

Un nuevo algoritmo de estimación de estado dinámico para redes de distribución utilizando diferentes métodos de pronóstico

A novel dynamic state estimation algorithm for distribution networks using different forecasting methods

Lautaro E. Valenzuela^{1,2*}  <https://orcid.org/0000-0002-3430-4999>

Matias Antunez¹  <https://orcid.org/0009-0007-6979-2498>

Mariano A. Risso^{1,3}  <https://orcid.org/0009-0000-0562-737X>

Pablo A. Lotito^{1,2}  <https://orcid.org/0000-0002-7579-6942>

Aldo Rubiales^{1,3}  <https://orcid.org/0009-0006-0981-2912>

Recibido 08 de noviembre de 2022, aceptado 17 de marzo de 2023

Received: November 08, 2022 Accepted: March 17, 2023

RESUMEN

Este artículo presenta un algoritmo de estimación de estado para redes de distribución basado en el filtro de Kalman Unscented (UKF). En lugar de voltajes nodales, este método utiliza potencia activa y reactiva nodal como variables de estado en el modelo dinámico. Se probaron y compararon diferentes algoritmos de previsión de la demanda para ayudar en el paso de la predicción. Además, el algoritmo incluye el paquete de software OpenDSS como motor de cálculo.

Se utilizó la red de distribución IEEE de 13 nodos para probar la metodología mediante la simulación de varios escenarios de generación de medidas. Para realizar estas simulaciones, se tuvieron en cuenta los valores de medición de una distribuidora de energía local. Los resultados expusieron diferentes niveles de desempeño, dependiendo de la naturaleza del escenario y el método de pronóstico seleccionado.

Palabras clave: Estimación de estados, redes de distribución, pronóstico.

ABSTRACT

This paper presents a State Estimation Algorithm for Distribution Networks based on the Unscented Kalman Filter (UKF). Instead of nodal voltages, this method uses nodal active and reactive power as state variables in the dynamic model. Different demand forecast algorithms to assist the prediction step were tested and compared. In addition, the algorithm includes the software package OpenDSS as a calculation engine.

We used the 13-node IEEE distribution network to test the methodology by simulating several scenarios of measurement generation. These simulations were based on the measured values of a local energy distribution company. The results exposed different performance levels depending on the nature of the scenario and the selected forecast method.

Keywords: State estimation, distribution networks, forecasting.

¹ Instituto PLADEMA, UNICEN, Campus Universitario. Tandil, Argentina.

E-mail: lautaroemanuelvalenzuela@gmail.com; mantunez@exa.unicen.edu.ar; mrisso@exa.unicen.edu.ar; plotito@exa.unicen.edu.ar; arubiale@exa.unicen.edu.ar

² Consejo Nacional de investigaciones Científicas y Técnicas, CONICET. Tandil, Argentina.

³ Consejo de Investigaciones Científicas de la Provincia de Buenos Aires, CICPBA. Tandil, Argentina.

* Autor de correspondencia: lautaroemanuelvalenzuela@gmail.com

INTRODUCCIÓN

El estado de un sistema está definido por variables que proporcionan una representación completa de su condición interna en un momento dado [1].

La estimación del estado (SE) es una herramienta crucial en los sistemas de administración de energía. Su objetivo es buscar el estado más probable de la red a través de la adquisición de datos de medición para garantizar un funcionamiento seguro, confiable y óptimo. Además, otros algoritmos utilizan la estimación establecida como entrada para cálculos posteriores.

Las medidas incluyen voltajes, tensión y datos de inyección de potencia o corriente [2].

La estimación del estado es un área importante de investigación, principalmente en el área de sistemas de transmisión de potencia. Las técnicas más frecuentes consideran mínimos cuadrados ponderados (WLS) [3] y obtienen las soluciones aprovechando la alta redundancia de las medidas disponibles.

Los sistemas de distribución de energía presentan características que los diferencian de los sistemas de transmisión. Entre ellos se encuentran los siguientes:

- Topología radial con escasa presencia de mallas.
- Sistema de carga trifásico y desequilibrado.
- Cargas distribuidas separadas por distancias cortas.
- Alta relación resistencia-reactancia en los conductores.
- Presencia de generación distribuida.
- Falta de unidad de medida.

Estas características conducen a un escenario que proporciona muy poca información sobre las mediciones.

Las medidas de tensión y de potencia en el alimentador son las únicas disponibles, y una operación adecuada requerirá una supervisión y un conocimiento del estado de la red. Sin embargo, la instalación de equipos de medición en diferentes puntos de la red es bastante costosa. En consecuencia, la metodología para los sistemas de transmisión no puede aplicarse directamente, lo que lleva a considerar otras alternativas [4, 5].

En la literatura existen varias técnicas para este tipo de problema. Todos ellos parten de la definición del vector de medida z dado en la ecuación (1).

$$z = h(x) + e \quad (1)$$

$$e \sim N(0, \sigma^2) \quad (2)$$

El vector z se calcula con la función no lineal h , la cual se aplica al vector de estado x . Este último contiene el conjunto mínimo de variables a partir de las cuales se puede calcular el estado completo de la red. Además, se agrega un vector de error e . Este mismo representa el ruido introducido en las medidas y está compuesto por una variable gaussiana independiente de media cero y varianza σ^2 (definida en la ecuación (2)).

Los diferentes métodos de SE buscarán el valor del vector de estado x que proporcione un error mínimo en función de las medidas disponibles en un momento dado.

Existen diferentes alternativas para el problema de estimación del estado del sistema de distribución (DSSE) [6]. Aquí, se consideran dos factores al implementar un algoritmo SE sobre estas redes: selección de método y selección de variable de estado. Se propone una clasificación de los métodos encontrados en la bibliografía.

Métodos estáticos basados en WLS

El objetivo de los métodos estáticos, llamados así porque sólo utilizan la información actual, es minimizar la función objetivo $J(x)$ teniendo en cuenta el error cuadrático de las medidas obtenidas en cada momento. El problema de minimización está definido por la ecuación (3),

$$\min_x J(x) = [z - h(x)]^T R_z^{-1} [z - h(x)] \quad (3)$$

$$R_z = \text{diag}(\sigma_{z1}^2, \sigma_{z2}^2, \dots, \sigma_{zm}^2) \quad (4)$$

Donde en la ecuación (4) se denota la matriz de covarianza de error [7], que se calcula en base a la desviación del error en cada medición, asumidas éstas independientes.

Algunas técnicas de minimización son: descenso de gradiente [8], Newton-Raphson [9], quasi-Newton [10]. Además, se han propuesto diferentes alternativas en cuanto a la selección de variables de estado [6].

