



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

DETECCIÓN DE MEDIDAS ERRÓNEAS MEDIANTE ESTRATEGIAS
DE PARTICIÓN PARA LA ESTIMACIÓN DE ESTADO EN SISTEMAS
ELÉCTRICOS DE GRAN ESCALA

TESIS PARA OPTAR AL GRADO DE
DOCTOR EN INGENIERÍA ELÉCTRICA

HENRRY FERNANDO MOYANO BOJORQUE

PROFESOR GUÍA:
LUIS VARGAS DÍAZ

MIEMBROS DE LA COMISIÓN:
RODRIGO MORENO VIEYRA
ANTONIO ZAMBRONI DE SOUZA
MATÍAS NEGRETE PINCETIC

SANTIAGO DE CHILE

2024

RESUMEN DE LA TESIS PARA OPTAR AL
GRADO DE DOCTOR EN INGENIERÍA ELÉCTRICA
POR: HENRRY FERNANDO MOYANO BOJORQUE
FECHA: 2024
PROFESOR GUÍA: LUIS VARGAS DIAZ

DETECCIÓN DE MEDIDAS ERRÓNEAS MEDIANTE ESTRATEGIAS DE PARTICIÓN PARA LA ESTIMACIÓN DE ESTADO EN SISTEMAS ELÉCTRICOS DE GRAN ESCALA

En la operación de los sistemas eléctricos de potencia, garantizar la seguridad y confiabilidad es esencial, lo que implica el monitoreo constante de las variables de control del sistema. Sin embargo, el alto número de estas variables dificulta la toma de decisiones por parte del operador del sistema (SO). Una herramienta como el estimador de estado (SE) se utiliza para evaluar las condiciones del sistema a través de un conjunto de mediciones. No obstante, la presencia de errores en las mediciones, el crecimiento de los sistemas eléctricos de potencia (SEP) y la creciente incorporación de fuentes de energía renovable han complicado el proceso de estimación. Como resultado, se ha desarrollado la estimación distribuida, que se basa en la partición física de un SEP para aplicar estimaciones locales. En este trabajo, proponemos un nuevo enfoque de partición basado en la agrupación nodal. Este enfoque divide el sistema en áreas y distribuye las variables y mediciones considerando a la redundancia como métrica de control del proceso de partición. Esto permite la estimación local y, a partir de los resultados, la detección y corrección de mediciones incorrectas, asegurando estimaciones precisas y eficientes en comparación con trabajos similares

Por el camino se debe continuar, y frente a la adversidad debemos sacar nuestras mejores aptitudes, este trabajo para aquellos que están, estuvieron y confiaron en mi, a Vero, Pame, Martina y Andrea a ellas les dedico este esfuerzo.

Henry

Agradecimientos

La importancia de transitar en la vida implica tener la capacidad de establecer metas, algunas de las cuales se cumplirán mientras que otras serán temporales. Sin embargo, es fundamental reconocer que en este proceso nos encontramos con personas que nos impulsan a seguir adelante y alcanzar nuestros objetivos. Su calidad humana siempre ha estado presente para apoyarme en mis caídas, ayudarme a levantarme y seguir adelante.

Expresar gratitud implica muchas cosas, implica comprometerse a mirar hacia atrás y humildemente mejorar en base a lo aprendido. Quiero agradecer a esta segunda casa que es Santiago, que nos ha acogido y nos ha brindado grandes recuerdos, pero lo más importante, grandes amigos. Espero que el tiempo nos permita reunirnos para recordar.

Quiero agradecer al profesor Luis Vargas por su paciencia, sus consejos y, lo más importante, por su amistad. Su apoyo ha demostrado su gran calidad como ser humano. Siempre estuvo allí para ayudarme a corregir y, sobre todo, reflexionar para alcanzar mis metas.

Por último, no puedo dejar de mencionar a aquellos que nos recibieron el primer día en nuestra llegada a Santiago. A pesar de ser desconocidos en esta gran ciudad, supieron alentarnos y apoyarnos. Agradezco a mi primo, el Dr. Javier Maldonado, y a su familia, quienes han convertido a Santiago y a Chile en su hogar.

Las cosas suceden en su momento y todo debería ser para nuestro bien. Eso es lo que he aprendido en esta experiencia y en este proceso. Gracias a la Facultad de Ciencias Físicas y Matemáticas de la Universidad de Chile, y gracias a todos los profesores por compartir sus conocimientos.

Tabla de Contenido

1. Introducción	1
1.1. Motivación	1
1.2. Definición del Problema	3
1.3. Hipótesis	5
1.4. Objetivos	5
1.4.1. Objetivo General	5
1.4.2. Objetivos Específicos	6
1.5. Alcance del Trabajo	6
1.6. Metodología	7
2. Estado del Arte	9
2.1. Detección e Identificación de Mediciones Erróneas	9
2.2. Fuentes de Información	12
2.3. Modelación del Sistema Eléctrico de Potencia	12
2.4. Estimación de Estado	14
2.4.1. Mínimos cuadrados Ponderados	15
2.4.2. Procesadores Bayesianos	17
2.4.3. Filtro de Kalman (EKF)	19
2.4.4. Filtro Unscented de Kalman (UKF)	20
2.5. Criterios para partición de sistemas	23
2.6. Estimación de Estado Distribuida DSE	24

2.7. Impacto de Recursos Renovables en la estimación de estado	28
2.8. Error en los procesos de estimación	29
2.9. Comentarios Finales	31
3. Validación del modelo	32
3.1. Planteamiento	32
3.2. Procesamiento	33
3.3. Agrupación Nodal	36
3.4. Método Nodal de Partición	37
3.4.1. Conceptos preliminares	38
3.4.2. Formulación del problema	40
3.5. Detección e Identificación de mediciones erróneas	44
3.6. Comentarios Finales	47
4. Análisis de los Resultados	48
4.1. Datos de Simulación	48
4.2. Validación del Modelo	50
4.2.1. Simulaciones en el sistema IEEE 14 Barras	50
4.2.2. Simulaciones en el sistema IEEE 118 Barras	54
4.3. Detección e Identificación de Mediciones Erróneas	65
4.4. Comentarios Finales	70
4.5. Discusión	72
5. Conclusión	74
5.1. Conclusión	74
5.2. Trabajo futuro	75
Bibliografía	85
ANEXO	86

Anexo A. Programa Partición	86
Anexo B. Métodos de Detección de errores	89
B.1. Método de Chi Cuadrado Prueba de Distribución	89
B.2. Método del Gran residual LNR	90

