

UN ENFOQUE COMPLEJO DE SEPARACIÓN CIEGA DE FUENTES PARA ESTIMAR LOS MODOS DE OSCILACIÓN ELECTROMECAÑICOS Y MODOS SHAPES A PARTIR DE MEDICIONES AMBIENTE DE ÁREA AMPLIA

A COMPLEX BLIND SOURCE SEPARATION APPROACH TO ESTIMATE ELECTROMECHANICAL OSCILLATION MODES AND MODE SHAPES FROM WIDE-AREA AMBIENT MEASUREMENTS

José J. Nuño-Ayón¹, Eduardo S. Bañuelos-Cabral², Jorge L. García-Sánchez³, Carlos A. López-de Alba⁴, J. Sotelo-Castañón⁵.

¹jose.nuno@academicos.udg.mx / ² eduardo.banuelos@academicos.udg.mx / ³ jorgel.garcias@academicos.udg.mx / ⁴ carlos.ldealba@academicos.udg.mx / ⁵ julian.sotelo@academicos.udg.mx

Recibido: octubre 17, 2019 / Aceptado: diciembre 15, 2019 / Publicado: febrero 18, 2020

Resumen. Los sistemas de medición de área amplia combinados con técnicas espacio-temporales permiten mejorar la identificación de los modos de oscilación electromecánicos y sus modos *shapes* con el fin de caracterizar el comportamiento dinámico de un sistema eléctrico de potencia de gran tamaño bajo condiciones ambiente. Sin embargo, las tendencias, el comportamiento no estacionario y el ruido en las mediciones son importantes retos para llevar a cabo la identificación y visualización de los modos oscilatorios y sus modos *shapes*. Por tales razones, una metodología que combina la transformada de Hilbert con el algoritmo de identificación ciega de segundo orden se propone en este artículo. El objetivo principal de la transformada de Hilbert es transformar los datos medidos en datos complejos para estimar señales fuente complejas y una matriz de mezclado compleja mediante el uso del algoritmo de identificación ciega de segundo orden. A partir de la información anterior, un conjunto de características dinámicas espacio-temporales son propuestas y obtenidas con el fin de caracterizar el comportamiento dinámico del sistema. Finalmente, datos ambiente son obtenidos a partir de un modelo de estabilidad transitoria del sistema eléctrico de Nueva York y Nueva Inglaterra para demostrar la eficacia de la metodología propuesta.

Palabras clave: separación ciega de fuentes, transformada de Hilbert, sistemas de medición de área amplia, modos de oscilación electromecánicos y modos *shapes*.

Abstract. Wide-area measurement systems combined with spatio-temporal techniques allow to improve the identification of electromechanical oscillation modes and their mode shapes in order to characterize the dynamic behavior of a large power system under ambient conditions. However, trends, nonstationary behavior and noise in measurements are important challenges for carrying out the identification and visualization of oscillatory modes and their mode shapes. For such reasons, a methodology that combines the Hilbert transform with the second-order blind identification algorithm is proposed in this paper. The main objective of the Hilbert transform is to transform the measured data in complex data for estimating complex source signals and a complex mixing matrix by using the second-order blind identification algorithm. From the above information, a set of space-temporal dynamic characteristics are proposed and obtained in order to characterize the dynamic behavior of system. Finally, ambient data are obtained from a transient stability model of the New England/New York power system for demonstrating the effectiveness of the proposed methodology.

Key Words: Blind source separation, Hilbert transform, wide-area measurement systems, electromechanical oscillation modes and mode shapes.

1. Introducción

Los sistemas de medición de área amplia basados en unidades de medición fasorial proporcionan una visión sin precedentes de la dinámica espacial y temporal de los procesos oscilatorios en los sistemas

eléctricos de potencia bajo condiciones ambiente. Un ejemplo de tales procesos, son los fenómenos de oscilación electromecánicas entre generadores o sistemas eléctricos interconectados, en el cual varios generadores o regiones que interactúan entre sí. Las oscilaciones electromecánicas son inherentes a los sistemas eléctricos de potencia. Estas oscilaciones se clasifican como modos interárea y modos locales, que típicamente tienen actividad oscilatoria en el rango de 0.10 Hz a 0.79 Hz (modos locales) y 0.80 Hz a 2 Hz (modos interárea). Las oscilaciones interárea se caracterizan por un grupo de generadores que oscilan en contra de otro grupo de generadores, mientras que los modos locales están relacionados con algún generador o planta y no son observables globalmente [1]. Ambas oscilaciones ocurren como modos particulares que están excitados por cambios en el sistema eléctrico de potencia, como variaciones de carga o fallas en la red. Si las oscilaciones interárea no están suficientemente amortiguadas, puede ocurrir una operación inestable, lo que puede conducir a una separación incontrolada del sistema eléctrico de potencia en islas y, en consecuencia, apagones. Por lo tanto, el análisis de los modos de oscilación electromecánicas mediante métodos basado en mediciones ambiente de área amplia es esencial, ya que pueden proporcionar información valiosa sobre las propiedades dinámicas y la estabilidad del sistema [2].

Una variedad de métodos espacio-temporales han sido aplicada para estimar las frecuencias y sus relaciones de amortiguamiento a partir de mediciones ambiente del sistema eléctrico de potencia, los cuales incluyen a: la identificación de subespacios [3], el análisis de componente independiente con decremento aleatorio [4], los modelos autorregresivos de naturaleza multivariable [5], la técnica de excitación natural con el algoritmo de realización *eigensystem* [6] y la identificación ciega de segundo orden combinado con decremento aleatorio y el algoritmo de realización *eigensystem* [7]. Aunque todos estos métodos ofrecen estimar las frecuencias oscilatorias y sus relaciones de amortiguamiento, estas técnicas no permiten determinar que componentes o elementos en el sistema eléctrico de potencia están participando en un modo electromecánico específico. Hay otras técnicas espacio-temporales, tales como el método de Ibrahim [8], el análisis de modos Koopman [9], la descomposición modal dinámica [10], la descomposición modal empírica multivariable [11], las cuales son ahora usadas rutinariamente para identificar información modal a partir de mediciones transitorias. Otras aplicaciones incluyen el análisis de coherencia [12]-[14], y la extracción de patrones espacio-temporales de baja frecuencia [15]. Sin embargo, todos los métodos mencionados han sido aplicados a mediciones sin ruido, el cual es un objetivo clave para esta investigación, así como la identificación del modo dinámico dominante. Además, los datos ambiente se correlacionan temporalmente y espacialmente, ocasionando que las técnicas de procesamiento de señales convencionales no siempre son apropiadas para analizar y modelar grandes conjuntos de datos ambiente provenientes de sensores espacialmente separados. Por lo tanto, en este artículo se presenta un enfoque complejo de separación ciega de fuente que aprovecha las correlaciones espaciales en los datos para la estimación de las señales fuente o modos oscilatorios y sus modos *shapes* a partir de datos ambiente simulados. La metodología propuesta es especialmente adecuada para el análisis de datos ambiente que contengan contribuciones de eventos cuyo comportamiento dinámico cambian en espacio y tiempo. Los resultados obtenidos a partir de los datos ambiente simulados muestran que el método propuesto es muy eficiente para identificar los modos oscilación electromecánicas y sus modos *shapes*.

