de distribución. Esta alternativa sólo emplea las medidas de tensión y corriente en la subestación a frecuencia fundamental evitando costos de inversión (en especial en aparatos sofisticados de medida). En este artículo se presentan los fundamentos básicos de las Máquinas de Soporte Vectorial, la manera de adquirir los datos necesarios para entrenar la herramienta de inteligencia artificial cuando un sistema se encuentra en estado de falla, los pasos para llevar a cabo la localización

de la zona de falla, los resultados de la metodología propuesta en un sistema prototipo y las conclusiones derivadas de esta investigación.

Máquinas de Soporte Vectorial

¿Por qué las SVM? Para problemas simples, la teoría estadística de aprendizaje puede identificar con mucha 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 presenta 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 SVM, solo depende del parámetro C , la función kernel (incluyendo sus parámetros), que para el caso del RBF [10] solo requiere del parámetro σ evitando así requerimientos sobre parámetros exclusivos de arquitectura, tales como número de nodos y capas, tipo de conexión entre capas, etc. [11].

Los clasificadores 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 $y \in \{-1, +1\}$, existe un único hiperplano de separación óptimo (OSH), tal 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 [10, 12, 13]. Entonces, el hiperplano de separación óptimo se expresa de la forma:

$$g(\vec{x}) = (\vec{w} \cdot \vec{x}) + b \quad (1)$$

donde se desea maximizar el margen, tal como se presenta en la figura 1.

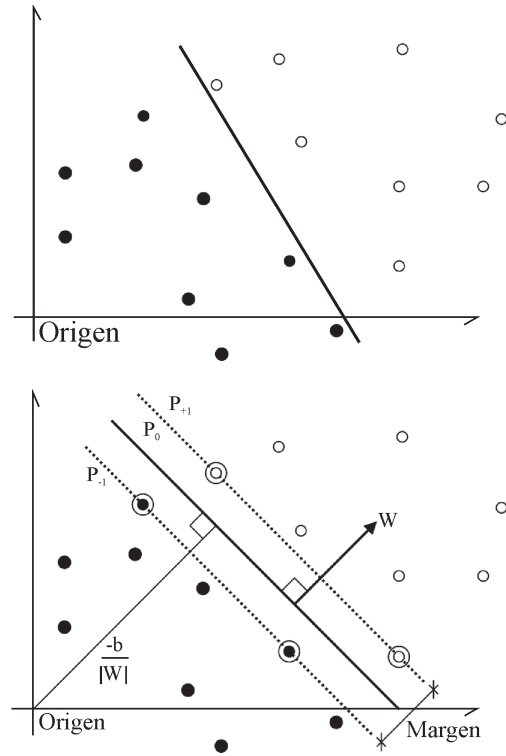


Figura 1 Hiperplanos que separan correctamente los datos. El OSH de la derecha tiene un mayor margen de separación entre clases, por lo tanto se espera una mejor generalización

La función decisión $f_{w,b}(\vec{x}_i) = y_i$, se puede definir como el signo que resulta de evaluar un dato en (1) y se muestra en (2).

$$f_{w,b}(\vec{x}_i) = \text{sign}[g(\vec{x}_i)] = \text{sign}[(\vec{w} \cdot \vec{x}) + b] \quad (2)$$

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

Si existen datos erróneos, ruido o alto solapamiento de clases en los datos de entrenamiento, puede afectar el hiperplano clasificador óptimo. 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 introduciendo una variable de relajación (3).

$$\varepsilon_i \geq 0, \forall i \quad (3)$$

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 a través de una función no lineal elegida a priori [12], ver figura 2, donde por medio

de una función (Φ) se trazan los datos de entrada ($x_i \in \mathbb{R}^N$), a algún espacio (de mayor dimensión y con producto punto) denominado espacio característico (F). Así la ecuación (1) que depende del producto punto de los vectores en el espacio de entrada, se transforma en una función que depende del producto punto de los vectores en el espacio característico. Tal función se define en (4).