Métodos DSSE de ajuste de carga

En este tipo de técnicas, los valores de carga se ajustan en función de las curvas de perfil de carga del cliente. Los datos de medición se especifican como restricciones en el algoritmo. Los valores de inyección de corriente y potencia varían para aproximar los resultados del flujo de carga a los valores medidos. La función objetivo es idéntica a las técnicas WLS. Varios trabajos han presentado esta estrategia utilizando flujos de carga [11, 12], técnicas basadas en diferentes heurísticas como la optimización de enjambres de partículas [13], entre otras.

Métodos SE dinámicos

El objetivo de los métodos dinámicos es buscar el estado más probable del sistema utilizando también la información proporcionada por la trayectoria temporal del estado [14]. Se basan en la premisa de que los sistemas eléctricos tienen un estado casi estacionario y un comportamiento predecible, con pequeños cambios en los valores de carga a lo largo del tiempo. Así, las medidas recibidas se procesan con la estimación a priori disponible y se predice la variación de estado. Matemáticamente, un modelo de la dinámica viene dado por una función de transición que obtiene el estado en $t+1$ en base a datos históricos hasta t [15]. Este paso está representado en la ecuación (5),

$$x_{t+1} = F_t x_t + g_t + q_t \quad (5)$$

Donde x_t denota el vector de estado en t tiempo, la matriz F_t y el vector g_t describen el proceso de transición y q_t representa el ruido introducido en el proceso de predicción. Así, el sistema de ecuaciones no lineales de los métodos anteriores dado por la ecuación (6) debe resolverse junto con la ecuación (5) mejorando la eficiencia en comparación con los métodos estáticos.

$$z_t = h(x_t) + e_t \quad (6)$$

Un algoritmo WLS debe reinicializarse y repetirse cada vez con un nuevo conjunto de medidas [14]. Por otro lado, los métodos SE dinámicos utilizan información de estados pasados y modelos dinámicos para predecir el siguiente estado, que se filtra con el conjunto de medidas adquiridas. Además, una ventaja de este tipo de método es la detección de anomalías, que pueden deberse a la presencia de una dinámica no esperada en los componentes del

estado del sistema, datos incorrectos o errores de configuración de la red.

Cabe mencionar que esta técnica falla en presencia de cambios repentinos en los valores de carga causados por una variación de estado significativa en un tiempo corto sin respetar el modelo dinámico. Sin embargo, estos eventos son poco comunes y están causados por fenómenos predecibles (desconexión de consumidores, programas de televisión de gran interés, interrupciones programadas) [16].

Para modelos de evolución como los que se ven en la ecuación (5) y ecuación (6), el algoritmo estándar de Kalman [33] no se puede aplicar debido a las no linealidades en (6), por lo que se han propuesto diferentes extensiones. Ejemplo de ellos son los algoritmos del filtro de Kalman extendido (EKF) y del filtro de Kalman unscented (UKF) [17, 18]. Cabe señalar que en [15] se demuestra que el algoritmo UKF mejora el algoritmo EKF, pero siempre realizándose sobre sistemas de transmisión en lugar de sistemas de distribución.

Métodos SE distribuidos

A diferencia de los sistemas de transmisión, los sistemas de distribución tienen varias subestaciones. Los métodos SE distribuidos dividen la red en subáreas de acuerdo con los puntos de medición geográficos y topológicos y, por lo tanto, resuelven el problema como estimadores locales. Esto permite que el cálculo se realice de forma distribuida y en paralelo. Se han presentado algunos trabajos sobre el criterio de división en subáreas y procesamiento paralelo [19, 20].

Además, la selección de variables de estado también es importante en el diseño de algoritmos. En la literatura se han analizado diferentes alternativas, y varios trabajos han propuesto dos tipos de variables de estado: voltajes nodales [21, 22] y corrientes de línea. En [4] se expone una comparación de resultados entre ambas alternativas.

Además, los métodos DSSE de ajuste de carga promueven el uso de inyección de potencia en cada nodo como variables de estado [23, 24]. Diversos trabajos de investigación sustentan que estas variables son más adecuadas con algoritmos de pronóstico de demanda para determinar el comportamiento de modelado dinámico y generación de pseudo-medidas

[17]. Sin embargo, no existe ningún trabajo publicado que presente implementaciones con este tipo de variables.

La mayoría de los métodos de estimación utilizados para las redes de distribución son métodos SE dinámicos. Basado en la premisa de que las variables de estado de potencia nodal son mejores para predecir el comportamiento de su dinámica, este trabajo presenta un algoritmo basado en UKF que utiliza la inyección nodal de potencia activa y reactiva como variables de estado.

Este artículo está organizado de la siguiente manera: la sección *ALGORITMO* presenta los pasos de los algoritmos y el modelo matemático para la selección de variables de estado. La metodología para el paso de predicción se analiza en la sección *PRONÓSTICO*; las secciones *EXPERIMENTOS* y *RESULTADOS* examinan casos de prueba y sus resultados; finalmente, exponemos la conclusión y comentamos trabajos futuros que ayudarían a la implementación de la metodología propuesta.

ALGORITMO

Un extenso análisis de la literatura mostró que los métodos SE dinámicos se encuentran entre los más adecuados para las redes de distribución [5]. Por lo tanto, en este trabajo nos enfocamos en un algoritmo SE basado en la metodología UKF. El filtro Kalman unscented es una variante del filtro Kalman [18] para sistemas con una dinámica no lineal. El paso crucial en el filtrado de Kalman es la actualización de la varianza del estado. Cuando las ecuaciones de evolución y observación son lineales, se puede aplicar la fórmula $var(AX) = A^T var(x) A$, donde X es un vector aleatorio y A una matriz. En nuestro caso, la observación actualizada z_{t+1} en la ecuación (6) depende de forma no lineal del estado anterior, por lo que se debe estimar su varianza. De hecho, la ecuación de observación (6) no es lineal y la varianza del valor observado $var(z_t)$ no se puede calcular a partir de $var(x_t)$ en contraste con la varianza del valor predicho que se puede calcular por linealidad como $var(x_{t+1}) = F_t var(x_t) F_t^T$. Para estimar $var(z_t)$, el método UKF calcula un conjunto de puntos llamados *puntos sigma* aplicando una desviación estándar a cada componente del vector de estado alrededor de su valor actual. Luego, los puntos sigma se actualizan

con la ecuación (7) obteniendo nuevos valores que se utilizan para estimar la nueva varianza.