Este artículo está estructurado como sigue. En la sección dos, una breve descripción del enfoque de separación ciega de fuentes, así como la formulación matemática de la metodología propuesta son presentadas, respectivamente. Mientras que en la sección tres, datos ambiente son simulados en un sistema eléctrico de potencia de prueba y son recolectados para evaluar el desarrollo de la metodología propuesta. Finalmente, en la sección cuatro se muestran las conclusiones de este trabajo de investigación.

2. Metodología

En este artículo se propone una metodología estadística para la estimación de modos de oscilación electromecánicos y sus modos *shapes* a partir de mediciones de área amplia. La formulación matemática y un diagrama de flujo de la metodología propuesta se presentan a continuación.

Antecedentes teóricos de separación ciega de fuentes

La separación ciega de fuentes (en inglés *Blind Source Separation - BSS*) se refiere al proceso de extracción de señales (fuente) desconocidas a partir de un conjunto de señales observadas (mediciones) sin información adicional acerca de las fuentes individuales o el proceso de mezclado [16]. Más formalmente, se establece que $s_1(t), s_2(t), \dots, s_n(t)$ son un conjunto de n señales fuente, que se asume son mutuamente independientes y tienen un promedio de cero. Refiriéndose a la ecuación (1), se establece que $x_1(t), x_2(t), \dots, x_m(t)$ son señales medidas (observaciones) por sensores en m ubicaciones del sistema, muestreadas en tiempo t , se asume son representadas como

$$\mathbf{x}(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_m(t) \end{bmatrix} = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} \begin{bmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_n(t) \end{bmatrix} + \begin{bmatrix} n_1(t) \\ n_2(t) \\ \vdots \\ n_m(t) \end{bmatrix} \quad (1)$$

donde $\mathbf{A} = [\mathbf{a}_1 \ \mathbf{a}_2 \ \cdots \ \mathbf{a}_n] \in \mathbb{R}^{m \times n}$ es una matriz de mezclado desconocida que representa la transformación lineal de las señales fuente $\mathbf{s}(t) = [s_1(t) \ s_2(t) \ \cdots \ s_n(t)]^T \in \mathbb{R}^n$ a las observaciones $\mathbf{x}(t) \in \mathbb{R}^m$, y $\mathbf{n}(t) = [n_1(t) \ n_2(t) \ \cdots \ n_m(t)]^T \in \mathbb{R}^m$ es el ruido de medición no deseado.

Evaluando (1) en cada instante de tiempo $t = t_k, k = 1, 2, \dots, N$, el conjunto de observaciones $\mathbf{x}(t) = [x_1(t) \ x_2(t) \ \cdots \ x_m(t)]^T \in \mathbb{R}^m$ puede ser reescrito como

$$\mathbf{X}(t) = [\mathbf{x}_1(t) \ \mathbf{x}_2(t) \ \cdots \ \mathbf{x}_m(t)]^T = \mathbf{Y}(t) + \mathbf{N}(t) = \mathbf{A}\mathbf{S}(t) + \mathbf{N}(t) \quad (2)$$

donde $\mathbf{S}(t) = [\mathbf{s}(t_1) \ \mathbf{s}(t_2) \ \cdots \ \mathbf{s}(t_N)] \in \mathbb{R}^{n \times N}$ es matriz que contiene las señales desconocidas, $\mathbf{N}(t) = [\mathbf{n}(t_1) \ \mathbf{n}(t_2) \ \cdots \ \mathbf{n}(t_N)]^T \in \mathbb{R}^{m \times N}$ es una matriz ruido aditivo $\mathbf{Y}(t) \in \mathbb{R}^{m \times N}$ es una matriz que representa el mezclado de las señales fuente sin ruido.

Finalmente, el objetivo de la separación ciega de fuentes es encontrar una matriz de desmezclado $\mathbf{W} = \mathbf{A}^{-1}$ tal que las salidas $\hat{\mathbf{S}}(t) = \mathbf{W}\mathbf{X}(t)$ son la mejor aproximación a las señales fuente $\mathbf{S}(t)$, en la ecuación (1) [16]. Una vez que las señales fuente y la matriz de mezclado se han estimado, las señales medidas por los sensores pueden ser reconstruidas. El enfoque complejo de separación ciega de fuentes combina la transformada de Hilbert [17] con el algoritmo de identificación ciega de segundo orden [18].

Un enfoque complejo de separación ciega de fuentes

La metodología propuesta involucra dos etapas, las cuales se describen a continuación. Una vez que las observaciones $\mathbf{x}_1(t), \mathbf{x}_2(t), \dots, \mathbf{x}_m(t)$ se registran, la primera etapa consiste en aplicar la transformada de Hilbert a cada señal medida para que el modelo matemático de la ecuación (2) tome la forma siguiente

$$\hat{\mathbf{X}}(t) = \mathbf{X}_R(t) + j\mathbf{X}_I(t) \quad (3)$$

donde $\hat{\mathbf{X}}(t) \in \mathbb{C}^{m \times N}$ es la matriz de observación compleja, $j = \sqrt{-1}$ y los subíndices R y I denotan la parte real e imaginaria de los vectores, respectivamente.

Una vez que la transformada de Hilbert se aplicó a cada señal medida, la segunda etapa consiste en aplicar el algoritmo de identificación ciega de segundo orden (en inglés *Second-Order Blind Identification - SOBI*) a la matriz de observación compleja para estimar las señales fuente complejas a partir de su estructura temporal y posteriormente la matriz de mezclado compleja. Este algoritmo diagonaliza conjuntamente varias matrices de covarianza con diferentes retardos de tiempo, las cuales son básicamente estadísticas de segundo orden.