Índice de Tablas

4.1. Varianza del sistema de medición	50
4.2. Resultados: partición del sistema eléctrico IEEE 14 barras con 82 mediciones	52
4.3. Resultados: partición del sistema eléctrico IEEE 14 barras con 60 mediciones	52
4.4. Resultados: partición del sistema eléctrico IEEE 14 barras con 55 mediciones	52
4.5. Resultados: partición del sistema eléctrico IEEE 14 barras con 49 mediciones	52
4.6. Comparación del tiempo de procesamiento entre estimación distribuida y estimación centralizada	53
4.7. Partición Nodal Sistemas IEEE118 Barras: Caso Base	55
4.8. Partición Nodal Sistemas IEEE118 Barras: Caso BN9-2Areas	58
4.9. Partición Nodal Sistemas IEEE118 Barras: Caso BN8-3Areas	58
4.10. Partición Nodal Sistemas IEEE118 Barras: Caso BN7-3Areas	59
4.11. Error cuadrático medio (MSE) y el tiempo de procesamiento en los casos evaluados.	62
4.12. Error Cuadrático del vector de estado (V, θ)	65
4.13. Configuración IEEE118 barras BN7-3.Areas	66
4.14. Análisis del Residual normalizado para la identificación de medidas erróneas	67
4.15. Partición del sistema IEEE118 BN8-5Areas	69
4.16. Distribución de barras del Sistema BN8-5Areas	71

Índice de Ilustraciones

1.1. Estructura General de una Estimación de Estado en un EPS	4
2.1. Algoritmo Filtro de Kalman	20
2.2. Transformación Unsceded, conjunto de puntos distribuidos sobre un error elip- soidal son transformados a un nuevo espacio	21
2.3. Partición de un sistema en n subsistemas, extraido de [1]	27
3.1. Proceso de construcción de los Susistemas	34
3.2. Determinación de los Subsistema en la Iteración n	35
3.3. Diagrama Unifilar: Disposición física de las mediciones	37
3.4. Áreas no solapadas	40
3.5. Barras solapadas	40
3.6. Enlaces solapados	40
3.7. # de mediciones por Barra Nodal (BN)	41
3.8. Nivel de Jerarquía de la Barra Nodal	41
3.9. Proceso de construcción de los subsistemas	42
3.10. Proceso de solapamiento de barras en los Subsistemas	43
3.11. Generación de los Subsistemas Caso IEEE14 barras	44
3.12. Proceso de un Estimador de Estado Distribuido DSE	44
4.1. Caso Estudio Sistema Eléctrico IEEE 14, extraido de [111]	51
4.2. Partición del Sistema Eléctrico IEEE 14 Barras	53
4.3. Tiempo de procesamiento Distribuido vs Centralizado	54

4.4. Caso estudio Sistema eléctrico IEEE 14 barras-82 mediciones, dividido en 3 subsistemas.	54
4.5. Case estudio para grandes Sistemas Eléctricos de Potencia Sistema IEEE118 Barras, extraído de [112]	56
4.6. Distribución de mediciones por barra en el Sistema IEEE118 Barras	57
4.7. Sistema eléctrico IEEE118: caso base desarrollado en [107]	57
4.8. Sistema eléctrico IEEE118: caso BN9	58
4.9. Sistema eléctrico IEEE118: caso BN8	59
4.10. Sistema eléctrico IEEE118: caso BN7	60
4.11. Barra Nodal 9 mediciones	60
4.12. Barra Nodal 8 mediciones	61
4.13. Barra Nodal 7 mediciones	61
4.14. Tiempo de Procesamiento vs MSE en IEEE 118 Barras	63
4.15. Perfil de Tensión de los casos simulados	63
4.16. Distribución física de las Barras en el Proceso de partición de los casos de estudios	64
4.17. Dispersión del Error del Vector de estado (V, θ)	65
4.18. Número de mediciones por barra en el sistema IEEE118	67
4.19. Partición del Caso BN7: (a) Área 1, (b) Área 2, (c) Área 3	68
4.20. Perfil de tensión	68
4.21. Dispersión de error: (a) Con Mediciones Erróneas, (b) Sin Mediciones Erróneas	69
4.22. Barra Nodal 8 mediciones, cambio de configuración	70
4.23. Perfil de Tensión Sistema IEEE118 barras - 439 mediciones	70

Capítulo 1

Introducción

1.1. Motivación

La interconexión continua de los sistemas eléctricos de potencia, junto con las nuevas tecnologías en generación, los avances en los sistemas FACTS, los desarrollos en sistemas de medida como los PMU, y la creciente demanda de energía, han impulsado la evolución de los Sistemas de Gestión de Energía (**EMS**¹). Estos sistemas desempeñan un papel crucial al garantizar la seguridad y confiabilidad de la operación del sistema eléctrico. El origen de esta evolución se remonta al **Blackout**² ocurrido en 1965, el cual dejó sin suministro eléctrico a gran parte del nordeste de los Estados Unidos [1, 2].

Las consecuencias de las pérdidas masivas de suministro eléctrico, conocidas como apagones, han tenido un impacto significativo tanto en términos económicos como en la vida de millones de personas. Estos apagones han generado costos que se estiman en miles de millones de dólares y han afectado a comunidades enteras.

En la actualidad, un Sistema de Gestión de Energía (**EMS**) se compone de una infraestructura fundamental que permite el monitoreo, optimización y control de un sistema de energía eléctrica. El EMS desempeña un papel crucial al proporcionar conocimiento en tiempo real sobre la situación del sistema, lo que ayuda al Operador del Sistema (**SO**³) a tomar decisiones y prevenir trastornos o apagones en la red eléctrica, [3–5]. Basándose en la información proporcionada por el EMS, el SO tiene la responsabilidad de mantener la seguridad del sistema, asegurando que todas las demandas de energía sean suministradas de acuerdo con la capacidad del parque generador, sin violar los límites operativos, como las capacidades de las líneas de transmisión, los límites de tensión y los límites de generación, [6–8]. El SO, desde un centro de control, cumple con estas funciones a través de la ejecución de una serie de protocolos, [9].

El proceso de monitoreo del sistema en un EMS se apoya en una herramienta fundamental

¹*EMS: Energy Management System*

²*Blackout: Pérdida del suministro eléctrico en una área*

³*SO: System Operator*

conocida como estimador de estado (**SE**⁴) [10–13]. El SE se aplica a un sistema eléctrico modelado matemáticamente y su función principal es determinar o aproximar el valor óptimo de variables que no pueden ser capturadas directamente mediante sistemas de medición. La estimación del estado del sistema es de vital importancia, ya que afecta diversas funciones críticas de las redes eléctricas.

Desde una perspectiva estadística, el algoritmo del estimador de estado se formula como un problema de regresión múltiple no lineal. Su objetivo es aproximar el estado más probable del sistema eléctrico de potencia a partir de las variables de estado, que generalmente están representadas por tensiones y ángulos en cada nodo del sistema [14]. Estas variables informan al SO sobre el punto de operación del sistema y las acciones que deben llevarse a cabo, en caso necesario, durante estados de alerta, emergencia o situaciones extremas, para garantizar el retorno del sistema a un estado seguro y normal de operación [15].