Más específicamente, el algoritmo UKF consta de los siguientes pasos:

- Cálculo de puntos Sigma (ecuación (7)):

$$X_t = \left[x_t \quad x_t + \gamma \sqrt{P_t} \quad x_t - \gamma \sqrt{P_t} \right] \quad (7)$$

- Pronóstico (ecuaciones (8)-(13)):

$$X_{t+1} = F_t X_t + g_t \quad (8)$$

$$x_t^- = \sum_{i=0}^{2N} W_i^{(m)} X_{t+1, i} \quad (9)$$

$$P_t^- = \sum_{i=0}^{2N} W_i^{(c)} \left[X_{t+1, i} - x_t^- \right] \left[X_{t+1, i} - x_t^- \right]^T + Q \quad (10)$$

$$X_{t+1}^- = \left[x_t^- \quad x_t^- + \gamma \sqrt{P_t^-} \quad x_t^- - \gamma \sqrt{P_t^-} \right] \quad (11)$$

$$Z_t = \underbrace{h(X_{t+1}^-)}_{\text{aplicado a cada } X_{t+1}^- \text{ columna}} \quad (12)$$

$$z_t^- = \underbrace{\sum_{i=0}^{2N} W_i^{(m)} Z_{t, i}}_{\text{cada columna } i} \quad (13)$$

- Corrección (ecuaciones (14)-(17)):

$$P_{z_t^- z_t^-} = \underbrace{\sum_{i=0}^{2N} W_i^{(c)} \left[Z_t - Z_t^- \right] \left[Z_t - Z_t^- \right]^T}_{\text{cada columna } i} + R \quad (14)$$

$$P_{x_t^- z_t^-} = \underbrace{\sum_{i=0}^{2N} W_i^{(c)} \left[X_{t, i}^- - x_t^- \right] \left[Z_t - z_t^- \right]^T}_{\text{cada columna } i} \quad (15)$$

$$K_t = P_{x_t^- z_t^-} P_{z_t^- z_t^-}^{-1} \quad (16)$$

$$x_{t+1} = x_t^- + K_t \left(z_k - z_k^- \right) \quad (17)$$

N define la cantidad de variables de estado en el sistema. W Define los pesos con valores: $W_0^{(m)} = \frac{\lambda}{N + \lambda}$, $W_0^{(c)} = \frac{\lambda}{N + \lambda} + (1 - \alpha^2 + \beta)$ y $W_i^{(m)} = W_i^{(c)} = 1 / \{2(N + \lambda)\}$, donde $\lambda = \alpha^2(N + k) - N$ y $\gamma = \sqrt{N + \lambda}$. Los parámetros α y β determinan el *punto sigma* repartido alrededor de x_t (generalmente $10^{-4} \leq \alpha \leq 1$) y la incorporación del conocimiento de la

distribución x_t respectivamente. k suele ser 0 para la estimación de estado y $3-N$ para la estimación de parámetros.

Además, Q es la varianza asociada al error del sistema y define la confianza que el algoritmo otorga al modelo de pronóstico. R es la varianza asociada a las medidas del sistema.

Todos estos parámetros se obtuvieron de [25].

Modelo de variables de estado y OpenDSS

Como se mencionó en la sección *INTRODUCCIÓN*, los valores de potencia activa y reactiva en cada nodo se seleccionaron como variables de estado. En este contexto, es necesario determinar un procedimiento para encontrar el estado completo considerando todas las variables de la red. Este procedimiento debe calcularse a partir del vector de estado.

En consecuencia, el estado completo del sistema se definió como (x, y) donde x es el vector con las variables de estado y y es el vector con el resto de las variables.

En concreto, las variables incluidas en la ecuación (18) y ecuación (19) son las siguientes:

$$x = (v_0, p_{1,a}, p_{1,b}, p_{1,c}, q_{1,a}, q_{1,b}, q_{1,c}, p_{2,a}, p_{2,b}, p_{2,c}, q_{2,a}, q_{2,b}, q_{2,c}, \dots, p_{n,a}, p_{n,b}, p_{n,c}, q_{n,a}, q_{n,b}, q_{n,c}) \quad (18)$$

- v_0 : magnitud del voltaje de referencia.
- $p_{i,f}$: potencia activa inyectada en el nodo i en la fase f .
- $q_{i,f}$: potencia reactiva inyectada en el nodo i en la fase f .

$$y = (v_{1,a}, v_{1,b}, v_{1,c}, \xi_{1,a}, \xi_{1,b}, \xi_{1,c}, \dots, v_{n,a}, v_{n,b}, v_{n,c}, \xi_{n,a}, \xi_{n,b}, \xi_{n,c}, p_{1-2,a}, p_{1-2,b}, p_{1-2,c}, i_{1-2,a}, i_{1-2,b}, i_{1-2,c}, \dots) \quad (19)$$

- $v_{i,f}$: magnitud de voltaje en el nodo i en la fase f .
- ξ : ángulo de voltaje en el nodo i en la fase f (en radianes).
- $p_{i-j,f}$: flujo de potencia activa en la línea $i-j$ en la fase f .
- $q_{i-j,f}$: flujo de potencia reactiva en la línea $i-j$ en la fase f .
- $i_{i-j,f}$: línea actual $i-j$ en la fase f .

Cabe mencionar que el voltaje de referencia fue agregado en el vector x . Este valor es necesario ya

que la red de distribución tiene una topología radial y el sistema debe definirse a partir de la magnitud del nodo raíz.

Luego, se definió la fórmula $y = T(x)$, que encuentra el estado completo del sistema a partir de las variables de estado. Como la función T necesita realizar un cálculo no lineal, en este paso se implementó un motor que usa OpenDSS [26]. OpenDSS es un paquete de software de código abierto desarrollado por EPRI [27, 28], que se puede utilizar para simular redes de distribución. Cuenta con una interfaz COM que puede ser empleada en varios lenguajes de programación. El motor implementado utiliza los valores del vector x para establecer los valores de potencia activa y reactiva en cada nodo y genera el vector y a partir del cálculo del flujo de carga.

Por lo tanto, el vector z de la ecuación (1) se puede descomponer en la ecuación (20) y ecuación (21):

$$z_x = C_x x + \varepsilon_x \quad (20)$$

$$z_y = C_y y + \varepsilon_y \quad (21)$$

C_x y C_y son matrices binarias, donde cada fila consta de ceros y un 1 para indicar la posición que contiene una medida.

En este contexto, el esquema para realizar el cálculo de medidas para cada *punto sigma* correspondiente a la ecuación (12) se expone en la Figura 1.