Figura 2 La SVM no lineal mapea el espacio de entrada en otro de representación de dimensión alta y luego construye un OSH sobre este último, cuya representación en el espacio de entrada es una función de separación no lineal

$$k(\vec{u}, \vec{v}) = \Phi(\vec{u}) \cdot \Phi(\vec{v}) \quad (4)$$

debido a que F es de alta dimensión, el lado derecho de (4) es costosa en términos computacionales, sin embargo existe una función kernel (k), que se puede evaluar eficazmente y demostrar que corresponde a un mapeo de (Φ) en un espacio que abarca todos los productos punto [12].

Los kernels más utilizados se muestran en las ecuaciones (5), (6) (7).

- Polinomial:

$$k(\vec{u}, \vec{v}) = [(\vec{u} \cdot \vec{v}) + c]^d \text{ para } c > 0 \quad (5)$$

- Función de base radial (RBF):

$$k(\vec{u}, \vec{v}) = e^{\left(-\frac{\|\vec{u} - \vec{v}\|^2}{2\sigma} \right)} \quad (6)$$

- Sigmoide:

$$k(\vec{u}, \vec{v}) = \tanh[\kappa(\vec{u} \cdot \vec{v}) + \Theta] \quad (7)$$

Utilizando, además, los multiplicadores de Lagrange, el teorema dual de Wolfe y realizando algunas sustituciones, se obtiene el problema final de optimización [12] presentado en la ecuación (8).

$$\begin{aligned} \max_{\alpha} \quad & \sum_{i=1}^n \alpha_i - \frac{1}{2} \left[\sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j k(\vec{x}_i, \vec{x}_j) \right] \\ \text{sujeto a} \quad & 0 \leq \alpha_i \leq C, \forall i \\ & \sum_{i=1}^n \alpha_i y_i = 0 \end{aligned} \quad (8)$$

donde la función decisión se expresa como se presenta en la ecuación (9).

$$f(\vec{x}) = \text{sign} \left(\sum_{i=1}^n [\alpha_i y_i k(\vec{x}_i, \vec{x})] + b \right) \quad (9)$$

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 las SVM biclasificadoras manejar problemas de multclasificación con mayor simplicidad y/o menor tiempo de respuesta que una SVM generalizada para multclasificación [14].

Caracterización del Sistema en Falla

La metodología propuesta utiliza los valores eficaces de tensión y corriente de fase y línea antes y durante la falla, de donde se obtienen seis valores eficaces de tensión y corriente.

Definición de descriptor

Un descriptor es una característica tomada de una señal, que de algún modo aporta información sobre un evento. Los descriptores proporcionan toda la información necesaria para el aprendizaje de una herramienta de inteligencia artificial. En este trabajo se busca caracterizar una determinada zona de falla con descriptores obtenidos de las medidas tomadas en las subestaciones de distribución.

Se tiene como un objetivo importante utilizar descriptores sencillos de adquirir para no comprometer el buen funcionamiento del modelo, con la incertidumbre asociada a los aparatos de

medida y procesos numéricos aplicados a las señales. Considerando lo anterior, se propone trabajar únicamente con variaciones de tensión y de corriente.

Desde la primera propuesta de localización de fallas con inteligencia artificial [14], y pese a que los resultados obtenidos fueron satisfactorios, se eliminó el descriptor de pendiente (debido a que la parte transitoria de la señal entorpece la adquisición de este valor, adicionando así incertidumbre al proceso) y se mejoró el descriptor de la profundidad del hueco sin comprometer el buen desempeño del modelo.

Descriptores propuestos

En la figura 3 se muestra el comportamiento de las tensiones eficaces ante una falla monofásica en la fase A, ubicada en dos lugares distintos (distan 34,6 kilómetros uno del otro). Se puede ver que dos fallas monofásicas ubicadas en dos lugares diferentes dentro del sistema de distribución, vistas desde la subestación podrían producir huecos similares en la fase fallada, figura 3. Se concluye que solo la información de la fase fallada no es suficiente para determinar la ubicación del evento, pero al observar el comportamiento de las fases no falladas y las tensiones de línea se obtiene una marcada diferencia entre estas fallas. Por ello se propone trabajar con todas las señales de tensión y corriente de fase y de línea (no únicamente con la información de la fase fallada).