Para llevar a cabo la implementación del algoritmo SOBI, las señales fuente son asumidas para ser estacionarias y mutuamente no correlacionadas. Además, si las señales fuente se escalan para tener una varianza unitaria, entonces su matriz de covarianza es

$$\mathbf{R}_S(0) = E[\mathbf{S}(t)\mathbf{S}^H(t)] = \mathbf{I} \quad (4)$$

donde el superíndice H denota la transpuesta conjugada compleja de un vector o matriz e \mathbf{I} es la matriz identidad. Basado en la ecuación (4), las matrices de covarianza de retraso cero de las observaciones, tanto para la parte real como la parte imaginaria, son definidas por

$$\mathbf{R}_{\hat{\mathbf{X}}}(0) = E[\hat{\mathbf{X}}(t)\hat{\mathbf{X}}^H(t)] = \mathbf{A}\mathbf{R}_S(0)\mathbf{A}^H + E[\mathbf{N}(t)\mathbf{N}^H(t)] = \mathbf{A}\mathbf{A}^H + \sigma^2\mathbf{I} \quad (5)$$

donde σ^2 corresponde a las varianzas del ruido, el cual es asumido para ser estacionario e independiente de las señales fuente. Además, estos ruidos son espacialmente y temporalmente blancos.

El algoritmo SOBI envuelve dos pasos que a continuación se presentan. El primer paso consiste en el blanqueado de la parte de las observaciones sin ruido, tal que

$$E[\mathbf{Q}\mathbf{Y}(t)\mathbf{Y}^H(t)\mathbf{Q}^H] = \mathbf{Q}\mathbf{A}\mathbf{A}^H\mathbf{Q}^H = \mathbf{I} \quad (6)$$

donde $\mathbf{Q} = \mathbf{\Lambda}^{-1/2}\mathbf{U}^H \in \mathbb{C}^{n \times m}$ es la matriz de blanqueado.

A partir de la ecuación (6), se deduce que cualquier matriz de blanqueado \mathbf{Q} existe una matriz unitaria $\hat{\mathbf{U}}$ tal que $\hat{\mathbf{U}} = \mathbf{Q}\mathbf{A} \in \mathbb{C}^{n \times n}$. Cuando el ruido aditivo está presente en las observaciones, esto es $\mathbf{X}(t) \neq \mathbf{Y}(t)$, el proceso de blanqueado $\mathbf{Z}(t) = \mathbf{Q}\hat{\mathbf{X}}(t) \in \mathbb{C}^{n \times N}$ produce

$$\begin{aligned} E[\mathbf{Z}(t)\mathbf{Z}^H(t)] &= E[\mathbf{Q}\hat{\mathbf{X}}(t)\hat{\mathbf{X}}^H(t)\mathbf{Q}^H] = \mathbf{Q}\mathbf{A}\mathbf{A}^H\mathbf{Q}^H + \mathbf{Q}\sigma^2\mathbf{Q}^H \\ &= \mathbf{Q}(\mathbf{R}_{\hat{\mathbf{X}}}(0) - \sigma^2\mathbf{I})\mathbf{Q}^H + \mathbf{Q}\sigma^2\mathbf{Q}^H \\ &= \mathbf{Q}\mathbf{R}_{\hat{\mathbf{X}}}(0)\mathbf{Q}^H \end{aligned} \quad (7)$$

donde la matriz \mathbf{Q} se puede obtener a partir de la descomposición de valores propios de la matriz de correlación de las observaciones. Más formalmente, esto se puede definir como: $\mathbf{R}_{\hat{\mathbf{X}}}(0) = E[\hat{\mathbf{X}}(t)\hat{\mathbf{X}}^H(t)] = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^H$, donde $\mathbf{U} \in \mathbb{C}^{m \times m}$ es una matriz unitaria que contiene los vectores propios que están relacionados con la matriz diagonal de valores propios $\mathbf{\Lambda} \in \mathbb{C}^{m \times m}$.

El segundo paso tiene como propósito determinar una matriz unitaria $\hat{\mathbf{U}}$. Para este fin, un conjunto de matrices de covarianza retrasadas de las observaciones blanqueadas $\mathbf{Z}(t)$ son consideradas como

$$\begin{aligned}
\mathbf{R}_Z(\tau) &= E[\mathbf{Z}(t)\mathbf{Z}^H(t+\tau)] = \mathbf{Q}E[\hat{\mathbf{X}}(t)\hat{\mathbf{X}}^H(t+\tau)]\mathbf{Q}^H \\
&= \mathbf{Q}AE[\mathbf{S}(t)\mathbf{S}^H(t+\tau)]\mathbf{A}^H\mathbf{Q}^H \\
&= \hat{\mathbf{U}}\mathbf{R}_S(\tau)\hat{\mathbf{U}}^H \quad \forall \tau \neq 0
\end{aligned} \tag{8}$$

donde $\mathbf{R}_S(\tau)$ es una matriz diagonal que contienen la autocovarianza y covarianza cruzada de las señales fuente. La ecuación anterior es un resultado clave que establece que una matriz de covarianza retrasada $\mathbf{R}_Z(\tau) \in \mathbb{C}^{n \times n}$ para cualquier retardo de tiempo diferente de cero τ puede ser diagonalizada por una matriz unitaria $\hat{\mathbf{U}}$.

A partir de la ecuación (8), el algoritmo de SOBI aprovecha la eigenestructura de la matriz de observación blanqueada $\mathbf{Z}(t)$ mediante un conjunto de matrices de covarianza retrasadas $\mathbf{R}_Z(\tau)$, $\tau = 1, 2, \dots, K$ para mejorar la robustez al ruido. Estas matrices son aproximadamente diagonalizadas usando un procedimiento llamado como: diagonalización aproximada conjunta (en inglés *Joint Approximate Diagonalization - JAD*) [19]. Este procedimiento tiene por objetivo encontrar la matriz unitaria $\hat{\mathbf{U}}$ que satisface lo siguiente

$$\mathbf{R}_Z(\tau) = \hat{\mathbf{U}}\mathbf{B}(\tau)\hat{\mathbf{U}}^H \tag{9}$$

donde las matrices $\mathbf{B}(\tau) \in \mathbb{C}^{n \times n}$, $\tau = 1, 2, \dots, K$ son lo más diagonales posible porque una diagonalización exacta no puede ser posible. De acuerdo a este procedimiento, un problema de optimización se lleva a cabo con respecto a una matriz $\hat{\mathbf{U}}$ que minimiza la suma de los cuadrados de los términos fuera de la diagonal de $\hat{\mathbf{U}}^H\mathbf{R}_Z(\tau)\hat{\mathbf{U}}$ para K matrices de covarianza retrasadas, i.e., $\min_{\hat{\mathbf{U}}} \sum_{\tau=1}^K \text{off}(\hat{\mathbf{U}}^H\mathbf{R}_Z(\tau)\hat{\mathbf{U}})$. El problema de optimización se resuelve usando la técnica de rotación de Jacobi, el cual busca una rotación $\hat{\mathbf{U}}$ que diagonaliza múltiples matrices mediante un proceso iterativo [19].

