

Aplicación del análisis de componente principal y redes neuronales en la identificación de oscilaciones de potencia

Ernesto Vázquez, Oscar L. Chacón, Héctor J. Altuve*

Resumen

Los relevadores de distancia tienen tendencia a operar incorrectamente durante oscilaciones de potencia, originadas por disturbios en la red eléctrica. Actualmente existen distintos métodos para bloquear la operación de los relevadores en estas condiciones, los cuales no son completamente efectivos debido al carácter dinámico de estos fenómenos. En este trabajo se estudia la aplicación del análisis de componente principal (ACP) en forma conjunta con redes neuronales (RN) para la identificación de oscilaciones de potencia en sistemas eléctricos de potencia. Finalmente se muestran los resultados obtenidos para un caso de simulación, en el cual se aprecian las ventajas de aplicar el ACP para la solución de este problema.

Palabras Claves: Oscilaciones de potencia, redes neuronales, análisis de componentes principales.

I. INTRODUCCIÓN

Las oscilaciones de potencia entre máquinas síncronas de un sistema eléctrico de potencia se originan, por lo general, como consecuencia de la eliminación tardía de un cortocircuito, o por la desconexión de una línea de enlace o una planta generadora por cualquier causa. En los casos más graves puede llegarse a la pérdida de sincronismo entre las máquinas del sistema.¹ La frecuencia de estas oscilaciones puede ser desde menos de 1 Hz hasta varios Hz. Las bajas frecuencias son típicas de sistemas eléctricos fuertes y de los primeros instantes de la oscilación; en sistemas débiles y en ciclos de oscilación posteriores al primero se tienen las frecuencias más elevadas.

En estas condiciones, los relevadores de distancia tienen por lo general tendencia a operar durante las oscilaciones de potencia, ya que éstas



provocan (al igual que los cortocircuitos) elevaciones de la corriente y reducciones del voltaje. Tal operación de los relevadores no es deseable, pues puede afectar al sistema en situaciones que no necesariamente son críticas.

A fin de evitar la operación incorrecta de los relevadores por efecto de las oscilaciones de potencia se utilizan esquemas de bloqueo; la función de estos esquemas es impedir la operación de la protección durante las oscilaciones de potencia y permitir la operación durante cortocircuitos. Para que la función de bloqueo opere correctamente, es necesario discriminar el comportamiento de las variables eléctricas (voltaje, corriente, impedancia, etc.) durante oscilaciones de potencia y durante cortocircuitos. No obstante, debido a que la oscilación de potencia es un fenómeno que depende del comportamiento dinámico de los generadores del sistema, la razón de cambio de las variables eléctricas asociadas no es constante, y puede presentar amplios intervalos de variación, dependiendo de diversos factores; este comportamiento constituye un problema en la

* Universidad Autónoma de Nuevo León, Facultad de Ingeniería Mecánica y Eléctrica. Doctorado en Ingeniería Eléctrica A.P-89-F, Cd. Universitaria, San Nicolás, 66450, N.L., México. evazquez@gama.fime.uanl.mx

selección del principio de funcionamiento y de los parámetros de ajuste del esquema de bloqueo.¹⁻⁵ Actualmente existen distintos esquemas de bloqueo, basados en los siguientes criterios:

- Medición de la razón de cambio de la impedancia aparente.
- Medición de la razón de cambio de la resistencia aparente.
- Medición de la razón de cambio de la corriente.
- Medición de la razón de cambio de una componente del voltaje.
- Estimación del ángulo del voltaje.

No obstante, debido a que la oscilación de potencia es un fenómeno que depende del comportamiento dinámico de los generadores del sistema eléctrico de potencia, la razón de cambio de las variables eléctricas asociadas no es constante, y puede presentar amplios intervalos de variación, dependiendo de diversos factores; este comportamiento constituye un problema en la selección del principio de funcionamiento y de los parámetros de ajuste del esquema de bloqueo.

En este artículo se propone la utilización del Análisis de Componente Principal para capturar el comportamiento de las variables eléctricas durante oscilaciones de potencia en un subespacio de menor dimensión que permita diseñar un esquema de bloqueo efectivo.