Los descriptores que se proponen son las variaciones de tensión y corriente de fase y de línea (dV, dVL, dI, dIL). Para obtener esta variación se requiere del valor eficaz de la fundamental de prefalla y de falla en estado estable, y el descriptor corresponde a la diferencia de estas magnitudes. En la figura 4 se presentan de forma gráfica los descriptores de tensión para cada una de las fases. Los descriptores de las señales de corriente se obtienen de manera análoga. Al utilizar los valores de prefalla implícitamente los descriptores se relacionan con la carga actual del sistema, de esta manera los descriptores son más robustos ante variación de carga, así se entrena únicamente en condiciones de carga nominal [15].




Figura 3 Comportamiento de las tensiones de fase y de línea ante una falla monofásica en la fase A en dos lugares distintos




Figura 4 Descriptores de la variación del valor eficaz de tensión

Metodología

Zonificación de la red

La zona es donde se desea discriminar la ubicación de la falla y su escogencia se basa en la topología del circuito. Primero se zonifica el circuito por cada ramal que tenga el sistema de distribución, luego se

hacen zonas cada vez más pequeñas para reducir cada vez más el área donde ha ocurrido la falla.

Adquisición de datos de falla

Los datos de falla son necesarios para la creación de una base de datos que contenga las señales vistas en la subestación cuando ha ocurrido una falla en el sistema de distribución. Esta se puede obtener, ya sea con base en el historial de fallas existente en la subestación o con la simulación del sistema bajo falla con algún software especializado. Una gran ventaja que ofrece la metodología propuesta es que se puede simular según el modelo que se tenga, es decir se adapta la solución del problema al modelo y no se tiene que adaptar el modelo al método (como ocurre con los métodos algorítmicos de distancia).

Adquisición de descriptores

Los descriptores se obtienen del valor eficaz de las tensiones y corrientes de fase y de línea para cada falla. Se aconseja realizar un filtrado a las señales, para trabajar solo con la componente fundamental y evitar posibles efectos negativos sobre la localización de fallas. Seguidamente se obtienen los descriptores para cada falla. Estos a su vez se agrupan y etiquetan dependiendo de la zona a la cual pertenece la falla. Se realiza un escalamiento simple a los descriptores (entre $[-1,1]$ o $[0,1]$ [14]). Este paso es importante para evitar dificultades numéricas durante los cálculos.

Los descriptores se deben dividir en dos grupos, uno se utilizará en la etapa de entrenamiento y con el otro grupo se probará la capacidad de aprendizaje de la SVM ya entrenada.

Entrenamiento de la SVM

Como se vió anteriormente, las máquinas de soporte vectorial necesitan la definición a priori tanto del parámetro de penalización C , como de la función kernel y sus respectivos parámetros. Para el modelo se utiliza la función kernel RBF, el parámetro de la función kernel y el parámetro de penalización se determinan mediante validación cruzada y búsqueda en malla [14, 16].

Prueba

Con el fin de obtener la precisión final del modelo, se realiza una prueba última con datos desconocidos (estos datos no fueron utilizados en la etapa de entrenamiento de la SVM).

$$\% \text{Precisión} = \frac{\# \text{datos prueba clasificados correctamente}}{\# \text{total datos prueba}} \times 100 \quad (10)$$

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.

Pruebas y Resultados

Sistema de pruebas

Se utilizó como circuito de prueba el sistema de distribución de 25 kV de Saskatoon Power and Light de Saskatchewan (Canadá), presentado en [5]. El diagrama unifilar del sistema se muestra en la figura 5. Este circuito de pruebas ha sido utilizado para pruebas de distintos métodos de localización de fallas [1, 7, 14, 15].