Una vez que la matriz unitaria $\hat{\mathbf{U}}$ se obtiene, las señales fuente $\hat{\mathbf{S}}(t) \in \mathbb{C}^{n \times N}$ se pueden extraer como

$$\hat{\mathbf{S}}(t) = \hat{\mathbf{U}}^H\mathbf{Z}(t) = \hat{\mathbf{U}}^H\mathbf{Q}\hat{\mathbf{X}}(t) = \hat{\mathbf{W}}\hat{\mathbf{X}}(t) \tag{10}$$

y la matriz de mezclado $\hat{\mathbf{A}} \in \mathbb{C}^{m \times n}$ se calcula como

$$\hat{\mathbf{A}} = \mathbf{Q}^{-1}\hat{\mathbf{U}} \tag{11}$$

donde el superíndice -1 denota la inversa y $\hat{\mathbf{W}} \in \mathbb{C}^{n \times n}$ se define como la matriz de desmezclado. Es importante mencionar que la i -ésima señal fuente puede ser asociada con la evolución temporal del i -ésimo modo oscilatorio y el i -ésimo vector columna de la matriz de mezclado puede ser interpretado como el i -ésimo vector modal o modo *shape*. Enseguida, un conjunto de características dinámicas espacio-temporales son definidas.

Características dinámicas espacio-temporales

De acuerdo a la teoría de Hilbert [17], la aplicación de la transformada de Hilbert a las señales reales permite generar una señal analítica e identificar características temporales, tales como: amplitud temporal y velocidad angular. A partir de esto, las señales fuente obtenidas por la ecuación (10) pueden ser definidas como sigue

$$\hat{\mathbf{S}}(t) = \begin{bmatrix} \hat{\mathbf{S}}_1(t) \\ \hat{\mathbf{S}}_2(t) \\ \vdots \\ \hat{\mathbf{S}}_n(t) \end{bmatrix} = \begin{bmatrix} \mathbf{C}_1(t)e^{j\varphi_1(t)} \\ \mathbf{C}_2(t)e^{j\varphi_2(t)} \\ \vdots \\ \mathbf{C}_n(t)e^{j\varphi_n(t)} \end{bmatrix} = \begin{bmatrix} C_1(t_1)e^{j\varphi_1(t_1)} & c_1(t_2)e^{j\varphi_1(t_2)} & \cdots & c_1(t_N)e^{j\varphi_1(t_N)} \\ C_2(t_1)e^{j\varphi_2(t_1)} & c_2(t_2)e^{j\varphi_2(t_2)} & \cdots & c_2(t_N)e^{j\varphi_2(t_N)} \\ \vdots & \vdots & \ddots & \vdots \\ C_n(t_1)e^{j\varphi_n(t_1)} & c_n(t_2)e^{j\varphi_n(t_2)} & \cdots & c_n(t_N)e^{j\varphi_n(t_N)} \end{bmatrix} \quad (12)$$

donde $\mathbf{C}_n(t) = \left(\text{Re}(\hat{\mathbf{S}}_n(t))^2 + \text{Im}(\hat{\mathbf{S}}_n(t))^2 \right)^{1/2}$ es una n -ésima función de amplitud temporal y $\varphi_n(t) = \arctan\left(\frac{\text{Im}(\hat{\mathbf{S}}_n(t))}{\text{Re}(\hat{\mathbf{S}}_n(t))}\right)$ denota una n -ésima función de fase temporal. A partir de $\varphi_n(t)$, la n -ésima velocidad (frecuencia) angular puede ser calculada como sigue

$$\omega_n(t) = \frac{d\varphi_n(t)}{dt} \quad (13)$$

donde $\omega_n(t) \in \mathbb{R}^N$ está dado en radianes por segundo o $f_n(t) \in \mathbb{R}^N$ en Hertz. Así también, las señales fuente originales pueden ser expresadas como sigue: $\text{Re}[\hat{\mathbf{S}}_1(t)], \text{Re}[\hat{\mathbf{S}}_2(t)], \dots, \text{Re}[\hat{\mathbf{S}}_n(t)]$.

Por otro lado, las características espaciales son obtenidas mediante la ecuación (11), la cuales se describen enseguida

$$\hat{\mathbf{A}} = [\hat{\mathbf{a}}_1 \quad \hat{\mathbf{a}}_2 \quad \cdots \quad \hat{\mathbf{a}}_n] = \begin{bmatrix} \hat{a}_{11} & \hat{a}_{12} & \cdots & \hat{a}_{1n} \\ \hat{a}_{21} & \hat{a}_{22} & \cdots & \hat{a}_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{a}_{m1} & \hat{a}_{m1} & \cdots & \hat{a}_{mn} \end{bmatrix} = \begin{bmatrix} A_{11}e^{j\theta_{11}} & A_{12}e^{j\theta_{12}} & \cdots & A_{1n}e^{j\theta_{1n}} \\ A_{21}e^{j\theta_{21}} & A_{22}e^{j\theta_{22}} & \cdots & A_{2n}e^{j\theta_{2n}} \\ \vdots & \vdots & \ddots & \vdots \\ A_{m1}e^{j\theta_{m1}} & A_{m2}e^{j\theta_{m2}} & \cdots & A_{mn}e^{j\theta_{mn}} \end{bmatrix} \quad (14)$$

donde $|a_{nm}| = \left(\text{Re}(\hat{a}_{mn})^2 + \text{Im}(\hat{a}_{mn})^2 \right)^{1/2}$ y $\theta_{mn} = \tan^{-1}\left(\frac{\text{Im}(\hat{a}_{mn})}{\text{Re}(\hat{a}_{mn})}\right)$ son la magnitud espacial y la fase espacial.