La formulación e implementación del estimador de estado en sistemas eléctricos de potencia se remonta a la década de 1970. Fue desarrollado por Schweppe et al. [16, 17] y sus colaboradores, quienes adaptaron el modelo a las características de los parámetros (R-L-C) y la topología de la red (circuitos abiertos/cerrados), así como a un conjunto de datos redundantes de entrada definidos como mediciones, [18].

En el contexto de la estimación de estado en un sistema de energía eléctrica (**EPS**⁵), es fundamental contar con una herramienta que proporcione información confiable para la operación del sistema. El estimador de estado calcula en tiempo real la mejor estimación de la situación actual del sistema, suministrando datos precisos que son esenciales para la supervisión y control del EPS, [19–21] .

Al abordar la estimación del estado en un sistema eléctrico de potencia que se encuentra cerca de su estado de funcionamiento, se deben considerar varios aspectos importantes. Estos incluyen el criterio de estimación a utilizar, la redundancia de las mediciones disponibles y la distribución de probabilidad de los errores aleatorios. La estimación de estado del sistema es la base para la operación y control efectivos del sistema eléctrico [22–24]. Los valores estimados del estado del sistema permiten llevar a cabo las siguientes tareas:

- (a) Supervisión del sistema: Los valores estimados del estado proporcionan información actualizada sobre el funcionamiento del sistema eléctrico, lo que permite una supervisión continua de las variables de interés, como voltajes, corrientes y cargas. Esto ayuda a detectar desviaciones o anomalías que podrían indicar problemas en el sistema.
- (b) Control de la operación: La estimación precisa del estado del sistema es fundamental para tomar decisiones informadas en la operación del EPS. Permite al operador del sistema ajustar y controlar los parámetros del sistema, como la generación, la tensión y la configuración de las líneas de transmisión, de manera óptima y segura.
- (c) Planificación y diseño: La estimación del estado del sistema también es valiosa para la planificación y diseño de sistemas eléctricos. Proporciona información sobre el comportamiento del sistema en diferentes escenarios y condiciones operativas, lo

⁴*SE: State Estimator*

⁵*EPS: Electrical Power System*

que ayuda a tomar decisiones fundamentadas en la expansión de la infraestructura y la integración de nuevas fuentes de energía.

En resumen, la estimación de estado en un sistema eléctrico de potencia es una herramienta esencial para la operación, control, supervisión, planificación y diseño óptimos del sistema. Proporciona información confiable y actualizada que respalda la toma de decisiones en tiempo real y contribuye a la seguridad y confiabilidad del sistema eléctrico.

Es cierto que el proceso de estimación de estado en un sistema eléctrico de potencia puede estar sujeto a diferentes fuentes de error, lo cual puede afectar la precisión de los resultados estimados. Estos errores pueden originarse en los sistemas de medición, la topología del sistema y los parámetros de la red, [25, 26].

Sin embargo, se han desarrollado estrategias y procesos en la evolución de los estimadores de estado en los sistemas de gestión de energía con el objetivo de reducir la influencia de las mediciones erróneas en los valores estimados.

Actualmente, se están planteando enfoques que buscan mitigar los efectos de los errores en la estimación del estado del sistema eléctrico de potencia (EPS). Estos enfoques incluyen la identificación y corrección de posibles errores en las mediciones a través de técnicas de validación y verificación de datos. Además, se consideran métodos de estimación robusta que son menos sensibles a los errores en los parámetros y la topología del sistema. El objetivo es obtener resultados más confiables y precisos en la estimación del estado del EPS, [27–29].

La identificación de errores en la estimación de estado cumple una función importante, ya que permite obtener una estimación no sesgada del estado del sistema eléctrico de potencia. Al minimizar la influencia de esta condición, se mejora la precisión de los valores estimados y se garantiza una base confiable para las decisiones operativas y de control del sistema, [30, 31].

Para tener un enfoque gráfico del proceso de estimación de estado, en la Figura 1.1 se representa un esquema general de las etapas de un estimador estado aplicado a un sistema eléctrico de potencia (**EPS**).

1.2. Definición del Problema

La detección e identificación de medidas erróneas constituye el problema más importante al aplicar un estimador de estado en un Sistema de Energía Eléctrica (**EPS**). La presencia de estas medidas erróneas resta robustez al estimador y puede distorsionar sus resultados. Asimismo, la eliminación de estas medidas involucra la resolución de varios problemas, como la observabilidad, redundancia, exactitud de los valores estimados, robustez del estimador y tiempo de procesamiento.

En la actualidad, la evolución del tema de detección e identificación de medidas erróneas aún considera métodos tradicionales dentro del proceso de estimación de estado. Por ejemplo, se utiliza el estimador de mínimos cuadrados ponderados (WLS), el cual se complementa

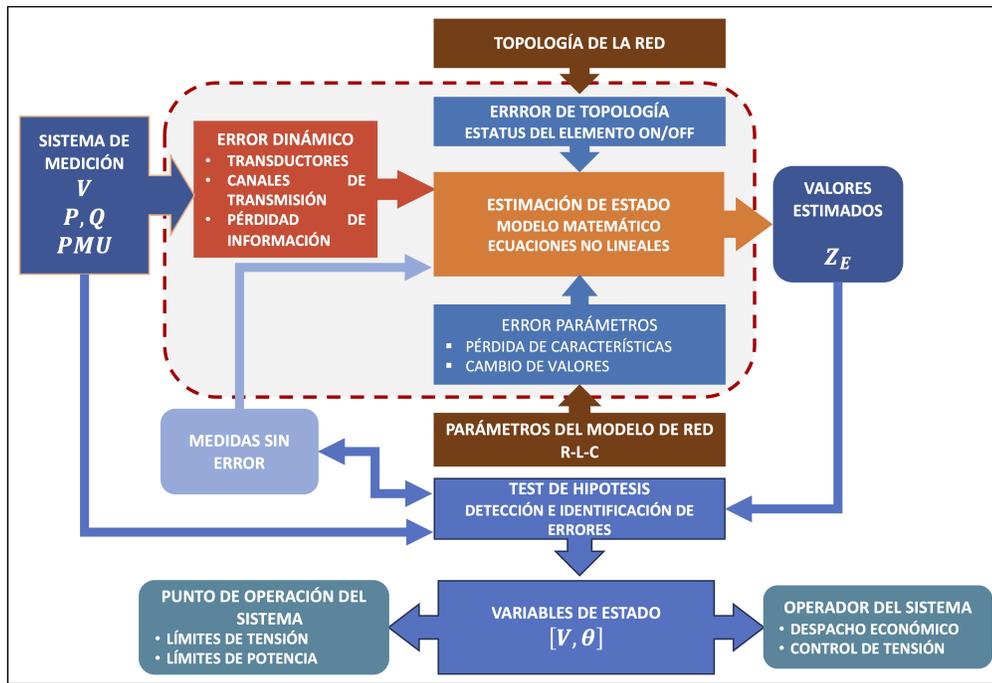


Figura 1.1: Estructura General de una Estimación de Estado en un EPS

con la prueba residual normalizada (LNR) para detectar e identificar errores graves. Sin embargo, esta combinación no es robusta en presencia de errores individuales y/o múltiples [32, 33]. Se ha demostrado que este fallo se debe a que las mediciones erróneas enmascaran los errores de manera significativa, ya que no reflejan sus errores en los residuos del estimador WLS [34, 35]. Además, el estimador WLS solo detecta e identifica datos incorrectos cuando la redundancia local es suficiente. Por lo tanto, los sistemas de medición en los sistemas eléctricos deben ser diseñados para satisfacer los requisitos de observabilidad y redundancia. Esto implica que el número, tipo y distribución topológica de los dispositivos de medición deben proporcionar sistemas de medición observables. Sin embargo, la alta redundancia en los sistemas de medición a menudo no se logra debido a limitaciones técnicas y/o financieras [36–38].