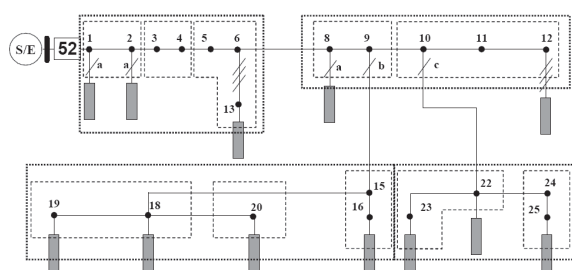


Figura 5 Diagrama unifilar del sistema de pruebas

Descripción de las pruebas

Distintas zonificaciones del sistema son propuestas para realizar las pruebas de desempeño del localizador, de tal forma que existan varios escenarios exigentes desde el punto de vista de clasifi-

Estos son generalmente el 20 % de la base total de datos y se extraen justo antes de la etapa de entrenamiento de la SVM. Se define la precisión como el porcentaje de fallas que fueron localizadas correctamente como se muestra en (10).

cación. Se definen tres escenarios de zonificación diferentes, en los cuales se aprecia la variación del número de nodos por zona y la capacidad de localizar la zona en falla. En la figura 5 se muestran los escenarios de zonificación propuestos, donde la primera zonificación comprende cuatro zonas (líneas punteadas en la figura 5), la segunda zonificación tiene 10 zonas (líneas a trazos en la figura 5) y por último se hace una zona por cada barra, es decir se tienen 21 zonas.

Se desarrolló una toolbox en MATLAB para manejar las SVM y así para realizar las pruebas pertinentes. En la figura 6 se muestra la interfaz gráfica. Los detalles de esta toolbox se muestran en [14].

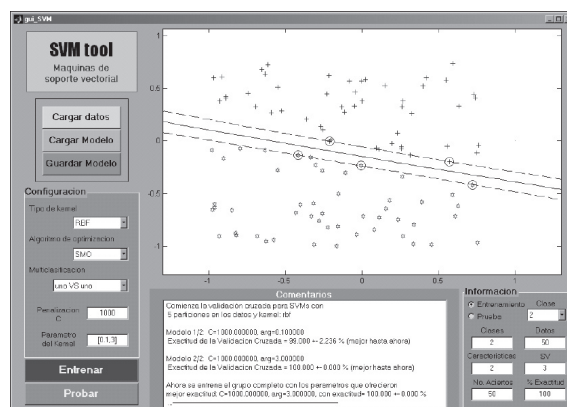


Figura 6 Interfaz gráfica de la toolbox de SVM desarrollada en MATLAB

Para cada escenario, en condición nominal, la cantidad de datos de entrenamiento corresponden a 225 registros de falla (24 % del total de datos); y 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.

Resultados de las pruebas

Se muestran resultados para el tipo de falla monofásico debido a que este tipo es muy crítico además de ser el más común, sin embargo los resultados de las pruebas de los tipos de fallas bifásicas, bifásica a tierra y trifásicas son superiores a los aquí presentados.

La tabla 1 muestra los resultados para distintas combinaciones de grupos de dos, tres o cuatro descriptores, en caso del sistema dividido en cuatro, diez, y veintiún zonas. Esta combinación de descriptores se realiza para determinar el mejor conjunto de entrada para la localización de la falla mediante el indicador de precisión. Los resultados de precisión para cada caso se obtienen de la ecuación (10). Se observa que el juego de descriptores de mayor precisión es la combinación dV y dI, pero en general los resultados son superiores al 95 %.

Tabla 1 Resultados de precisión (%) para todas las zonificaciones en condiciones nominales

	Zonas			
	4	10	21	Prom
dV_dI	100	96,69	96,22	97,6
dVL_dI	100	96,57	96,22	97,60
dVL_dI_dIL	100	96,34	96,34	97,56
dV_dVL_dI_dIL	100	96,34	96,22	97,52
dV_dVL_dI	100	96,22	96,22	97,48
dV_dI_dIL	100	96,22	96,22	97,48
dV_dVL	100	97,64	94,68	97,44
dV_dVL_dIL	100	96,34	94,68	97,01
dI_dIL	100	96,22	93,97	96,73
dV_dIL	100	96,22	91,37	95,86
dVL_dIL	98,33	96,34	91,49	95,39