Después de que el BSS complejo se ha implementado, el orden de las señales fuente es un paso muy importante en técnicas BSS. En este artículo se propone aplicar la norma Euclidiana a los vectores columna de la matriz de mezclado $\hat{\mathbf{A}} = [\hat{\mathbf{a}}_1 \quad \cdots \quad \hat{\mathbf{a}}_i \quad \cdots \quad \hat{\mathbf{a}}_n]$, para ordenar la matriz de mezclado $\hat{\mathbf{A}}$, así como las señales fuente $\hat{\mathbf{S}}(t)$. Más formalmente, lo anterior se define como sigue

$$L_2(\hat{\mathbf{a}}_i) = \|\hat{\mathbf{a}}_i\|_2 = \sum_{j=1}^m [\hat{a}_{ij}^2]^{1/2} = \sum_{j=1}^m [\text{Re}(\hat{a}_{ij})^2 + \text{Im}(\hat{a}_{ij})^2]^{1/2} \quad (15)$$

donde $i = 1, 2, \dots, n$.

Por consiguiente, la longitud total de los vectores columna de la matriz de mezclado puede ser dada como $\sum_{i=1}^n L_2(\hat{\mathbf{a}}_i)$ y la longitud normalizada de un vector columna, $L_2(\hat{\mathbf{a}}_i)$, puede ser definida como $E_i = L_2(\hat{\mathbf{a}}_i) / \sum_{i=1}^n L_2(\hat{\mathbf{a}}_i) \times 100$.

Un criterio práctico para elegir el número de longitudes relevantes es entonces dado por

$$\frac{\sum_{i=1}^d L_2(\hat{\mathbf{a}}_i)}{\sum_{j=1}^n L_2(\hat{\mathbf{a}}_j)} \times 100 \quad (16)$$

donde d es un número de longitudes relevantes. A continuación, en la Figura 1 se presenta un diagrama de

flujo de la metodología propuesta.

Diagrama de flujo del enfoque propuesto

El enfoque propuesto consiste principalmente de cuatro procesos. En el proceso uno es cuando las señales medidas son enviadas y almacenadas en un concentrador de datos. Una vez que los datos son obtenidos, a cada señal medida se le aplica la transformada de Hilbert para generar datos complejos; esto es en el proceso dos. En el proceso tres, la idea es recuperar las señales fuente y la matriz de mezclado, ambas de naturaleza compleja. Finalmente, en el proceso cuatro los parámetros modales (amplitud, frecuencia natural y relación de amortiguamiento) pueden ser estimados de la parte real de las señales fuente o modos oscilatorios y sus modos *shapes* pueden ser estimados de la matriz de mezclado compleja.

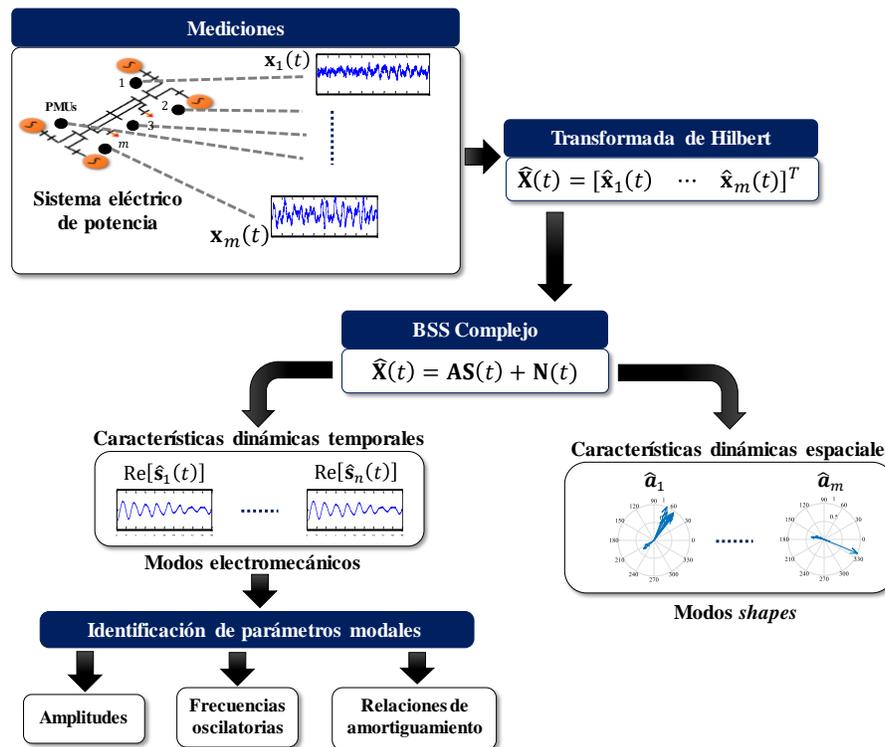


Figura 1. Diagrama de flujo de la metodología propuesta.

3. Aplicación a datos ambiente de área amplia

En esta sección, se investiga la aplicación de la metodología propuesta a datos ambiente simulados de un sistema eléctrico de prueba para extraer y caracterizar modos de oscilación electromecánicos y sus modos *shapes*. Para llevar a cabo esto, un programa de simulación de sistemas de potencia (en inglés *Power System Toolbox - PST*) es usado para generar los datos ambiente del sistema eléctrico interconectado de Nueva York y Nueva Inglaterra [1].

Sistema eléctrico de potencia de 16 generadores

El sistema eléctrico interconectado de Nueva York y Nueva Inglaterra se ha seleccionado para probar la habilidad del método propuesto para extraer modos oscilatorios y sus modos *shapes* a partir de un

conjunto de datos medidos. La Figura 2 proporciona un diagrama unifilar del sistema mencionado, en el cual se muestra que está compuesto de 16 generadores, 68 nodos o buses y 5 áreas o zonas eléctricas. Una simulación numérica del sistema se lleva a cabo durante 300 segundos, y con una frecuencia de muestreo de 20 Hz.