Existen otros métodos para la detección que se basan en el estimador de estado de mínimo valor absoluto ponderado (WLAV), el cual permite la detección de múltiples medidas erróneas, pero es propenso a fallar en presencia de un único error grave en un punto de influencia [39, 40]. También está el estimador de estado de mínima mediana cuadrática (LMS), que puede manejar múltiples medidas erróneas. Sin embargo, estos métodos no son ampliamente aceptados debido a sus altos requerimientos de memoria y tiempo de cálculo [41].

Con el objetivo de mejorar y optimizar la detección e identificación de medidas erróneas, se han desarrollado diversas técnicas de estimación de estado en la literatura internacional. Un enfoque es la estimación centralizada, que se caracteriza por capturar toda la información necesaria para el estimador en una unidad central. Sin embargo, para sistemas de gran tamaño con cientos de barras y líneas, este enfoque no solo implica una comunicación excesiva y cargas computacionales elevadas, sino que también crea un único punto de fallo [42–46].

Se han desarrollado algunos avances que permiten reducir estos efectos mediante el uso de

nuevos sistemas de medición [47–50]. Entre estos avances, se destaca el uso de las Unidades de Medida Fasorial (**PMU**⁶), que realizan mediciones sincronizadas utilizando un sistema de geo-referenciamiento GPS, lo cual proporciona una alta precisión en los datos. El uso de PMU mejora significativamente la estimación de estado, ya que permite medir el fasor de tensión en las barras y el fasor de corriente en las ramas, lo cual reemplaza matemáticamente el sistema no lineal por un sistema lineal, [51].

Otro enfoque que ha sido desarrollado por varios investigadores es el concepto de estimación distribuida o jerárquica, conocido en la literatura como métodos de estimación multi-área (MASE) [52–56]. Estos algoritmos dividen sistemas muy grandes en varios subsistemas y aplican una estimación local en cada uno de ellos, para garantizar la observabilidad de cada subsistema, se establecen criterios para limitar las zonas o áreas, en cada subsistema se definen el conjunto de variables de estado y las restricciones asociadas a las condiciones de frontera entre subsistemas. Luego, se realiza una estimación local y se lleva a cabo el proceso de detección e identificación de medidas erróneas; finalmente, se ensambla el sistema para representar los resultados como una estimación global del sistema con referencia a una única barra.

De acuerdo a lo expuesto anteriormente, queda claro la importancia de contar con un conjunto de mediciones filtradas de errores, que permitan estimar con precisión las variables de estado en el punto de operación de un sistema eléctrico. Es necesario tener en cuenta que la eliminación de medidas en los métodos previamente reportados puede reducir la redundancia y la pérdida de observabilidad del sistema. La propuesta presentada en este proyecto de tesis se basa en el concepto de redundancia local mediante una estimación distribuida, con el objetivo de mejorar el proceso de estimación y la detección e identificación de medidas erróneas.

1.3. Hipótesis

Se plantea que es factible desarrollar un algoritmo de partición que permita construir subsistemas en el proceso de estimación distribuido, considerando el número de mediciones asociadas a cada barra, con el objetivo de mejorar el proceso de estimación de estado. Además, se postula que mediante la implementación de este modelo de partición, se logrará mejorar el proceso de identificación de mediciones erróneas.

1.4. Objetivos

1.4.1. Objetivo General

El propósito fundamental de esta investigación consiste en concebir y elaborar un algoritmo de partición destinado a la formación de subsistemas durante el procedimiento de

⁶PMU: *Phasor measurement unit*

estimación distribuida en sistemas eléctricos. Este algoritmo se diseñará tomando en consideración el número de mediciones asociado a cada barra. La meta primordial es optimizar el proceso de estimación de estado a través de estimadores convencionales WLS y filtros Bayesianos EKF y UKF, al mismo tiempo que se perfecciona la detección e identificación de mediciones erróneas en el sistema eléctrico. Todo ello se llevará a cabo teniendo en cuenta la naturaleza dinámica intrínseca de los sistemas eléctricos.

1.4.2. Objetivos Específicos

Los objetivos específicos de esta Tesis son los siguientes:

1. Investigar y analizar de manera exhaustiva los métodos existentes de partición de sistemas eléctricos en el contexto de la estimación distribuida y la detección de mediciones erróneas.
2. Desarrollar un algoritmo de partición que tome en cuenta el número de mediciones asociado a cada barra, con el objetivo de construir subsistemas óptimos durante el proceso de estimación distribuida.
3. Implementar y evaluar el rendimiento del algoritmo de partición en sistemas eléctricos de prueba, con el fin de determinar su eficacia para mejorar el proceso de estimación de estado y para la identificación de mediciones erróneas.
4. Evaluar y comparar el rendimiento del algoritmo propuesto con otros métodos de partición existentes, considerando criterios de precisión, eficiencia y escalabilidad.
5. Minimizar la pérdida de información y su impacto en la robustez del estimador y en los valores estimados, asegurando la integridad y confiabilidad del proceso de estimación distribuida.
6. Proponer recomendaciones y pautas para la implementación y aplicación práctica del algoritmo de partición en sistemas eléctricos reales, considerando aspectos técnicos, operativos y económicos para garantizar su viabilidad y efectividad en entornos prácticos.

Estos objetivos específicos se centran en desarrollar, implementar y evaluar el algoritmo de partición propuesto, así como en analizar su efectividad y viabilidad en el contexto de la estimación distribuida y la detección de mediciones erróneas en sistemas eléctricos.