MODELOS DE PRONÓSTICO PARA LA EVOLUCIÓN DEL SISTEMA

Sobre la ecuación (8) se realiza un pronóstico para determinar la evolución de los *puntos sigma*. En

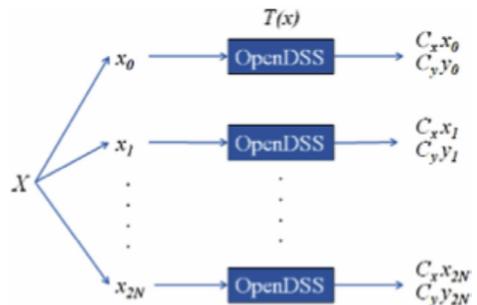


Figura 1. Estado completo y medidas desde puntos sigma usando OpenDSS.

este contexto, se realiza un relevamiento de posibles métodos a aplicar en este paso.

Dinámica constante

Este escenario de predicción propone una evolución inalterada en cada paso del tiempo. Se establece un modelo basado en la ecuación (22).

$$x_{t+1} = x_t \tag{22}$$

Teniendo en cuenta la fórmula (8), se puede determinar que $F_t = I$, siendo I la matriz identidad y $g_t = 0$. Este modelo se apoya en la hipótesis de que los sistemas de potencia respetan una dinámica cuasi-estacionaria.

Suavizado exponencial - Holt

En el marco del sistema eléctrico, las matrices F_t y g_t difícilmente se encuentran para establecer un modelo de pronóstico. Esto se debe a que la dinámica asociada a ellos respeta la evolución correspondiente a las funciones no lineales. En [15] se propone el uso del método de Holt, el cual se basa en el suavizado exponencial. Esto define las matrices F_t y g_t como se describe en la ecuación (23) y ecuación (24).

$$F_t = \alpha_t (1 + \beta_t) I \tag{23}$$

$$g_t = (1 + \beta_t)(1 - \alpha_t)x_t^- - \beta_t a_{t-1} + (1 - \beta_t)b_{t-1} \tag{24}$$

Siendo I la matriz identidad, α_t y β_t parámetros con valores entre 0 y 1, x_t^- es el vector de estado de pronóstico en tiempo pasado. $a_t = \alpha_t x_t + (1 - \alpha_t)x_t^-$ y $b_t = \beta_t(a_t - a_{t-1}) + (1 - \beta_t)b_{t-1}$ se refieren al suavizado de series temporales y la tendencia estimada, respectivamente.

ARIMA

ARIMA comprende una combinación de modelos autorregresivos (AR), integrados (I) y de media móvil

(MA) utilizados en el pronóstico de series temporales. En la mayoría de los casos, se emplean en campos estadísticos y econométricos para realizar estudios de comportamiento financiero. El objetivo de esta técnica es buscar coeficientes y regresiones para pronosticar valores basados en información histórica. Más específicamente, un modelo $ARIMA(p, d, q)$ usa los parámetros p, d y q (enteros no negativos) para indicar el orden de los componentes en cada modelo. La ecuación (25) define el modelo.

$$\underbrace{\left(1 - \sum_{k=1}^p \phi_k L^k\right)}_{\text{Parte autorregresiva}} \underbrace{(1-L)^d}_{\text{Parte integrada}} x_t = \underbrace{\left(1 + \sum_{k=1}^q \theta_k L^k\right)}_{\text{Parte media móvil}} \varepsilon_t \tag{25}$$

L es el operador *shift* que representa la acción de retraso $L^k x_t = x_{t-k}$. ϕ y θ son los coeficientes que debe encontrar el modelo y se asignan a las partes auto regresiva y de promedio móvil, respectivamente. Cada coeficiente está asociado al valor de rezago correspondiente. La parte de integración se dedica a hacer estacionaria la serie temporal, que es un requisito principal cuando se trabaja con estos modelos.

Cuando existe, se puede agregar un componente estacional para considerar su comportamiento en la serie de tiempo. Así, pueden considerarse patrones diarios, semanales, mensuales o anuales. En este caso se formula un modelo $SARIMA$ (promedio móvil integrado autor regresivo estacional) donde se deben definir los parámetros (P, Q, D) para determinar el orden de los componentes estacionales. La ecuación (26) define el modelo matemático.

Donde Φ y θ son los coeficientes de los componentes estacionales para las partes auto regresivas y de promedio móvil, respectivamente. S define el valor del retraso estacional.

Cada parámetro anterior (estacional y no estacional) se fija de acuerdo con la función de auto correlación

$$\underbrace{\left(1 - \sum_{k=1}^P \Phi_k L^{Sk}\right)}_{\text{Parte estacional autorregresiva}} \underbrace{\left(1 - \sum_{k=1}^p \phi_k L^k\right)}_{\text{Parte autoregresiva}} \underbrace{\left(1 - L^S\right)^D}_{\text{Parte int. estacional}} \underbrace{(1-L)^d}_{\text{Parte int.}} x_t = \underbrace{\left(1 + \sum_{k=1}^Q \Theta_k L^{Sk}\right)}_{\text{Parte estacional media móvil}} \underbrace{\left(1 + \sum_{k=1}^q \theta_k L^k\right)}_{\text{Parte media móvil}} \varepsilon_t \tag{26}$$

(ACF) y la función de auto correlación parcial (PACF) de la serie temporal. Finalmente, se despliega el método de máxima verosimilitud para encontrar los coeficientes del modelo.

En este caso, se determina un modelo para cada variable en el vector de estado. Posteriormente, se realiza un pronóstico y se aplica una desviación para calcular los *puntos sigma*.

CASO DE ESTUDIO

El algoritmo propuesto fue probado sobre un ejemplo de una red de distribución llamada IEEE de 13 nodos (115kV - 4.16kV - 0.48kV) [29], utilizando la implementación provista por OpenDSS.

Se simularon valores reales y adquisiciones de medidas en diferentes puntos de la red a lo largo del tiempo. La Figura 2 ilustra la topología y los puntos de medición.

Los valores reales se fijaron a partir de resultados de flujos de potencia, tomando como entradas valores de carga de 4 alimentadores. Esta información fue proporcionada por un distribuidor de energía local a través de su SCADA.

Se realizaron perturbaciones sobre valores reales para simular la adquisición de medidas. El valor de varianza definido fue 0,01 pu.