II. EFECTO DE LAS OSCILACIONES DE POTENCIA SOBRE LOS RELEVADORES DE DISTANCIA

La impedancia aparente ($Z = V / I$, donde V e I son el voltaje y la corriente en la ubicación del relevador) medida por un relevador de distancia en estado estable es prácticamente constante, pero su

valor varía con el tiempo durante cortocircuitos, oscilaciones de potencia y pérdidas de sincronismo. Las variaciones de esta impedancia pueden representarse como trayectorias en el plano complejo impedancia como se muestra en la Fig. 1 (trayectorias 1, 2 y 3). Normalmente el origen de coordenadas corresponde a la ubicación del relevador y las variaciones de la impedancia medida para cortocircuitos en la dirección de operación del relevador se representan como trayectorias en el primer cuadrante. Para el análisis, es conveniente superponer las características de operación del relevador en el mismo plano; esta característica es representada por el círculo 4, para el caso de una primera zona de un relevador de distancia tipo mho ajustada para proteger el 80% de la línea de transmisión AB (línea 5).

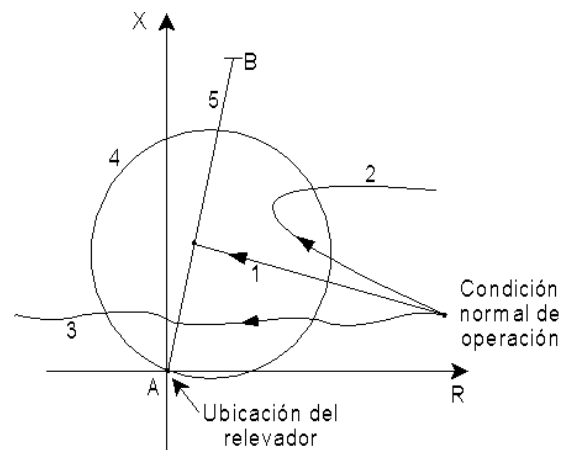


Fig. 1. Efecto de las oscilaciones de potencia y pérdidas de sincronismo sobre los relevadores de distancia.

A partir de una condición normal de operación, un cortocircuito es visto por el relevador como una trayectoria de impedancia similar a la trayectoria 1, que termina en un punto de la impedancia de la

línea de transmisión, dentro de la característica de operación del relevador, ocasionando que éste opere. Durante una oscilación de potencia (trayectoria 2) o una pérdida de sincronismo (trayectoria 3), la trayectoria de impedancia puede penetrar en la zona de operación del relevador, pudiendo operar en forma incorrecta. Esto se debe a que durante estas condiciones, el relevador mide una impedancia muy similar a la que mediría durante un cortocircuito trifásico.^{1,3}

En el caso de un sistema de potencia de dos máquinas, las trayectorias de impedancia en el plano complejo se pueden representar por una línea recta o circunferencias. Sin embargo, en sistemas multimáquinas las trayectorias son más complejas. En ese caso es imprescindible simular el sistema en una computadora digital en cuanto a su comportamiento durante oscilaciones transitorias electromecánicas.

El método más utilizado para el bloqueo de protecciones de distancia es el de la razón de cambio de la impedancia, que se basa en el hecho de que la impedancia medida por el relevador se desplaza por el plano complejo impedancia con distintas velocidades dependiendo de si se trata de un cortocircuito, una oscilación o una pérdida de sincronismo. Esto se debe a que un cortocircuito es un transitorio electromagnético, con constantes de tiempo muy pequeñas, por lo que este tipo de transición es muy rápida (trayectoria 1), mientras que las oscilaciones de potencia y las pérdidas de sincronismo son fenómenos transitorios electromecánicos (dependen de la dinámica de los rotores de los generadores) que tienen asociadas constantes de tiempo más grandes y que se manifiestan como transiciones lentas (trayectorias 2 y 3). No obstante, este método tiene problemas durante oscilaciones de potencia rápidas, como las que ocurren durante pérdidas de sincronismo en

sistemas eléctricos débiles, que se confunden con cortocircuitos, y que provocan la operación incorrecta de los relevadores de distancia.¹

III. ANALISIS DE COMPONENTE PRINCIPAL

Un método muy utilizado en estadística para el análisis de datos es el análisis de componente principal (ACP) equivalente a la maximización del contenido de la información en señales de salida con distribución gaussiana.⁶ El objetivo de este método es el determinar un conjunto de m vectores ortogonales en el espacio de datos que contengan la mayor información posible de la varianza de los mismos. Con la proyección de los datos del espacio p -dimensional original (generalmente $p > m$), sobre el subespacio m -dimensional generado por estos vectores, se forman agrupamientos (clusters) que son más viables a ser clasificados mediante la proyección en una dirección de gran varianza, como se muestra en la Fig. 2.