1.5. Alcance del Trabajo

El alcance del trabajo propuesto se detalla a continuación:

1. Investigar y analizar métodos existentes de partición de sistemas eléctricos en el contexto de la estimación distribuida y la detección de mediciones erróneas:

- Se revisarán y analizarán estudios e investigaciones previas relacionadas con la partición de sistemas eléctricos y la detección de mediciones erróneas en la estimación de estado.
 - Se considerarán diversos métodos y enfoques utilizados en la literatura para comprender sus fortalezas, limitaciones y aplicabilidad en el contexto de esta investigación.
2. Desarrollar un algoritmo de partición que considere el número de mediciones asociado a cada barra para construir subsistemas óptimos en el proceso de estimación distribuida:
 - Se diseñará y desarrollará un nuevo algoritmo de partición basado en criterios que tengan en cuenta el número de mediciones disponibles en cada barra.
 - El algoritmo se enfocará en optimizar la construcción de subsistemas para mejorar la estimación de estado y la detección de mediciones erróneas.
 3. Implementar y evaluar el algoritmo de partición en sistemas eléctricos de prueba:
 - Se seleccionarán sistemas eléctricos de prueba representativos de diferentes tamaños y características para implementar el algoritmo de partición.
 - Se realizarán pruebas y simulaciones utilizando datos simulados o históricos para evaluar el rendimiento del algoritmo en términos de precisión, eficiencia y escalabilidad.
 4. Comparar el rendimiento del algoritmo propuesto con otros métodos de partición existentes:
 - Se seleccionarán métodos de partición existentes utilizados en la estimación distribuida y la detección de mediciones erróneas para realizar una comparación detallada.
 - Se evaluarán y compararán los resultados obtenidos por el algoritmo propuesto con los de otros métodos en términos de precisión, eficiencia y capacidad de detección de mediciones erróneas.
 5. Validar el método de partición y su aplicación en la detección y corrección de mediciones erróneas.
 - en los proceso de estimación de estado se aplicarán métodos convencionales, tales como el de mínimos cuadrados ponderados WLS y Filtros Bayesianos tales como el EKF iterativo
 - Para la determinación de las mediciones erróneas se aplicará el Chi Cuadrado
 6. Proponer recomendaciones y pautas para la implementación y aplicación práctica del algoritmo de partición en sistemas eléctricos reales:

1.6. Metodología

Para cumplir con los los objetivos, se revisó el marco teórico aplicado a una estimación de estado distribuida en sistemas eléctricos de potencia que permitan determinar un modelo en el proceso de partición, considerando los criterios matemáticos para que luego de su

aplicación, compararlos con procesos de estimación de estado centralizado y distribuido y determinar su eficiencia.

La estructura de la tesis se indica a continuación. En el Capítulo 1 se presenta un breve resumen del trabajo y la introducción de toda la propuesta basados en una estimación de estado distribuido y la identificación de mediciones erróneas. Luego, en el Capítulo 2 se realiza una revisión del Estado de Arte, sobre los métodos aplicados en los procesos de estimación distribuida analizando sus características y alcances. En el Capítulo 3, se desarrolla la propuesta metodológica para la implementación del método de partición, en el Capítulo 4, se detalla la implementación del modelo y los resultados del estudio; y, en el Capítulo 5 se presentan las conclusiones del trabajo final y el camino a seguir en trabajos futuros.

Capítulo 2

Estado del Arte

Desde la implementación de los estimadores de estado en los sistemas eléctricos de potencia [57], se han realizado numerosos avances en este campo con el objetivo de mejorar la robustez de los estimadores. Estos avances incluyen el desarrollo de nuevas técnicas y algoritmos de estimación, la creación de métodos más eficientes para la detección e identificación de errores, la implementación de estrategias para corregir errores topológicos y ajustar parámetros, y la utilización de estimadores que permitan modelar la dinámica del sistema.

En el presente trabajo, se propone un enfoque específico, por lo tanto, a continuación se describirán los desarrollos más relevantes que han contribuido al estado del arte en el contexto de este proyecto de tesis.

2.1. Detección e Identificación de Mediciones Erróneas

Existen diversas fuentes de errores que pueden afectar el desempeño de los estimadores del estado. Estas incluyen errores de topología que pasan desapercibidos para el operador, errores gruesos en las mediciones y transductores, errores de parámetros en la base de datos, y la naturaleza no sincronizada de las mediciones convencionales. Sin embargo, el desarrollo de unidades de mediciones sincronizadas ha abierto nuevas oportunidades para mejorar el monitoreo de las redes de energía. Como se ha mencionado anteriormente, la detección e identificación de medidas erróneas es una parte fundamental de cualquier estimador de estado (SE). La capacidad del estimador para detectar datos incorrectos está relacionada con las características de los sistemas de medición, la configuración de la red y los parámetros de la misma. Por tanto, diversos estudios se centran en la identificación de errores en los parámetros, la detección de errores en la topología y, especialmente, la detección e identificación de mediciones erróneas [58, 59].

Según [60], uno de los beneficios fundamentales de utilizar un estimador de estado es su capacidad para detectar, identificar y corregir errores en las mediciones. Este proceso se conoce como procesamiento de datos erróneos, el cual puede llevarse a cabo como parte de la estimación de estado o como un procedimiento de post-estimación, dependiendo del método,

utilizado. Independientemente del enfoque de estimación de estado, la detectabilidad de los datos erróneos depende de la configuración de las mediciones y la redundancia presente.

La medida errónea se refleja en un residual normalizado elevado, el cual no está relacionado con la escala del sistema de energía, sino que depende únicamente de la redundancia de las mediciones. Cuanto mayor sea el nivel de redundancia, mayor será la ventaja del elemento diagonal en la matriz y , y por lo tanto, será más fácil detectar los datos erróneos [22, 49].

Ma et al. [61, 62] presentaron un enfoque para detectar datos anómalos en los sistemas SCADA, que pueden ser causados por mal funcionamiento de los dispositivos, ataques de hackers u otro tipo de manipulación malintencionada. En su método, en lugar de utilizar directamente las mediciones SCADA como fuente de datos erróneos, utilizan los residuales calculados con la ayuda de un estimador de estado. Luego, mediante el algoritmo BACON (Block Adaptive Computationally efficient Outlier Nominator), determinan los valores atípicos que identifican los errores

Otros métodos para la detección, como el propuesto por [63], aplican técnicas de estimación distribuida, donde los subsistemas se forman en base a sus niveles de tensión. Según los autores, este enfoque reduce significativamente el impacto negativo de la falta de homogeneidad en el régimen calculado y la información telemétrica en el cálculo de los subsistemas de una clase de tensión. Esto permite utilizar un método más eficiente de detección de medidas erróneas para cada subsistema.

Por otro lado, [64] propone la aplicación de un concepto de error de propagación residual en el área. Este método descompone todo el sistema en varias regiones no superpuestas, donde los datos de medición errónea solo afectan a las mediciones dentro de cada región. El enfoque propuesto considera un sistema de energía interconectado operado por múltiples operadores de sistemas o centros de control, según los límites administrativos. Sin embargo, los datos de medición erróneos en una región administrativa pueden afectar los índices de rendimiento de otras regiones debido al acoplamiento físico entre los subsistemas. Por lo tanto, el método evalúa qué regiones pueden ser afectadas por los datos erróneos de medición.

En el artículo de Granelli et al., los autores plantean el problema como una optimización no lineal con variables mixtas. Para resolverlo, se utilizan técnicas de optimización combinatoria, como el método "*branch and bound*" (BB) propuesto en [65], algoritmos genéticos (GA) y la técnica de búsqueda Tabu (TS). Estos enfoques se estructuran en tres etapas principales:

- i. Generación de una identificación tentativa de bad data
- ii. Solución a la estimación de estado; y,
- iii. Almacenamiento de memoria de los casos considerados.