Además, los valores de entrada utilizados en los flujos de potencia se dieron considerando tres escenarios diferentes para probar el comportamiento del algoritmo con cada método de pronóstico dado en la sección *PRONÓSTICO* en varias situaciones relacionadas con la evolución del sistema. Cada escenario se simuló con diferentes dinámicas en 700 pasos de tiempo.

- Escenario 1: comportamiento de carga constante con pequeñas variaciones a lo largo del tiempo.
- Escenario 2: comportamiento de la carga respetando los patrones diarios. Los patrones son similares en cada carga, pero tienen amplitudes diferentes.
- Escenario 3: Comportamiento de la carga respetando los patrones diarios. Los patrones en cada carga presentan diferentes variaciones estacionales y amplitudes.

Los patrones estacionales y los valores de carga base en cada escenario se obtuvieron considerando el caso real de los alimentadores mencionados anteriormente.

RESULTADOS

En primer lugar, se determinó un índice de error con respecto a los valores reales para analizar el comportamiento del estimador de estado implementado [16, 30, 31, 32]. Este índice considera

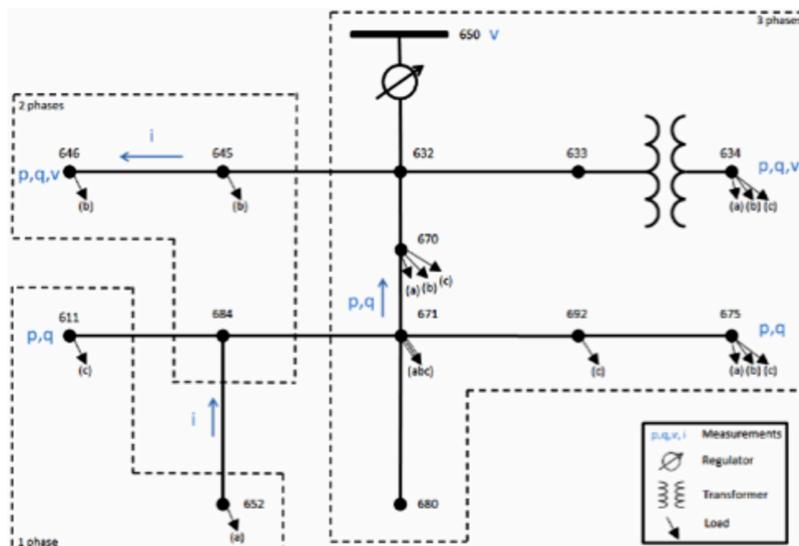


Figura 2. IEEE 13 nodes distribution network.

el error de estimación absoluto medio en cada tiempo y se define como ecuación (27).

$$error_t = \frac{\sum_{i=1}^N |x_{t,i}^r - x_{t,i}|}{N} \quad (27)$$

Donde x_t^r y x_t corresponden al vector de estado real y estimado respectivamente en el tiempo t , y N es el número de variables de estado.

La Figura 3 muestra los valores del índice a lo largo de 700 pasos de tiempo para cada escenario.

Como indica el gráfico, el algoritmo arroja significativos valores de error utilizando el método de Holt, por lo tanto, se descartó como una alternativa viable. Sin embargo, los dos restantes trabajan con un error aceptable, pero en términos generales, ARIMA presenta mejores resultados.

Además, se realizó un estudio en diferentes puntos de la red. Se seleccionaron puntos sin información de medición. La Figura 4 y Figura 5 presentan los

valores reales y estimados con cada método de pronóstico de magnitudes y ángulos de tensión (fase C) en el nodo 692 respectivamente. Por otro lado, en la Figura 6 y Figura 7 se presentan también los valores reales y estimados de magnitudes de tensión para el nodo 633 y ángulos de tensión para el nodo 671. Los gráficos muestran una buena adaptación a la evolución de la magnitud del voltaje con pequeños errores en los valores estimados usando métodos constantes y ARIMA. Además, con respecto a los valores de los ángulos, el método constante tiende a mostrar errores considerables en el escenario más inestable. Sin embargo, ARIMA sigue presentando buenos resultados.

Además, la Figura 8 muestra las potencias activas en el nodo 645 (fase B). En este gráfico, el modelo constante comienza a arrojar mayor error en escenarios más complejos. En concreto, presenta los más significativos en los escenarios 2 y 3. Además, el escenario 3 tiene una dinámica muy variada en el tiempo ya que contiene cambios repentinos y se interrumpe el comportamiento estacional. Esto se debe a que hubo días no convencionales (tales como

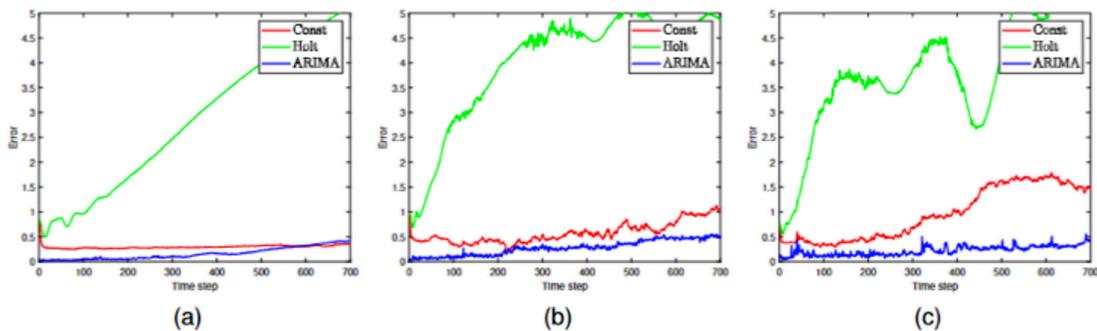


Figura 3. Error de índice para cada escenario. (a) Escenario 1. (b) Escenario 2. (c) Escenario 3.

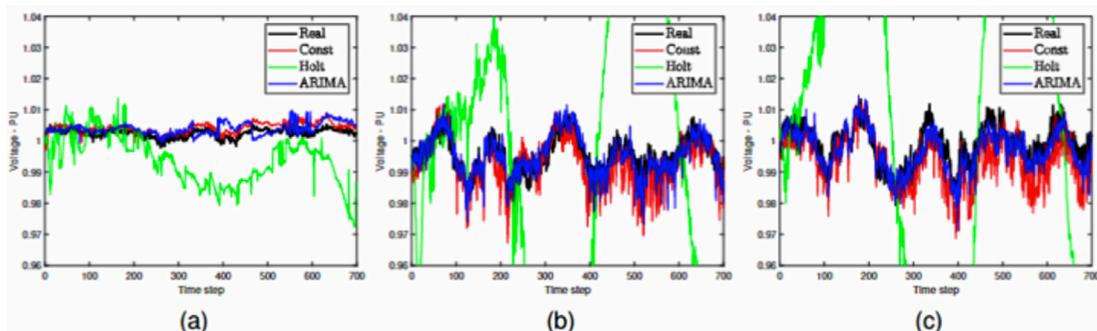


Figura 4. Voltage pu nodo 692 para el escenario. (a) Escenario 1. (b) Escenario 2. (c) Escenario 3.