Fig. 2. Concepto de análisis de componente principal.

En la Fig. 2, OA es la dirección del mayor componente principal de la distribución generada por la agrupación de puntos, y OB es la dirección del segundo mayor componente principal. La proyección sobre OA muestra más estructura que la proyección sobre OB, por lo que los agrupamientos

son más viables a ser identificados por su proyección en direcciones de gran varianza. Por consiguiente, la reducción en dimensionalidad en el ACP puede retener la mayoría de información intrínseca de los datos.

La técnica de análisis de componente principal (ACP) es apropiada en casos en los cuales no se dispone de una variable dependiente o un conjunto de variables como en el caso de regresión múltiple. La técnica ACP transforma un conjunto de variables correlacionadas en un conjunto de variables no correlacionadas, y simplifica la transformación encontrando los componentes más cercanos a las variables originales pero ordenados en forma decreciente al orden de su varianza. Esta transformación de hecho es una rotación ortogonal en el espacio de las variables originales.

A. Obtención de los componentes principales ⁶

Supongamos que $x=[x_1 \ x_2 \ \dots \ x_p]$ sea una variable estocástica p-dimensional con media μ y matriz de covarianza Σ . El problema consiste en determinar un nuevo conjunto de variables $[y_1, y_2, \dots, y_p]$ que no estén relacionadas y cuya varianza decrece de la primera a la última. Cada una de estas variables y_j se toma como una combinación lineal de las variables x_i de tal forma que:

$$\begin{aligned} y_j &= a_{1,j}x_1 + a_{2,j}x_2 + \dots + a_{p,j}x_p \\ y_j &= a_j'x \end{aligned} \tag{1}$$

siendo $a_j'=[a_{1,j} \ a_{2,j} \ \dots \ a_{p,j}]$ con la condición de que $\|a_j\|_2=1$; esto es, $a_j'a_j=1$, lo cual asegura que la transformación global sea ortogonal o que se preserven las distancias en el espacio p-dimensional.

El primer componente principal y_1 se determina seleccionando a_1 de tal forma que maximice la varianza de $y_1 = a_1'x$ sujeto a la restricción de que $a_1'a_1=1$. El segundo componente principal y_2 se determina seleccionando a_2 de tal forma que y_2 tenga la mayor varianza pero que no esté correlacionada con y_1 . En forma similar se puede proceder para y_3, y_4, \dots, y_p con varianza decreciente y que no estén correlacionados.

Para determinar y_1 se selecciona la varianza de y_1 como la función objetivo a maximizar, con respecto a a_1 , con la restricción de que $a_1'a_1=1$. Por consiguiente:

$$\begin{aligned} Var(y_1) &= Var(a_1'x) \\ &= E((a_1'x)^2) \\ &= a_1'E((x-\mu)(x-\mu)')a_1 \\ Var(y_1) &= a_1'\Sigma a_1 \end{aligned} \tag{2}$$

El problema para determinar la solución óptima de y_1 es:

$$\max a_1'\Sigma a_1, \text{ s.a. } a_1'a_1=1 \tag{3}$$

Formando el lagrangiano:

$$L(a_1) = a_1'\Sigma a_1 - \lambda(a_1'a_1 - 1) \tag{4}$$

y estableciendo las condiciones de optimalidad:

$$\frac{\partial L}{\partial a_1} = 2\Sigma a_1 - 2\lambda a_1 = 0 \tag{5}$$

o bien:

$$2(\Sigma - \lambda I)a_1 = 0 \tag{6}$$

Se observa que la solución no trivial de (6) es el eigenvalor λ_1 y el eigenvector a_1 de Σ . Pero como Σ es una matriz positiva semidefinida, ésta tiene p valores característicos $\lambda_1, \lambda_2, \dots, \lambda_p \geq 0$. Considerando que los eigenvalores son distintos y que $\lambda_1 > \lambda_2 > \dots > \lambda_p \geq 0$, surge la pregunta de como determinar el primer componente principal. En primera instancia se determina la máxima varianza de y_1 :

$$\begin{aligned} \text{Var}_{\max}(y_1) &= \text{Var}_{\max}(a_1'x) \\ \text{Var}_{\max}(y_1) &= a_1'(\Sigma a_1)_{\max} \\ \text{Var}_{\max}(y_1) &= a_1' \lambda a_1 \\ \text{Var}_{\max}(y_1) &= \lambda a_1' a_1 \\ \text{Var}_{\max}(y_1) &= \lambda \end{aligned}$$

(7)

Se aprecia que al maximizar la varianza de y_1 se selecciona el mayor valor característico λ_1 de Σ ; es decir, el componente principal a_1 es el eigenvector asociado al mayor valor característico λ_1 .

Siguiendo el mismo procedimiento se encuentra que el j -ésimo componente principal a_j corresponde al eigenvector asociado al j -ésimo mayor eigenvalor λ_j . Denotando por \mathbf{A} a la matriz de eigenvectores:

$$\mathbf{A} = [a_1, a_2, \dots, a_p]$$

(8)

y a y por el vector de componentes principales, entonces:

$$y = \mathbf{A}'x$$

(9)

La matriz de covarianza de y se denota por Λ , y está dada por

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_p \end{bmatrix}$$

(10)

ya que los componentes se seleccionan de tal forma que no estén correlacionados. Por lo tanto, de (9) se tiene:

$$\begin{aligned} \text{Var}(y) &= \text{Var}(\mathbf{A}'x) \\ &= \mathbf{A}'\text{Var}(x) \\ &= \mathbf{A}'\Sigma\mathbf{A} \end{aligned}$$

(11)

Pero como $\text{Var}(y) = \Lambda$:

$$\Lambda = \mathbf{A}'\Sigma\mathbf{A}$$

(12)

Como \mathbf{A} es una matriz ortonormal, la ecuación (12) puede reescribirse como:

$$\Sigma = \mathbf{A}\Lambda\mathbf{A}'$$

(13)

Por lo tanto, las varianzas de los diferentes componentes se pueden interpretar como los valores característicos de \mathbf{A} . La suma de estas varianzas esta dada por:

$$\sum_{i=1}^p \text{Var}(y_i) = \sum_{i=1}^p \lambda_i = \text{traza}(\Lambda)$$

(14)

de donde:

$$\begin{aligned} \text{traza}(\Lambda) &= \text{traza}(\mathbf{A}'\Sigma\mathbf{A}) \\ &= \text{traza}(\Sigma\mathbf{A}\mathbf{A}') \\ &= \text{traza}(\Sigma) \\ &= \sum_{i=1}^p \text{Var}(x_i) \end{aligned}$$

(15)

se tiene que la suma de las varianzas de las variables originales y la suma de las varianzas de los componentes principales son las mismas.

IV. REDES NEURONALES PARA EXTRACCIÓN DE COMPONENTES PRINCIPALES

Las redes neuronales son un sistema de mapeo no lineal cuya estructura está basada en principios observados en el sistema nervioso. La idea básica es que un sistema masivo de unidades simples de procesamiento de información, interconectadas de una manera apropiada, pueda generar muchos comportamientos o resultados complejos.

Existen casos en el procesamiento de señales en el cual no se dispone del par asociado de entrada (señal) – salida (respuesta del sistema) mediante la cual se pueda diseñar una red neuronal de multicapas de perceptrones con ajuste de parámetros basados en supervisión, que representen un modelo no lineal del sistema. En estas condiciones lo conveniente es el uso de una red neuronal con aprendizaje de parámetros sin supervisión, o de aprendizaje con auto-organización. En este tipo de red neuronal, ésta debe descubrir por sí misma (sin supervisión) cualquier relación de interés que pueda existir en las señales de entrada y transmitir las hacia la salida.