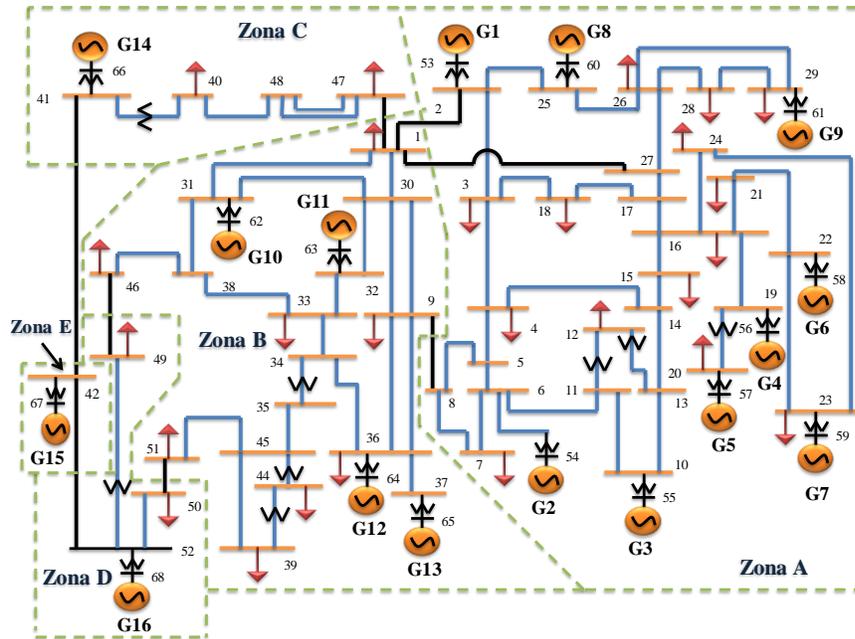


Figura 2. Diagrama unifilar del sistema eléctrico de potencia de prueba.

Operación ambiente del sistema prueba

Una respuesta ambiente describe mediciones del sistema durante operación ambiente cuando el sistema puede ser asumido para ser razonablemente lineal (alrededor del punto operativo) y la excitación (variación de carga) puede ser aproximada como aleatoria y Gaussiana.

Para excitar oscilaciones electromecánicas en condición ambiente, todas las cargas eléctricas del sistema se perturban por variaciones aleatorias. Estas variaciones en las cargas son consideradas como una distribución normal o Gaussiana con promedio de 0 y varianza igual a 1. En la Figura 3 se muestran las series de tiempo de desviación de velocidad angular, las cuales fueron seleccionadas para llevar a cabo el análisis. Estas señales simuladas muestran fenómenos oscilatorios, ruido y comportamiento no estacionario.

Extracción e identificación de las características dinámicas espacio-temporales

Usando los procedimientos descritos en las secciones previas, la matriz de observación compleja se define como $\hat{\mathbf{X}}(t) = [\hat{\omega}_1(t) \ \hat{\omega}_2(t) \ \dots \ \hat{\omega}_{16}(t)]^T$ donde $\hat{\omega}_i(t) = [\hat{\omega}_i(t_1) \ \hat{\omega}_i(t_2) \ \dots \ \hat{\omega}_i(t_{6000})]^T$, $i = 1, 2, \dots, 16$ son las desviaciones de velocidad angular de los generadores. De acuerdo al criterio práctico de longitud de la Sección 2 (ver Figura 4), tres señales fuente de las dieciséis señales fuente extraídas tienen mayor porcentaje, las cuales son usadas para analizar su información tanto espacial como temporal.

En la Figura 5a) se muestra la evolución temporal de las tres señales fuente dominantes, mientras que en la Figuras 5b) y 5c) se presentan sus espectros mediante el método propuesto (frecuencia

instantánea) y Fourier, respectivamente. Una inspección cercana de las formas de onda en la Figura 5a) muestra que las señales fuente dominantes $[\hat{s}_1(t)]$, $\text{Re}[\hat{s}_2(t)]$ y $\text{Re}[\hat{s}_3(t)]$ exhiben un comportamiento oscilatorio dominante. Estos comportamientos pueden asociarse con los principales modos de oscilación electromecánicos en el sistema eléctrico. Los resultados espectrales, tanto del método propuesto como del espectro de Fourier, en las Figuras 5b) y 5c) muestran que los movimientos del sistema pueden ser caracterizados por tres modos de oscilación (interárea) lentos con valores aproximados a 0.40 Hz, 0.65 Hz y 0.1 Hz.

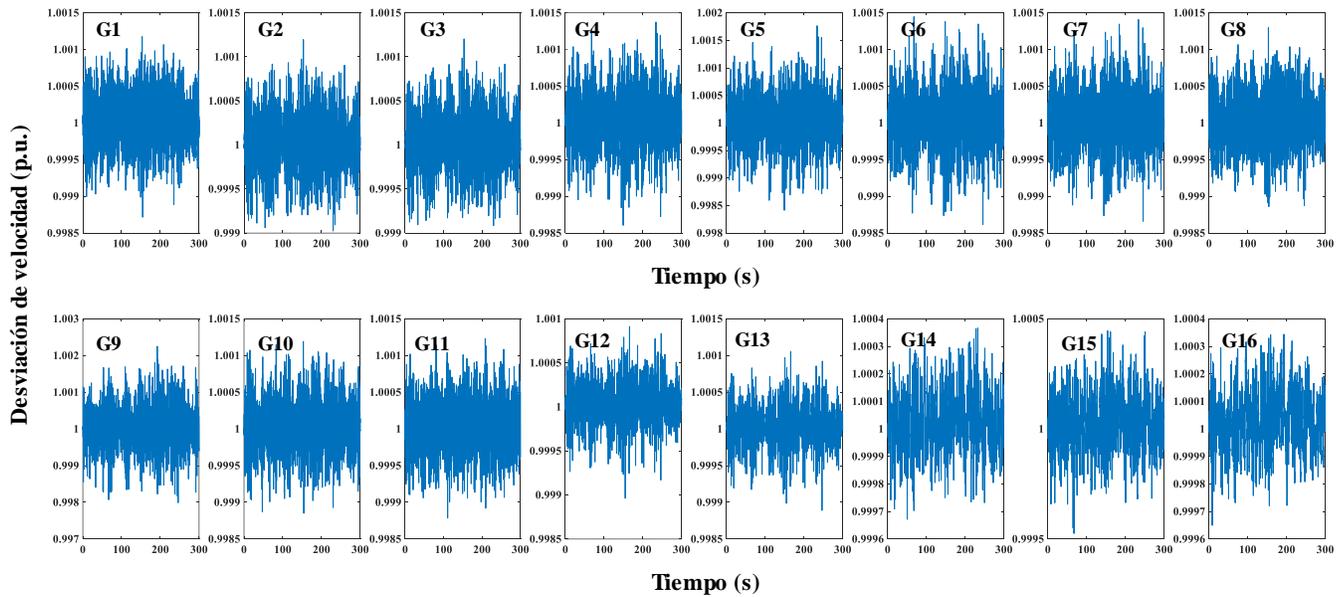


Figura 3. Medición ambiente de la desviación de velocidad angular.