Con el fin de acelerar la solución de la estimación de estado, se considera el uso de técnicas de sensibilidad. Además, se destaca que el almacenamiento eficiente de casos resueltos y la amplitud de la búsqueda desempeñan un papel crítico en la determinación de la eficiencia de los procedimientos. El cálculo de la estimación de estado en relación a un caso de identificación se considera computacionalmente la parte más exigente de cada procedimiento.

En el estudio realizado por Tarali et al. en [66], se presenta una forma de detectar e identificar medidas erróneas en las mediciones utilizando mediciones fasoriales de **PMU**. Estas

mediciones permiten transformar las medidas críticas en redundantes, sin modificar el estimador convencional inicial. Gracias a la sincronización del sistema de posicionamiento global (GPS) de señales satelitales, es posible realizar mediciones directas, precisas y sincronizadas de los fasores de tensión y corriente en el sistema eléctrico. Por otro lado, en [47] se plantea que para hacer frente a las medidas erróneas, se puede optar por estimar primero las ubicaciones o estimar simultáneamente sus ubicaciones y valores.

En el artículo [67], se plantea que la identificación de múltiples datos erróneos es un problema de optimización combinatoria. Para abordar este problema, se utiliza el método basado en PSO (Optimización por Enjambre de Partículas) con un procesamiento paralelo o PC-clúster. Este enfoque utiliza un vector binario de m dimensiones que agrupa las mediciones buenas y malas, lo que permite explorar las 2^m combinaciones posibles. Estas combinaciones se evalúan dentro de una función objetivo para determinar las mediciones erróneas.

En la literatura se ha destacado la importancia de contar con un sistema de medición que garantice valores estimados confiables. Con el avance tecnológico, el uso de unidades de medida fasorial (PMU) ofrece ventajas significativas. Estas unidades permiten establecer una referencia de ángulo de fase en un tiempo de referencia mundial, lo cual es de gran ayuda para capturar instantáneamente datos del sistema de energía. La utilización efectiva de esta tecnología resulta muy útil en la mitigación de apagones y en el monitoreo en tiempo real del comportamiento del sistema de energía [68].

Por otro lado, en [69], Zhu et al. presentan una formulación basada en coordenadas rectangulares utilizando PMU. Esta formulación permite el uso de medidas fasoriales de tensión y corriente sin dificultades numéricas, lo que facilita la detección y la identificación de errores. Además, se presenta una simplificación conveniente debido a cómo se puede desacoplar el nuevo Jacobiano en coordenadas rectangulares, lo que conduce a una prueba de observabilidad más simple.

En [70], se plantea una estimación distribuida utilizando el concepto de "SuperCalibrador". Este enfoque combina las características de los equipos de medición sincronizados, como las unidades de medida fasorial (PMU), con las medidas tradicionales para la estimación del estado de un sistema eléctrico. El modelo propuesto considera las variables de estado como la tensión de cada fase y la tensión referida al neutro.

La implementación de este enfoque se realiza a nivel de subestación, tratando cada subestación como un subsistema. En esta implementación se aplican las siguientes técnicas o etapas:

- i. La estimación.
- ii. Identificación de errores
- iii. Procesamiento de alarmas, y,
- iv. Para el acoplamiento de todos los sistemas considera una estimación coordinada.

2.2. Fuentes de Información

Como se ha mencionado anteriormente, el estimador de estado depende de un conjunto de fuentes de información para estimar los estados del sistema. En este contexto, se pueden destacar los siguientes elementos según [71]:

1. Los valores de los parámetros de diseño (R, L).
2. La información topológica o estructural (posición de interruptores).
3. El modelo matemático que represente el espacio de estado, el cual considera el modelo de planta y el modelo del sistema de medición.
4. Los distintos tipos de medida:
 - (a) Tele-medidas: medidas en tiempo real desde las unidades remotas de las subestaciones a través del SCADA y/o PMU.
 - (b) Pseudo-medidas: conjunto de datos históricos, menos precisión; por ejemplo, la potencia generada en las centrales o la demanda de las subestaciones.
 - (c) Medidas virtuales: que no requieren ser medidas; por ejemplo la inyección cero en las subestaciones de transporte (nudos de tránsito).

La mayoría de las aplicaciones de Sistemas de Gestión de Energía (**EMS**) asumen que el sistema se encuentra en un estado pseudoestático, lo que permite realizar análisis de corriente alterna utilizando fasores. Para determinar el estado del sistema, se utiliza el modelo de la red y los fasores de tensión en todas las barras. Si bien es posible estimar los fasores de tensión en las barras basándose en un conjunto redundante de mediciones, la obtención de mediciones directas de fasores solo es posible si se sincronizan las mediciones.

Las unidades de medida fasorial (PMU) son dispositivos que aprovechan el posicionamiento geo-referenciado satelital GPS para sincronizar las mediciones temporales. Estos dispositivos recopilan señales de tensión y corriente en los secundarios de los transformadores de medida (CT y PT) y toman muestras a una velocidad de 48 muestras por ciclo. Posteriormente, estas muestras se procesan y sincronizan con la Hora Universal Coordinada (UTC) mediante un receptor GPS, con una precisión de hasta 1 segundo, según se menciona en [72].

El estándar IEEE C37.118 describe los requisitos, el formato y el protocolo de comunicación de datos proporcionados por los PMU, que son las unidades encargadas de capturar y transmitir las mediciones de fasores y otros parámetros del sistema eléctrico.

2.3. Modelación del Sistema Eléctrico de Potencia

Para abordar el problema de estimación del estado en sistemas eléctricos de potencia, es crucial comprender el comportamiento del sistema a través de su vector de estado y su modelo matemático correspondiente. Una aproximación común es utilizar el enfoque de

espacio de estado [73]. En este enfoque, el vector de estado del sistema eléctrico de potencia en cada instante de tiempo se compone de los fasores de tensión de las barras, que pueden ser descompuestos en magnitud y ángulo. Por lo tanto, el vector de estado se representa como $x(n) = (\delta_1, \delta_2, \delta_3, \dots, V_1, V_2, V_3, \dots)$, donde la dimensión del vector de estado para N barras está determinada por las 2N-1 variables de estado necesarias. Estas variables incluyen los módulos de tensión en las N barras y los ángulos de fase, medidos con respecto a una barra de referencia conocida como "slack".