Una red neuronal con aprendizaje sin supervisión puede establecer la similitud entre un patrón de entrada y los patrones vistos anteriormente, y aprender gradualmente a identificar los patrones típicos (similaridad); puede construir un conjunto de ejes para medir similitudes respecto a patrones previos (*Principal Component Analysis*); puede formar categorías sobre la base de correlaciones de los patrones de entrada y decir a que categoría pertenece un patrón de entrada dado

(*Clustering*) o dar como salida un prototipo apropiado (*Adaptive Vector Quantization AVQ*); o puede hacer un mapeo topográfico de las entradas de tal forma que patrones similares de entrada activen los nodos de salida (*Feature Mapping*).⁶

En los sistemas neuronales con auto-organización, las neuronas cercanas compiten en sus actividades por medio de interacciones laterales mutuas, desarrollándose de una manera adaptiva hacia detectores específicos de diferentes patrones de señales, similares a los encontrados en el cerebro humano. Esta propiedad de los sistemas con auto-organización se puede usar para descubrir o extraer rasgos distintivos de los datos de entrada.

A. Algoritmo de aprendizaje Hebbiano para el primer componente principal normalizado

Para la estimación del primer componente principal \hat{y}_1 y su eigenvector asociado \hat{w}_1 de la matriz de correlación Σ , Oja⁷ propuso una unidad de procesamiento simple $\hat{y}_1 = \hat{w}_1' x$, utilizando un algoritmo de aprendizaje (corrección a los pesos \hat{w}_1) que determine el vector \hat{w}_1 con las siguientes propiedades:

- Valor normalizado de 1, i.e. $\|\hat{w}_1\|_2 = 1$, \hat{w}_1 es de $(n \times 1)$.
- Es una aproximación al eigenvector de la matriz de correlación Σ .
- Maximiza la varianza de la salida \hat{y}_1 , que es el primer componente principal de los datos de entrada con media cero.

La regla de aprendizaje llamada regla Hebbiana o regla de Oja,⁸ se puede establecer como:

$$\hat{w}_{1,j}(k+1) = \hat{w}_{1,j}(k) + \eta(k) \hat{y}_1(k) [x_j(k) - \hat{y}_1(k) \hat{w}_{1,j}(k)]$$

$$j = 1, 2, \dots, n$$
(16)

o en forma matricial

$$\Delta \hat{w}_1(k) \equiv \hat{w}_1(k+1) - \hat{w}_1(k) = \eta(k) \hat{y}_1(k) [x(k) - \hat{y}_1(k) \hat{w}_1(k)]$$
(17)

donde $\eta(k) = 1/k^\gamma$, $1/2 \leq \gamma \leq 1$.

B. Algoritmos de aprendizaje adaptivo de un subespacio principal

Una red neuronal de dos capas para la extracción de un subespacio principal se muestra en la Fig. 3. La primera capa es la de las entradas $x_i(k)$ y contiene N neuronas que solamente alimentan el vector $x(k) = [x_1(k) \ x_2(k) \ x_3(k) \ \dots \ x_N(k)]^T$ a la segunda capa sin modificación. La segunda capa tiene M neuronas artificiales con función de actividad lineal (ADALINE), y está conectada a la primera capa mediante los pesos $w_j(k) = [w_{j1}(k) \ w_{j2}(k) \ w_{j3}(k) \ \dots \ w_{jN}(k)]^T$, donde $w_{ji}(k)$ representa la conexión entre la i -ésima neurona de entrada y la j -ésima neurona de salida, siendo M la dimensión del subespacio principal.⁹




Fig. 3. Red neuronal autoasociativa.

Oja⁸ propuso un algoritmo de aprendizaje sin supervisión para la actualización de la matriz de pesos W de la forma siguiente:

$$\Delta W(k) = \eta(k) [x(k) - W(k)y(k)] y^T(k)$$
(18)

donde

$$y(k) = W(k)x(k)$$

$$W = [w_1 \ w_2 \ \dots \ w_M]$$

V. APLICACIÓN DEL ACP EN LA IDENTIFICACIÓN DE OSCILACIONES DE POTENCIA

Para realizar el ACP se generaron señales de prueba a través de la simulación en MATLAB¹⁰ del sistema de potencia de prueba mostrado en la Fig. 4.