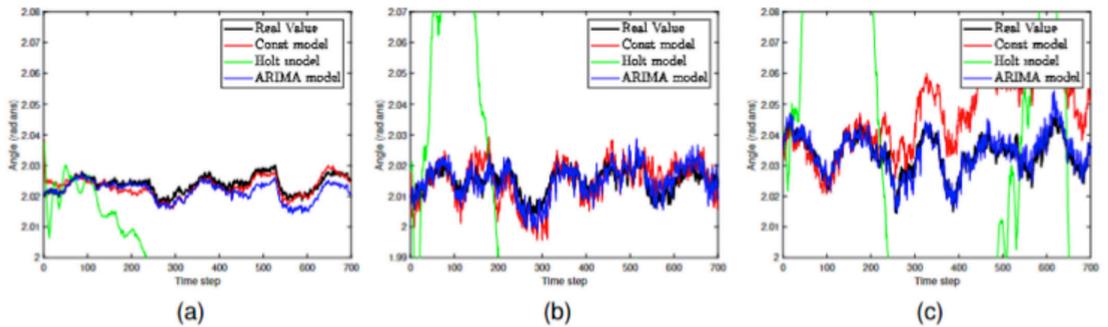


Figura 5. Angulo en nodo 692 para el escenario. (a) Escenario 1. (b) Escenario 2. (c) Escenario 3.

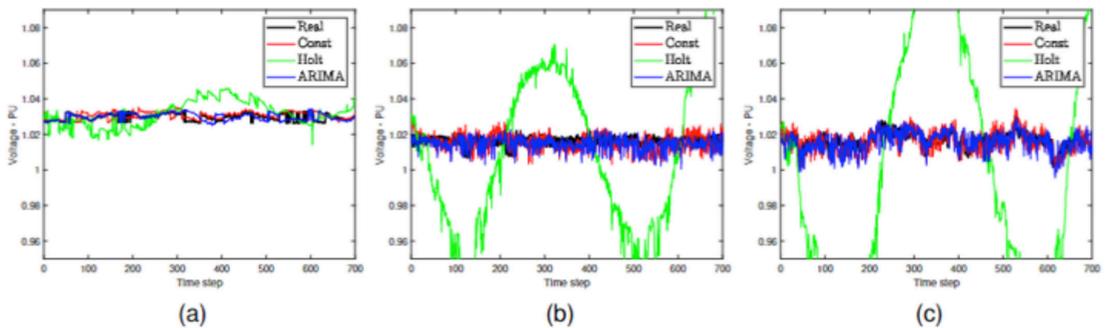


Figura 6. Voltage pu nodo 633 para el escenario. (a) Escenario 1. (b) Escenario 2. (c) Escenario 3.

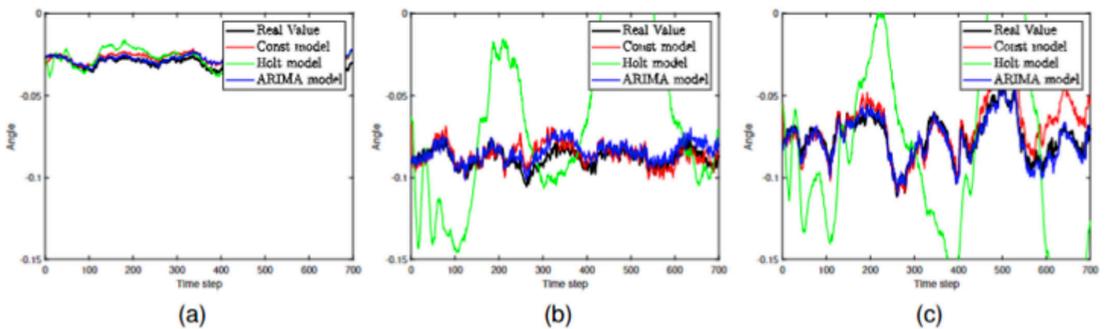


Figura 7. Angulo en nodo 671 para el escenario. (a) Escenario 1. (b) Escenario 2. (c) Escenario 3.

feriados, eventos deportivos, etc.) con observaciones que no respetan la evolución previa, por lo que no respetan la estacionalidad esperada. Sin embargo, ARIMA pudo adaptarse eficientemente al nuevo contexto.

Para analizar un comportamiento promedio, la Figura 9 y Figura 10 representan el error medio promedio (MAE) considerando todas las magnitudes de voltaje y valores de ángulo en cada paso de tiempo para modelos constantes y ARIMA. Además,

la Tabla 1 muestra los respectivos valores medios. Esta información indica un mejor desempeño con el modelo ARIMA a medida que el escenario se torna más complejo. Ambos métodos tienen picos de error en pasos de tiempo que presentan cambios repentinos de cargas.

CONCLUSIONES

Este artículo presenta un método novedoso para SE en redes de distribución. Su técnica se basa en

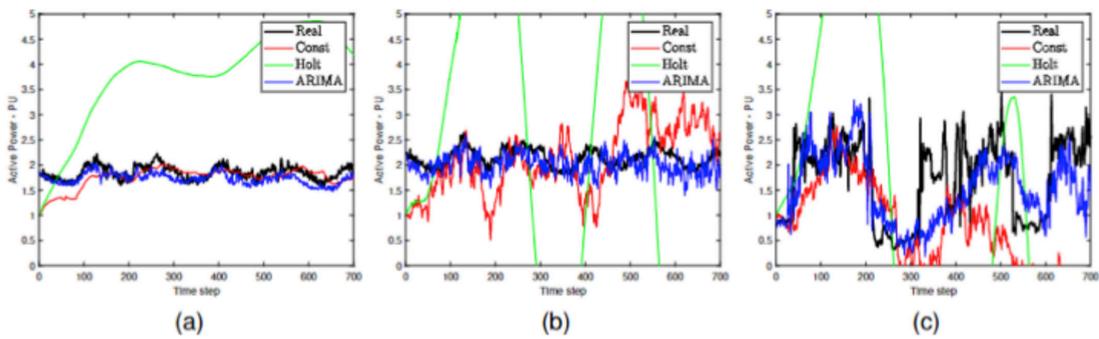


Figura 8. Potencia activa nodo 645 para el escenario. (a) Escenario 1. (b) Escenario 2. (c) Escenario 3.