Los modelos propuestos en [74–76] describen la dinámica del sistema en tiempo lento. Estos modelos asumen que el comportamiento del sistema es casi estacionario y se controla en intervalos de tiempo de unos pocos minutos. Se plantea una transición discreta en el tiempo lineal (predicción) de los estados para representar el comportamiento del sistema.

$$x_{t+1} = F_t x_t + g_t + w_t \quad (2.1)$$

Donde la matriz F_t y el vector g_t describen el proceso de transición de los estados y w_t es el ruido del proceso. Un enfoque común y ampliamente aceptado para el cálculo de F y g es la técnica de identificación de parámetros en línea (Método del Holt), [77]. En [74] se propone un método para calcular F y g sobre la base de una transición de estado usando las ecuaciones de la red. La transición para cada estado tiene en cuenta el efecto de las variaciones de estado vecino. De igual manera y en las siguientes secciones se deben considerar las ecuaciones que modelan las inyecciones y flujos de potencia activa y reactiva y que se presentan a continuación.

Ecuaciones de potencia:

$$P_i = \sum_{j=1}^N V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}). \quad (2.2)$$

$$Q_i = \sum_{j=1}^N V_i V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}). \quad (2.3)$$

Ecuaciones de flujo de potencia:

$$P_{ij} = V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) - G_{ij} V_i^2. \quad (2.4)$$

$$Q_{ij} = V_i V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) - V_i^2 (B_{ij} - b_{ij}). \quad (2.5)$$

donde:

- P_i, Q_i :inyección de potencia activa y reactiva de la barra *i-esima*.
- V_i, V_j :los módulos de las tensiones entre barras *i-esima* y *j-esima*.
- P_{ij}, Q_{ij} :flujo de potencia activa y reactiva entre las barras *i-esima* y *j-esima*.
- $\theta_{ij} = \theta_i - \theta_j$:desfase entre las tensiones en las barras *i* y *j*.
- G_{ij} :componente real del elemento *i, j-esimo* de la matriz de admitancia nodal.

B_{ij} :componente imaginaria del elemento i, j -ésimo de la matriz de admitancia nodal.
 b_{ij} :Admitancia paralelo del modelo de la línea que une el nodo i con el nodo j .

2.4. Estimación de Estado

El objetivo de la estimación de estado en un sistema eléctrico de potencia es encontrar la mejor estimación $\hat{\mathbf{x}}$ del estado verdadero \mathbf{x} que se ajuste a las medidas \mathbf{z} relacionadas con \mathbf{x} a través de un modelo no lineal [78].

Este proceso implica el procesamiento de mediciones redundantes e imperfectas para obtener la mejor estimación del estado del sistema. El estimador de estado actúa como un filtro entre todas las mediciones recibidas de la red y las aplicaciones del Sistema de Gestión de Energía (**EMS**) que requieren información precisa y confiable sobre el estado real de la red [79, 80].

En la década de 1970, se desarrolló un nuevo tipo de estimador de estado que permitió rastrear las condiciones de operación del sistema. Este estimador utilizaba series consecutivas y no correlacionadas de mediciones que varían en el tiempo [81]. Se basaba en la suposición de que la red se comporta de manera cuasi-estacionaria, determinada por cambios lentos y dinámicos en la carga.

Como se sabe, el sistema de energía no es estático, sino que experimenta cambios a lo largo del tiempo, aunque de manera muy lenta. Cuando las cargas cambian, la generación debe adaptarse a esos cambios, lo que a su vez afecta los flujos de energía y las inyecciones en todas las barras del sistema de energía. Estos cambios dinámicos en el sistema de potencia no pueden ser capturados por un estimador de estado estático tradicional (SSE).

Por lo tanto, se desarrolló una nueva técnica llamada estimador de estado dinámico (DSE) [82]. El DSE tiene en cuenta la dinámica del sistema y permite relacionar el vector de estado con las observaciones a través del uso del espacio de estados. Esto implica que el modelado de la dinámica del sistema debe ser capaz de establecer dicha relación.

Bajo esta nueva evolución, se plantea la implementación de dos enfoques para aplicar el Estimador del Estado Distribuido (DSE): el enfoque centralizado y el enfoque descentralizado. En el artículo [83], se presenta el DSE centralizado que asume que el sistema es observable mediante un sistema de medición compuesto por PMU. Este enfoque utiliza una reducción de Kron para simplificar el sistema a las terminales de los generadores, pero requiere un conocimiento preciso de los parámetros de cada componente del sistema y mediciones PMU en tiempo real.

Por otro lado, el DSE descentralizado se implementa utilizando únicamente mediciones PMU locales y cumple con el criterio de observabilidad local de los estados dinámicos. Este enfoque permite aplicaciones de monitoreo y control a nivel local. A diferencia del DSE centralizado, el DSE descentralizado es más rápido de ejecutar y no se ve afectado por la inexactitud del modelo de otros componentes del sistema. Sin embargo, la redundancia de

las mediciones locales es baja y se implementan controles locales, [84].

El DSE centralizado ofrece la ventaja de lograr una monitorización y control global, además de contar con una mayor robustez frente a problemas de calidad y seguridad de datos debido a la alta redundancia de las mediciones. No obstante, requiere una carga computacional elevada y se basa en suposiciones fuertes sobre la precisión de los modelos del sistema dinámico completo. En contraste, el DSE descentralizado tiene un menor requerimiento de mediciones y depende del modelo dinámico de los componentes de interés, lo que lo hace más rápido de ejecutar. Sin embargo, la redundancia de las mediciones locales es baja y se limita a controles locales

Por lo tanto, el análisis de un sistema dinámico requiere al menos dos modelos: primero, un modelo que describe la evolución del estado con el tiempo (ecuación de estado o de planta), y segundo, un modelo que relaciona las medidas ruidosas con el estado (ecuación de observación o verosimilitud). La formulación probabilística del espacio de estados y el requisito de actualizar la información con la recepción de nuevas medidas se llevan a cabo idealmente mediante la aproximación Bayesiana.

En las siguientes secciones se presenta una breve descripción de dos tipos de estimadores: el más utilizado en los desarrollos de estimación, que es el de mínimos cuadrados, caracterizado por su naturaleza estática; y los estimadores basados en la teoría Bayesiana, que permiten capturar la dinámica del sistema.

2.4.1. Mínimos cuadrados Ponderados

El método de estimación de mínimos cuadrados ponderados (WLS) es un estimador de tipo estático que se utiliza para encontrar el estado subyacente que minimiza la diferencia entre las mediciones estimadas y las mediciones reales. Este método se basa en un modelo determinado por el proceso de medición y utiliza pesos para dar mayor importancia a ciertas mediciones sobre otras. Referencias como [85, 86] abordan y discuten este enfoque de estimación.

$$z = h(x) + v \tag{2.6}$$

donde:

\mathbf{z} el vector de m -medidas del sistema.

\mathbf{x} el vector de n -variables de estado del sistema

h_i función no lineal que relaciona la medida con el vector de estado \mathbf{x} .

\mathbf{v} el vector de error de \mathbf{m} -medidas.

El estado del sistema, representado por el vector de estado \mathbf{x} , está relacionado con las mediciones recibidas \mathbf{z} a través de un proceso no lineal descrito en la ecuación (2.6). En este modelo, se asume que el error \mathbf{v} es aleatorio y sigue una distribución normal con media cero y covarianza \mathbf{R} . El conjunto de mediciones incluye magnitudes de voltaje, inyecciones y flujos de potencia.