Fig. 4. Sistema de potencia de prueba.

Está compuesto por un generador de 100 MVA, 20 kV, 60 Hz, interconectado con un sistema infinito mediante dos transformadores y dos líneas paralelas, cuyas impedancias por unidad están indicadas en la Fig. 4. Los datos del generador, también expresados por unidad cuando corresponde, son los siguientes:

$$\begin{array}{llll} X_d=1.81 & X_q=1.76 & X'_d=0.3 & X'_q=0.65 \\ X''_d=X''_q=0.25 & X_2=0.25 & X_0=0.04 & R_a=0.003 \\ R_2=0.063 & R_0=0.005 & T'_{d0}=8.0 \text{ s} & T'_{q0}=1.0 \text{ s} \\ T''_{d0}=0.03 \text{ s} & T''_{q0}=0.07 \text{ s} & H=3.5 & K_D=0 \end{array}$$

La perturbación aplicada al sistema para provocar su pérdida de sincronismo consiste en la aparición de un cortocircuito trifásico en una de las líneas, y su eliminación por desconexión de la línea. El cortocircuito se mantiene durante 10 ciclos, que es un valor mayor que el tiempo crítico de estabilidad del sistema. El período de integración utilizado es de 1 ms, de modo que se obtienen valores fasoriales de voltaje y corriente espaciados 1 ms. Esto equivale a la información que se obtiene en un relevador digital con una frecuencia de muestreo de 960 Hz (16 muestras por ciclo), que es muy utilizada en relevadores comerciales.

En la Fig. 5 se muestran las gráficas correspondientes a las variaciones del módulo de la impedancia (z), el ángulo de la impedancia (Ang) la resistencia (r) y la reactancia (x) medidas en la ubicación del relevador durante el proceso transitorio posterior a la desconexión de la línea.




Fig. 5. Variables eléctricas medidas en la ubicación del relevador de la figura 4.

Se puede apreciar como después de la desconexión de la línea para eliminar el cortocircuito del sistema, inicia el proceso oscilatorio que corresponde a la oscilación de potencia que degenera en una pérdida de sincronismo.

Calculando los eigenvalores de la matriz de covarianza de estas variables se obtiene:

$$\lambda = \begin{bmatrix} 3.0706 & 0 & 0 & 0 \\ 0 & 0.73107 & 0 & 0 \\ 0 & 0 & 0.43041 & 0 \\ 0 & 0 & 0 & 0.10586 \end{bmatrix}$$

Se observa que los primeros valores característicos son los más dominantes (representan aproximadamente el 90% de $\Sigma\lambda_i$); por lo tanto, las componentes principales (las dos primeras) son los eigenvectores correspondientes a los eigenvalores de mayor valor, es decir:

$$A = \begin{bmatrix} 0.793 & -0.041 \\ 0.409 & 0.057 \\ 0.449 & 0.002 \\ -0.008 & -0.997 \end{bmatrix}$$

En la Fig. 6 se muestran las proyecciones de las variables originales sobre el subespacio las dos primeras componentes principales. Se puede observar que la información se agrupa en cuatro zonas bien definidas, la primera corresponde a la condición de pre-falla antes del cortocircuito (zona 1), la segunda es el cortocircuito (zona 2) y las dos últimas representan la oscilación de potencia posterior a la eliminación del cortocircuito (zonas 3). Analizando este comportamiento se puede concluir que es posible identificar en forma rápida y sencilla entre un cortocircuito y una oscilación de potencia. Esta tarea podría ser realizada por un perceptrón, ya que como se observa en la Fig. 6, la

información de componentes principales del cortocircuito y la oscilación de potencia es linealmente separable.




Fig. 6. Proyección de las variables eléctricas de la figura 5 en el subespacio de las dos primeras componentes principales.

Analizando la Fig. 6, se observa que existe gran similitud entre la condición pre-falla y la oscilación de potencia en el subespacio de las componentes principales. Sin embargo, ambas condiciones son similares en el hecho de que no deben provocar la operación de un relevador de distancia. Por tanto, solo es necesario entrenar un perceptrón para que discrimine los cortocircuitos de las oscilaciones de potencia y las condiciones de pre-falla.