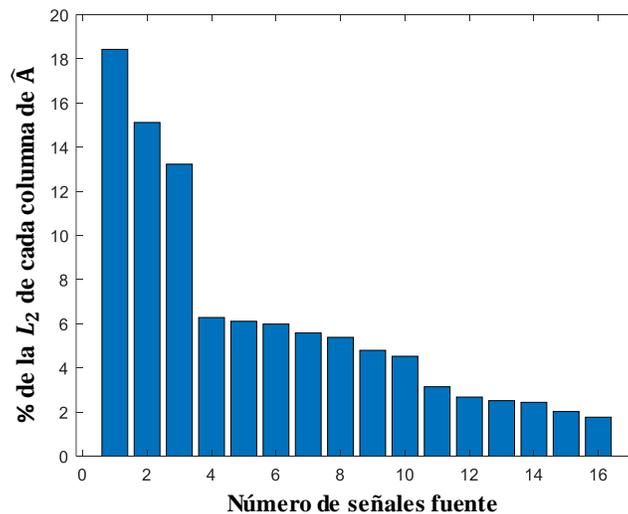


Figura 4. Porcentaje de cada vector columna de la matriz de mezclado.

Por referencia y comparación, en la Tabla 1 se presentan las principales características de los modos más lentos del sistema eléctrico de potencia, los cuales son obtenidos mediante el análisis de pequeña señal

[1]. Como puede ser visto, los modos de oscilación # 1, # 2 y # 3 están asociados a las señales fuente dominantes $\text{Re}[\hat{s}_1(t)]$, $\text{Re}[\hat{s}_2(t)]$ y $\text{Re}[\hat{s}_3(t)]$.

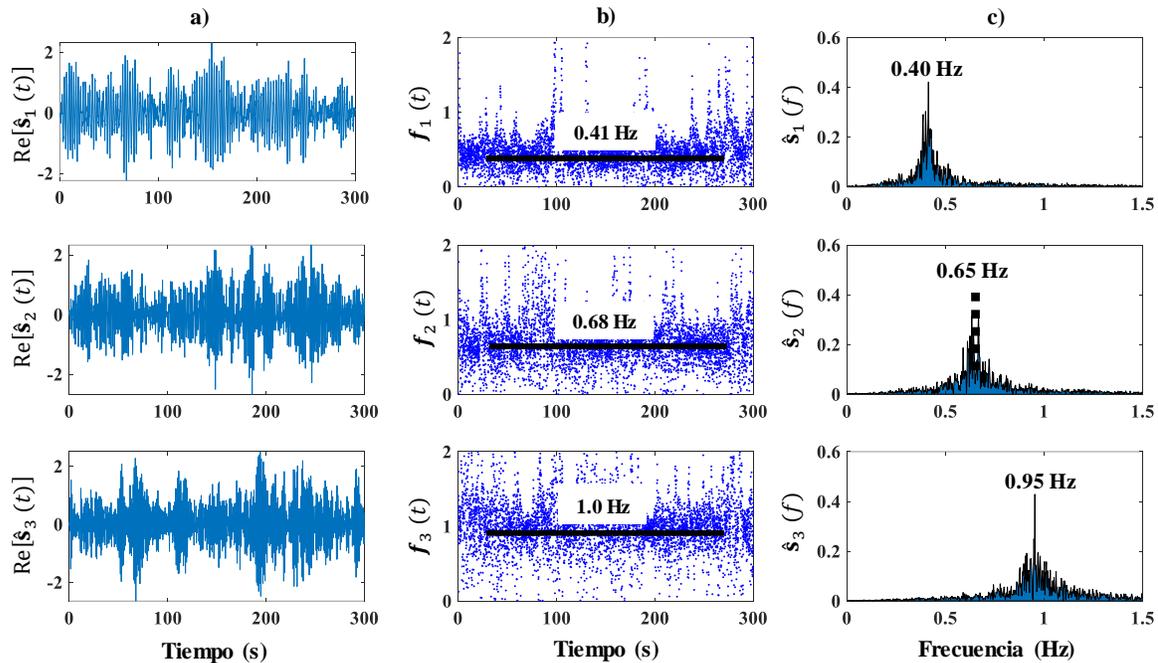


Figura 5. Señales fuente dominantes: a) Evolución temporal, b) Frecuencia instantánea y c) Espectro de Fourier.

Tabla 1. Modos electromecánicos más lentos en el sistema de prueba.

Modo	Eigenvalor	Relación de amortiguamiento (%)	Frecuencia (Hz)	Tipo
1	$-0.0817 \pm j2.6410$	3.0920	0.4203	Interárea
2	$-0.1905 \pm j4.0621$	4.6860	0.6465	Interárea
3	$-0.2364 \pm j6.0513$	3.9040	0.9631	Interárea

En la Figura 6 se muestran los modos *shapes* estimados mediante la metodología propuesta y análisis de pequeña señal. El análisis del modo *shape* extraído a partir del método propuesto para el modo de 0.41 Hz en la Figura 6a) muestra una oscilación en el que los generadores # 1 a # 13 oscilan en contra de los generadores # 14 a # 16. Este patrón oscilatorio es consistente con el obtenido por el análisis de pequeña señal, el cual es presentado en la Figura 6b). En la Figura 6a) se presenta también el modo oscilatorio de 0.64 Hz, el cual es también consistente con el modo *shape* de análisis modal mostrado en la Figura 6b). Como se puede observar, los generadores # 1 a # 9 se encuentran oscilando en contra de los generadores # 10 a # 14. Por último, el modo *shape* del modo oscilatorio de 0.95 Hz dado en las Figuras 6a) y 6b) muestra que el generador # 9 tiene una mayor participación en dicho modo que el resto de los generadores. Este patrón es consistente en ambas metodologías.