Sensibilidad ante variación de carga

El rendimiento de estas zonificaciones ante diferentes escenarios de carga se muestra en las Figuras 7, 8, 9 para los casos de cuatro, diez y veintiún zonas respectivamente. Vale la pena resaltar que se entrenó en estado nominal con 225 registros y se prueba en condiciones nominales con 720 registros y otras condiciones de carga (60 %, 80 %, 120 %, 140 % de la carga nominal) con 945 registros para cada caso, teniendo un total de 225 datos de entrenamiento (4,8 % del total de datos) y 4500 datos de prueba (95,2 % del total de datos) para cada zonificación.

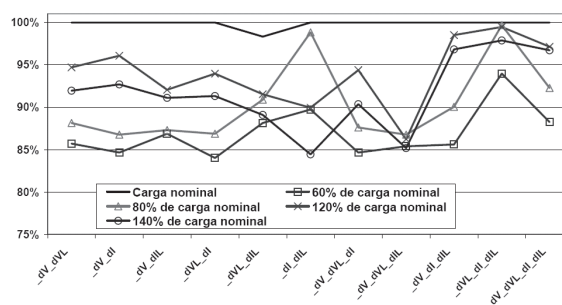


Figura 7 Gráfico comparativo de la precisión de las combinaciones de descriptores, en el caso de una zonificación de cuatro zonas, en caso de falla monofásica




Figura 8 Gráfico comparativo de la precisión de las combinaciones de descriptores, en el caso de una zonificación de 10 zonas, en caso de falla monofásica




Figura 9 Gráfico comparativo de la precisión de las combinaciones de descriptores, en el caso de una zonificación de 21 zonas, en caso de falla monofásica

Análisis de resultados

A partir de las pruebas se puede observar, como la precisión disminuye a medida que varía la carga del sistema entre el intervalo de 0,6 a 1,4 veces la carga nominal para una zonificación determinada, y entrenando el localizador SVM con datos tomados en condiciones nominales de carga. En la figura 10 se presenta una comparación gráfica de los valores de precisión promedio de todas las cargas para las distintas zonificaciones.




Figura 10 Gráfico comparativo de la precisión promedio para todas las zonificaciones, en caso de falla monofásica

La combinación de descriptores que mejor comportamiento presentan ante variación de carga es la variación de tensión (dV_dVL), debido a su poca variabilidad ante cambios de carga del sistema (a diferencia de la corriente). Esta afirmación

se ve sustentada en los resultados obtenidos, en los cuales la precisión del localizador decae considerablemente cuando se tiene en cuenta únicamente los descriptores relacionados con corriente (dI_dIL).

Cuando las zonas son cada vez más pequeñas, la precisión del localizador disminuye, figura 10. Entonces cuando se va a localizar una falla primero se observa el comportamiento del clasificador con menor número de zonas (en este caso 4 zonas), seguidamente se observa el comportamiento del clasificador siguiente con un número mayor de zonas (en este caso 10 zonas). Si el último resultado está contenido en la zona arrojada por el anterior localizador se habrá acotado la región de localización de la falla, este proceso se continúa realizando hasta que la siguiente zonificación (más pequeña que las anteriores) no coincida en el resultado, o hasta utilizar el último clasificador implementado. Esto se realiza para converger a la menor región con la probabilidad más alta de la ubicación de la falla debido a que el localizador con menor cantidad de zonas presenta un mejor comportamiento (debido a menor exigencia aplicada a las SVM y mejor caracterización de cada zona con mayor cantidad de datos).

Conclusiones

Se ha presentado una metodología para localizar fallas en sistemas de distribución teniendo en cuenta las características de estos, empleando SVM. El sistema se caracteriza con descriptores que fueron utilizados para la etapa de entrenamiento y prueba ante diferentes casos de variación de carga.

Se muestra un alto desempeño del método aquí propuesto, comparable en resultados con métodos clásicos que estiman la distancia a la falla y ofreciendo la ventaja de una única estimación en caso de haber ramificaciones (solución al problema de la múltiple estimación). El localizador de fallas con descriptores de tensión entrenado con aproximadamente el 4,8 % (225 registros) del total de los datos, muestra resultados superiores al 87 % probado con el resto de los datos (4500 registros).