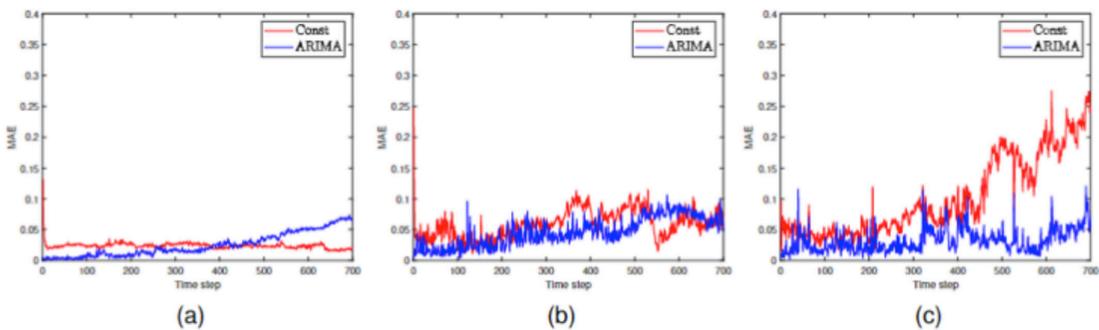


Figura 9. MAE para valores de magnitud de voltaje para cada escenario. (a) Escenario 1. (b) Escenario 2. (c) Escenario 3.

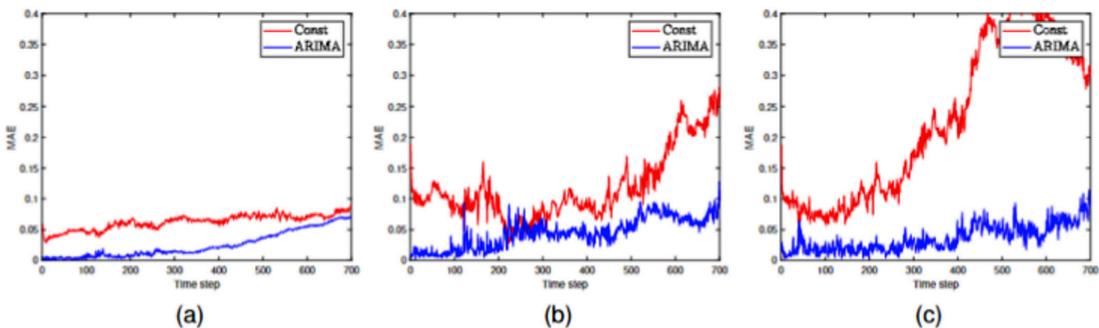


Figura 10. MAE para valores de ángulo para cada escenario. (a) Escenario 1. (b) Escenario 2. (c) Escenario 3.

Tabla 1. Promedio MAE para valores de voltaje y ángulo.

	Voltaje PU (V)		Ángulo (ξ)	
	CONST	ARIMA	CONST	ARIMA
Escenario 1	0,0237	0,025	0,0627	0,0250
Escenario 2	0,0584	0,0460	0,1183	0,0447
Escenario 3	0,1024	0,0323	0,2253	0,0361

diferentes alternativas expuestas en la bibliografía, y aplica el algoritmo UKF utilizando como variables de estado la inyección de potencia activa y reactiva. Se definió un modelo para calcular el estado completo del sistema a partir de variables de estado utilizando la herramienta OpenDSS. Además, se probaron diferentes métodos de pronóstico en el paso de predicción.

Las pruebas se realizaron sobre la topología de 13 nodos de la red de distribución IEEE. La adquisición de mediciones en diferentes puntos se simuló a través de perturbaciones en los resultados del flujo de energía, utilizando datos de medición de un distribuidor de energía local como entrada. Los resultados obtenidos durante las pruebas fueron satisfactorios, en las mismas se compararon los diferentes métodos de pronóstico y ARIMA presentó el mejor desempeño. Estos resultados son prometedores para este nuevo enfoque y deja como trabajo a futuro cuestiones como la consideración de eventos inesperados como días festivos, apagones, etc utilizando variables exógenas con ARIMAX. Además, se puede considerar la aplicación de las técnicas ANN que se han aplicado previamente en el campo de la demanda eléctrica y podrían probarse sobre algoritmos SE dinámicos.

REFERENCIAS

- [1] D. Simon, *Optimal state estimation: Kalman, H infinity, and nonlinear approaches*, 1sted. New Jersey, USA: John Wiley & Sons, 2006.
- [2] J. Chen, Y. Liao, B. Gou, and K. Yocum, "Impacts of load levels and topology errors on WLS state estimation convergence," in *IEEE North Amer. Power Symp. (NAPS)*, Champaign, IL, USA, 2012, pp. 1-6, doi: 10.1109/NAPS.2012.6336329.
- [3] A. Ali and A. Exposito, *Power system state estimation: theory and implementation*, 1st ed. New York, USA: CRC press, 2004.
- [4] M. Pau, P.A. Pegoraro, and S. Sulis, "WLS distribution system state estimator based on voltages or branch-currents: Accuracy and performance comparison," in *Proc. IEEE Int. Instrum. Meas. Technol. Conf. (I2MTC)*, Minneapolis, MN, USA, 2013, pp. 493-498, doi: 10.1109/I2MTC.2013.6555467.
- [5] M. Juárez, "Estimadores de estado en redes de distribución: revisión del estado del arte", Tesis Master, Dep. Ing. Eléctrica, Univ. de Sevilla, Sevilla, España, 2016. [En línea]. Disponible: <https://biblus.us.es/bibing/proyectos/abreproy/70789>
- [6] A. Primadianto and C.N. Lu, "A Review on Distribution System State Estimation," *IEEE Trans. on Power Syst.*, vol. 32, no. 5, pp. 3875-3883, Sept. 2017, doi:10.1109/TPWRS.2016.2632156.
- [7] R. Singh, B. Pal, and R. Jabr, "Choice of estimator for distribution system state estimation," *IET Gener., Transmiss. & Distribution*, vol. 3, no. 7, pp. 666-678, Dec. 2009, doi: 10.1049/iet-gtd.2008.0485.
- [8] L. Hasdorff, *Gradient optimization and nonlinear control*, 1st ed. USA: Krieger Pub Co, 1976.
- [9] A. Ben-Israel, "A Newton-Raphson method for the solution of systems of equations," *J. Math. Anal. Appl.*, vol. 15, no. 2, pp. 243-252, Aug. 1966. doi: 10.1016/0022-247x(66)90115-6.
- [10] C.G. Broyden, "Quasi-Newton methods and their application to function minimisation," *Mathematical Computation*, vol. 21, no. 99, pp. 368-381, Sept. 1967, doi: 10.1090/s0025-5718-1967-0224273-2.
- [11] Z.J. Simendic, C. Vladimir, and G.S. Svenda, "In-field verification of the real-time distribution state estimation," in *CIREN 2005 - 18th International Conference and Exhibition on Electricity Distribution*, Turin, Italy, 2005, pp. 1-4, doi: 10.1049/cp:20051129.
- [12] N. Katic, L. Fei, G. Svenda, and Z. Yongji, "Field testing of distribution state estimator," in *22nd International Conference and Exhibition on Electricity Distribution (CIREN 2013)*, Stockholm, Sweden, 2013, pp. 1-4, doi: 10.1049/cp.2013.0679.
- [13] S. Naka, T. Genji, T. Yura, and Y. Fukuyama, "A hybrid particle swarm optimization for distribution state estimation," *IEEE Trans. Power Syst.*, vol. 18, no. 1, pp. 60-68, Feb. 2003. doi: 10.1109/tpwrs.2002.807051.
- [14] A. Debs and R. Larson, "A dynamic estimator for tracking the state of a power system," *IEEE Trans. Power App. Syst.*, vol. PAS-89, no. 7, pp. 1670-1678, Sept. 1970, doi:10.1109/tpas.1970.292822.
- [15] G. Valverde and V. Terzija, "Unscented Kalman filter for power system dynamic state