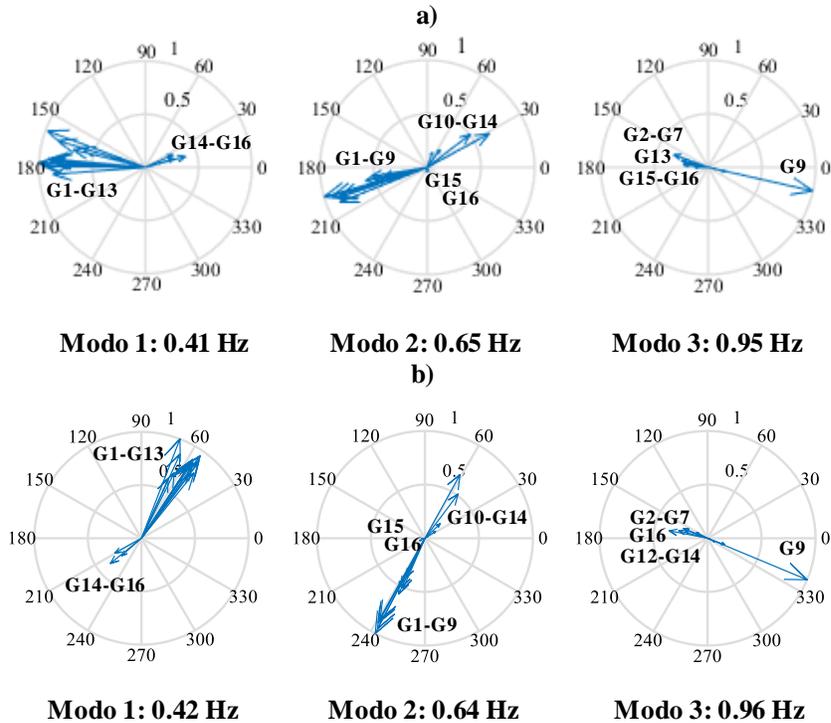


Figura 6. Modos *shapes* estimados: a) Metodología propuesta y b) Análisis de pequeña señal.

4. Conclusiones

El uso de métodos estadísticos espacio-temporales sobre datos del sistema eléctrico de potencia es un área de investigación que ha visto un interés creciente. En este artículo se implementó un enfoque complejo de separación ciega de fuente para la identificación de modos de oscilaciones electromecánicas y modos *shapes* a partir de datos simulados. Ejemplos con datos simulados indican que la metodología propuesta puede extraer modos oscilatorios del sistema eléctrico de potencia a partir de múltiples mediciones.

Los resultados obtenidos a partir de múltiples datos simulados muestran que las señales fuente contienen la evolución temporal de los modos de oscilación electromecánicas de baja frecuencia, en las cuales la transformada de Hilbert permite identificar frecuencia oscilatoria. Por otro lado, los vectores de mezclado complejos proporcionan la distribución y participación espacial de los modos oscilatorios. La mejora de la metodología propuesta consiste en incorporar el ángulo de fase en cada elemento del vector de mezclado con el fin de proporcionar información sobre la actividad modal y las fases relativas de las oscilaciones, las cuales pueden ser usadas para grupos de oscilación.

Finalmente, la metodología propuesta combinada con una ventana deslizante podría ser utilizada para llevar a cabo la estimación o el regimiento en línea de los modos de oscilación electromecánicas.

5. Referencias

1. G. Rogers (2000) Power System Oscillations, Kluwer Academic Publishers.

2. J. F. Hauer, D. J. Trudnowski, and J. G. DeSteele (2007) A perspective on WAMS analysis tools for tracking of oscillatory dynamics, *Proc. 2007 IEEE Power Eng. Soc. General Meeting*, pp. 1–10, Tampa, USA.
3. M. Larsson and D. S. Laila (2009) Monitoring of inter-area oscillations under ambient conditions using subspace identification, *Proc. IEEE Power Energy Soc. General Meeting*, pp. 1–6, Calgary, Canada.
4. J. J. Thambirajah, N. F. Thornhill, and B. C. Pal (2011) A multivariate approach towards inter-area oscillation damping estimation under ambient conditions via independent component analysis and random decrement, *IEEE Trans. Power Syst.*, vol. 26, no. 1, pp. 315–322.
5. M. Seppanen, L. C. Haarla, and J. Turunen (2013) Modal analysis of power systems with eigendecomposition of multivariate autoregressive models, *IEEE Power Tech.*, Grenoble, France, pp. 1–6.
6. J. M. Seppanen, J. Turunen, M. Koivisto, N. Kishor, and L. C. Haarla (2014) Modal analysis of power systems through natural excitation technique, *IEEE Trans. Power Syst.*, vol. 29, no. 4, pp. 1642–1652.
7. J. Seppanen, J. Turunen, M. Koivisto, and L. C. Haarla (2015) Measurement based analysis of electromechanical modes with second order blind identification, *Electric Power Syst. Res.*, vol. 121, pp. 67–76.
8. P. Zhang, X. Wang, X. Wang, and J. S. Thorp (2014) Synchronized measurement based estimation of inter-area electromechanical modes using the Ibrahim time domain method, *Electric Power Syst. Res.*, vol. 111, pp. 85–95.
9. Y. Susuki and I. Mezic (2014) Nonlinear koopman modes and power system stability assessment without models, *IEEE Trans. Power Syst.*, vol. 29, no. 2, pp. 899–907.
10. Barocio, B. C. Pal, N. F. Thornhill, and A. R. Messina (2015) A dynamic mode decomposition framework for global power system oscillation analysis, *IEEE Trans. Power Syst.*, vol. 30, no. 6, pp. 2902–2912.
11. You, J. Guo, G. Kou, Y. Liu, and Y. Liu (2016) Oscillation mode identification based on wide-area ambient measurements using multivariate empirical mode decomposition, *Electric Power Syst. Res.*, vol. 134, pp. 158–166.
12. K. K. Anaparthi, B. Chaudhuri, and N. F. Thornhill (2005) Coherency identification in power system through principal component analysis, *IEEE Trans. Power Syst.*, vol. 20, no. 3, pp. 1658–1660.
13. Y. Susuki and I. Mezic (2011) Nonlinear koopman modes and coherency identification of coupled swing dynamics, *IEEE Trans. Power Syst.*, vol. 26, no. 4, pp. 1894–1904.
14. M. A. M. Ariff and B. C. Pal (2013) Coherency identification in interconnected power systems- an independent component analysis approach, *IEEE Trans. Power Syst.*, vol. 28, no. 2, pp. 1747–1755.
15. A. R. Messina and V. Vittal (2007) Extraction of dynamic patterns from wide-area measurements using empirical orthogonal functions, *IEEE Trans. Power Syst.*, vol. 22, no. 2, pp. 682–692.
16. J. J. Ayon, E. Barocio, and A. R. Messina (2015) Blind extraction and characterization of power system oscillatory modes *Electric Power Syst. Res.*, vol. 119, pp. 54–65.
17. Mathias Johansson, The Hilbert transform, Master Thesis
18. A. Belouchrani, K. Abed-Meraim, J.-F. Cardoso and E. Moulines (1997) A blind source separation technique using second order statistics, *IEEE Trans. Signal Proc.*, vol. 45, no. 2, pp. 434–444.
19. J. F. Cardoso and A. Souloumiac (1996) Jacobi angles for simultaneous diagonalization, *SIAM J. Matrix Anal. Appl.*, vol. 17, no. 1, pp. 161–164.