Con ayuda de la metodología propuesta se puede reducir considerablemente el tiempo de restauración del sistema fallado, aumentando así los índices de continuidad del servicio de energía eléctrica y reduciendo, por consiguiente, los pagos por compensaciones debidas a una deficiente calidad del servicio.

Referencias

1. G. Morales, H. Vargas, J. Mora. "Impedance based method to fault location in power distribution, considering tapped loads and heavy unbalanced systems". *Proc. XII encuentro regional Iberoamericano del CIGRÉ*. Foz de Iguazú, Brasil. 2007.
2. J. Zhu, D. Lubkeman, A. Girgis. "Automated fault location and diagnosis on electric power distribution feeders". *IEEE Transactions on Power Delivery*. Vol. 12. 1997. pp. 801-809.
3. R. Aggarwal, Y. Aslan, A. Johns. "New concept in fault location for overhead distribution systems using superimposed components". *IEE Proc.-Gener. Trans. Distrib.* Vol. 144. 1997. pp. 309-304.
4. D. Novosel, D. Hart, Y. Hu, J. Myllymaki. "System for locating faults and estimating fault resistance in distribution networks with tapped loads". US Patent number 5,839,093. 1998.
5. R. Das. *Determining the Locations of Faults in Distribution Systems*. Saskatoon. Canada: Doctoral Thesis, University of Saskatchewan. 1998.
6. J. Mora. *Localización de faltas en sistemas de distribución de energía eléctrica usando métodos basados en el modelo y métodos basados en el conocimiento*. Girona, España: Tesis doctoral, Universidad de Girona. 2006.
7. G. Morales, H. Vargas, J. Mora. "Método de localización de fallas en sistemas de distribución basado en gráficas de reactancia". *Revista Scientia et Técnica*. Vol. 34. 2007. pp. 49-54.
8. *IEEE Guide for Determining Fault Location on AC Transmission and Distribution Lines*. IEEE Std 37.114. Power System Relaying Committee 2004.
9. G. Morales, J. Mora, G. Carrillo. "Evaluación comparativa de tres métodos de clasificación aplicados al problema de la localización de fallas de cortocircuito en sistemas de distribución de energía eléctrica". *Revista Scientia et Técnica*. Vol. 35. 2007. pp. 19-24.
10. C. Burges. "A tutorial on support vector machines for pattern recognition". *Data Mining And Knowledge Discovery*. Vol. 2. 1998. pp. 121-167.
11. R. Henao, F. Ojeda, M. Orozco, G. Castellanos. "Identificación de estados funcionales en bioseñales empleando SVM". *Proc. II Congreso Internacional de Inteligencia Computacional*. Medellín 2003.
12. B. Schölkopf, A. Smola. *Learning with Kernels Support Vector Machines, Regularization, Optimization and Beyond*. The MIT Press. Cambridge. 2002.
13. V. Vapnik. *The nature of statistical learning theory*. Springer Verlag. New York. 1995. pp. 17-55
14. G. Morales, A. Gómez. *Estudio e implementación de una herramienta basada en Máquinas de Soporte Vectorial aplicada a la localización de fallas en sistemas de distribución*. Bucaramanga, Colombia: Tesis de grado, Universidad Industrial de Santander, 2005. [Online]. Available: <http://tangara.uis.edu.co/biblioweb/pags/cat/popup/derautor.jsp?parametros=118738>. Consultada en mayo de 2007.
15. G. Morales, J. Mora, S. Pérez. "Análisis del desempeño de un localizador de fallas basado en svm ante la variación de carga en el sistema de distribución". *Revista Scientia et Técnica*. Vol. 32. 2006. pp. 7-12.
16. C. W. Hsu, C. C. Chang, C. J. Lin. *A practical guide to support vector classification*. Department of Computer Science, National Taiwan University, Tech. Rep., 2003. [Online]. Available: <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf> Consultada en mayo de 2007.