- estimation,” *IET Generation, Transmission & Distribution*, vol. 5, no. 1, pp. 29-37, Jan. 2011, doi:10.1049/iet-gtd.2010.0210.
- [16] M. Risso, A. Rubiales, and P. Lotito, “Hybrid method for power system state estimation,” *IET Generation, Transmission & Distribution*, vol. 9, no. 7, pp. 636-643, Apr. 2015, doi: 10.1049/iet-gtd.2014.0836.
- [17] M.B. Do Coutto Filho and J. C. Stacchini de Souza, “Forecasting-Aided State Estimation-Part I: Panorama,” *IEEE Trans. Power Syst.*, vol. 24, no. 4, pp. 1667-1677, Nov. 2009, doi: 10.1109/tpwrs.2009.2030295.
- [18] R. Kalman, “A new approach to linear filtering and prediction problems,” *J. Basic Eng.*, vol. 82, no. 1, pp. 35-45, Mar. 1960, doi: 10.1115/1.366255.
- [19] L. De Alvaro Garcia and S. Grenard, “Scalable distribution state estimation approach for distribution management systems,” in *2011 2nd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies*, Manchester UK, Dec. 5-7, 2011, doi: 10.1109/isgteurope.2011.6162617.
- [20] N. Nusrat, M. Irving, and G. Taylor, “Development of distributed state estimation methods to enable smart distribution management systems,” in *2011 IEEE Int. Symp. Ind. Electron.*, Gdansk, Poland, 2011, pp. 1691-1696, doi: 10.1109/ISIE.2011.5984416.
- [21] M.E. Baran and A.W. Kelley, “State estimation for real-time monitoring of distribution systems,” *IEEE Transactions Power Systems*, vol. 9, no. 3, pp. 1601-1609, Aug. 1994, doi: 10.1109/59.336098.
- [22] K. Li, “State estimation for power distribution system and measurement impacts,” *IEEE Transactions on Power Systems*, vol. 11, no. 2, pp. 911-916, May. 1996, doi: 10.1109/59.496174.
- [23] A.K. Sinha and J.K. Mondal, “Dynamic state estimator using ANN based bus load prediction,” *IEEE Transactions on Power Systems*, vol. 14, no. 4, pp. 1219-1225, Nov. 1999, doi: 10.1109/59.801876.
- [24] D. Falcao and U. Bezerra, “Power system operating state forecasting for security analysis applications,” *Int. J. Elect. Power & Energy Syst.*, vol. 13, no. 6, pp. 330-336, Dec. 1991. doi:10.1016/0142-0615.
- [25] R. Van Der Merwe and E. Wan, “The square-root unscented Kalman filter for state and parameter-estimation,” in *Proc. 2001 IEEE International Conference Acoustics, Speech, Signal Processing*, Salt Lake City, UT, USA. 2001, doi:10.1109/icassp.2001.940586.
- [26] R. Dugan, R. Arrit, R. Henry, T. McDermott, and W. Sunderm, “Open distribution system simulator,” OpenDSS - EPRI. Accessed: Mar. 9, 2023. [Online]. Available: <https://sourceforge.net/projects/electricdss/>
- [27] R. Dugan, R. Arrit, R. Henry, T. McDermott, and W. Sunderm, “Opendss epri distribution system simulator-harmonic load modeling documentation,” OpenDSS - EPRI.2014
- [28] R. Dugan, Reference guide: The open distribution system simulator (opendss), Electric Power Research Institute, Inc, vol. 7, p. 29, 2012.
- [29] W.H. Kersting, “Radial distribution test feeders,” in *IEEE Power Engineering Society Winter Meeting. Conference Proceedings*, vol. 2. Columbus, OH, USA, 2001, pp. 908-912, doi:10.1109/PESW.2001.916993.
- [30] K. Shih and S. Huang, “Application of a robust algorithm for dynamic state estimation of a power system,” *IEEE Transactions on Power Systems*, vol. 17, no. 1, pp. 141-147, Feb. 2002, doi: 10.1109/59.982205.
- [31] S. Huang and K. Shih, “Dynamic-state-estimation scheme including nonlinear measurement function considerations,” *IEE Proc. Generation, Transmission Distribution*, vol. 149, no. 6, pp. 673-678, 2002, doi:10.1049/ip-gtd:20020644.
- [32] C.L. Su and C.N. Lu, “Interconnected network state estimation using randomly delayed measurements,” *IEEE Transactions on Power Systems*, vol. 16, no. 4, pp. 870-878, Nov. 2001, doi: 10.1109/59.962439.
- [33] M. Grewal, “Kalman Filtering,” in *M. International Encyclopedia of Statistical Science*. 1st ed. M. Lovric, Ed., Berlin: Springer Berlin Heidelberg. 2011, pp. 705-708. doi: 10.1007/978-3-642-04898-2_321