VI. TRABAJO FUTURO

Los resultados obtenidos hasta el momento demuestran que la utilización del ACP permite analizar el comportamiento de las variables eléctricas en la ubicación de un relevador de distancia en el subespacio de las componentes

principales. En esta transformación se hace evidente el tipo de disturbio que ocurre en el sistema de potencia, con lo cual es posible diseñar un esquema de bloqueo por oscilaciones de potencia. Sin embargo, siguiendo el procedimiento descrito en este artículo, sería necesario contar con la información completa de las variables eléctricas antes de determinar sus proyecciones en el espacio de las componentes principales. En tiempo real, esto significa esperar a que termine el disturbio para emitir un juicio sobre lo que sucedió, cuando en realidad se desea determinar el tipo de disturbio mientras este está ocurriendo.

Una forma de resolver este problema es utilizar una red neuronal autoasociativa sin supervisión, donde la matriz de pesos obtenida en el entrenamiento corresponde a una aproximación de la matriz A de componentes principales. La función de esta red sería determinar la proyección de las variables eléctricas medidas por el relevador en el subespacio de las componentes principales en tiempo real. Con esta información disponible, se utilizaría un perceptrón para discriminar entre cortocircuitos y oscilaciones de potencia. El esquema final sería similar al indicado en la Fig. 7.




Fig. 7. Esquema propuesto para la identificación de oscilaciones de potencia en tiempo real.

VII. CONCLUSIONES

1. En este trabajo se describe la aplicación del ACP en forma conjunta con redes neuronales RN para la identificación de oscilaciones de potencia en sistemas eléctricos.

2. El objetivo del ACP es determinar un conjunto de m vectores ortogonales en el espacio de datos que contengan la mayor información posible de la varianza de los mismos, sobre los cuales se proyectarán los datos del espacio p -dimensional original sobre el subespacio m -dimensional generado por estos vectores.

3. Las componentes principales más representativas corresponden a los eigenvectores asociados a los eigenvalores de mayor valor de la matriz de covarianza de los datos. La proyección de los datos del espacio p sobre estas componentes caracteriza el comportamiento de los datos originales.

4. Se propone el diseño de un método de bloqueo por oscilaciones de potencia en base a la información de las proyecciones de las variables eléctricas en el subespacio de las componentes principales utilizando un perceptrón.

5. Finalmente se sugiere la aplicación de una red neuronal autoasociativa sin supervisión para determinar la proyección de las variables eléctricas medidas por el relevador en el subespacio de las componentes principales en tiempo real.

VIII. AGRADECIMIENTOS

Los autores agradecen al Consejo Nacional de Ciencia y Tecnología de México (CONACyT) por el apoyo recibido para la realización de este trabajo, a través del proyecto 28562A.

IX. REFERENCIAS

1. S. H. Horowitz and A. G. Phadke, *Power System Relaying*, Great Britain: Research Studies Press LTD., 1992.
2. A. G. Phadke and J. S. Thorp, *Computer Relaying for Power Systems*, Great Britain: Research Studies Press LTD., 1988.
3. V. Cook, *Analysis of Distance Protection*, Great Britain: Research Studies Press LTD., 1985.
4. F. Ilar, "Innovations in the detection of power swing in electrical networks," *Brown Boveri REV*, vol. 81, no. 2, pp. 87-93.
5. M. S. Sachdev (Coordinator), *Microprocessor Relays and Protection Systems*, IEEE Tutorial Course Text, Publication no. 88EH0269-1-PWR, February 1988.
6. S. Haykin, *Neural Networks*, New Jersey: Prentice-Hall, 1999.
7. E. Oja, "Neural networks, principal components and subspace," *Int. Journal on Neural Systems*, vol. 1, 1989, pp. 61-68.
8. A. Cichocki and R. Unbehauen, *Neural Networks for Optimization and Signal Processing*, Chichester: John Wiley, 1993.
9. F. L. Luo and R. Unbehauen, *Applied Neural Networks for Signal Processing*, Cambridge: Cambridge University Press, 1998.
10. *MATLAB 5.3*, The MathWorks, Inc., 1998.