La estimación óptima del estado del sistema utilizando el método de mínimos cuadrados ponderados (WLS) o estimación de máxima verosimilitud se define como la solución al problema de optimización del error cuadrático, como se describe en la ecuación (2.7). Este enfoque busca encontrar el estado del sistema que minimiza la diferencia cuadrática entre las mediciones estimadas y las mediciones reales.

$$\min J(x) = \min \sum_{j=0}^{N-1} \frac{[z_i - h_i(x)]^2}{\sigma^2} \quad (2.7)$$

El estimador WLS no tiene memoria, lo que significa que sus valores estimados se calculan únicamente a partir de las entradas actuales del sistema, sin tener en cuenta el estado previo. Sin embargo, debido a la naturaleza no lineal del modelo de un sistema eléctrico de potencia y su dinámica, el estimador WLS no captura completamente este proceso.

Para abordar esta limitación, se propone un proceso iterativo que permite estimar las magnitudes del vector de estado. Como resultado, se obtiene la siguiente ecuación

$$x^{k+1} = x^k + [H^T(x)R^{-1}H(x)]^{-1} H^T(x)R^{-1}[z - h(x)] \quad (2.8)$$

donde:

H es la construcción de la matriz Jacobiana
R matriz de covarianza de las mediciones w
z mediciones u observaciones del sistema
 $h_i(x)$ ecuaciones del modelo matemático
x variables de estado.

Este proceso iterativo tiene en cuenta las relaciones no lineales del sistema y permite una mejor estimación de las magnitudes del estado en cada iteración.

El método WLS se ha utilizado ampliamente en los centros de control de todo el mundo debido a sus propiedades de simplicidad y rápida convergencia. Sin embargo, a pesar de que la estimación estática del WLS puede ser aceptable en condiciones completamente observables, no puede predecir el punto de funcionamiento futuro del sistema. Por lo tanto, para cada nuevo conjunto de mediciones, el estimador debe reiniciarse utilizando un vector de estado inicial x_0 , sin utilizar ninguna predicción del estado basada en estimaciones anteriores.

En los sistemas eléctricos actuales, donde las mediciones se realizan principalmente mediante SCADA, el WLS se utiliza comúnmente para resolver el problema de estimación de estado. Estas mediciones incluyen la inyección de potencia en las barras, el flujo de potencia en las líneas y la magnitud del voltaje en las barras. Aunque el WLS es ampliamente utilizado, no es robusto ya que falla en presencia de mediciones erróneas.

En contraste, el estimador de valor absoluto mínimo (LAV) es más robusto, pero tiene un alto costo computacional. Una de las características del estimador LAV es su capacidad para rechazar automáticamente las mediciones erróneas. Al utilizar mediciones fasoriales, el

estimador LAV ofrece dos ventajas importantes, según se describe en [87]:

1. Si el conjunto de mediciones consiste solo en fasores, el efecto de palanca de las mediciones se puede eliminar fácilmente mediante un escalado estratégico;
2. El rendimiento computacional del estimador LAV será competitivo con el del estimador WLS debido a la linealidad del problema de estimación para mediciones fasoriales.

2.4.2. Procesadores Bayesianos

Como se mencionó anteriormente, la aproximación Bayesiana en la estimación de estado tiene como objetivo construir la distribución de probabilidad a posteriori del estado, considerando toda la información disponible, incluyendo el conjunto de medidas recibidas. Este tipo de estimador se conoce como filtro recursivo [88], ya que procesa los datos recibidos secuencialmente en lugar de hacerlo en bloque, lo que evita la necesidad de almacenar todos los datos. El filtro recursivo consta de dos etapas básicas: la etapa de predicción (a priori) y la etapa de actualización (a posteriori).

En la etapa de predicción, se utiliza el modelo de movimiento para predecir el estado de la distribución de probabilidad a posteriori en el tiempo $t + 1$. Se debe tener en cuenta que el estado está sujeto a perturbaciones y se modela como ruido gaussiano. La predicción desplaza, deforma y expande la distribución de probabilidad a priori.

En la etapa de actualización, se utiliza la medida en el tiempo $t + 1$ para modificar la predicción de la distribución de probabilidad. Esta etapa incorpora la información de la medida y ajusta la distribución a posteriori.

En la literatura se han propuesto desarrollos significativos relacionados con la modelización dinámica y el establecimiento de un espacio de estados. Bajo esta perspectiva, es necesario establecer un modelo que capture el sistema y que pueda ser representado matemáticamente. Para ello, se debe modelar el sistema de planta y establecer un modelo que relacione las observaciones o mediciones. En el contexto de un sistema eléctrico de potencia, se utilizan ecuaciones no lineales para modelar su dinámica [89]. A continuación, se presentan las ecuaciones que definen el espacio de estados:

$$x_t = f(x_{t-1}, w_{t-1}) \quad (2.9)$$

$$z_t = h(x_t, v_t) \quad (2.10)$$

En el contexto del espacio de estados, la ecuación (2.9) describe la evolución del estado x_{t-1} al estado x_t en el intervalo de tiempo entre $t-1$ y t . Esta evolución tiene en cuenta el error w_{t-1} , que representa la incertidumbre en la actualización del estado. La ecuación (2.9) implica una distribución de probabilidad a priori $p(x_t|x_{t-1})$, que refleja la información disponible sobre el estado en el tiempo $t-1$ para predecir el estado en el tiempo t .

Por otro lado, la ecuación (2.10) representa el modelo de observación, que relaciona la medida z_t con el valor actual del estado x_t . En esta ecuación, el término v_t representa el error estocástico asociado a la medida, que refleja la incertidumbre en la medición. La ecuación (2.10) define una distribución de probabilidad de la medida $p(z_t|x_t)$, que describe la probabilidad de obtener la medida z_t dado el estado x_t .

Para establecer un espacio de estados, es necesario desarrollar un modelo que permita representar la evolución del vector de estado en función de las señales de control impuestas. En el trabajo de Blood et al. [90], se propone un modelo de planta basado en la ecuación de balance de nodos.

$$f_i(x, \Gamma) = V_i e^{j\delta_i} \sum V_k Y_{ik} e^{j(\delta_j + \phi_{ik})} - (P_i + jQ_i) = 0 \quad (2.11)$$

Donde $\Gamma = [P_1 P_2 \dots P_N \quad Q_1 Q_2 \dots Q_N]^T$, representa el vector de inyección de potencia activa y reactiva de dimensión $2N$

Derivando la ecuación de balance $f_i(x, \Gamma)$, respecto a x, Γ , tenemos:

$$\frac{\delta f_i(x, \Gamma)}{\delta x} dx + \frac{\delta f_i(x, \Gamma)}{\delta \Gamma} d\Gamma = 0 \quad (2.12)$$

$$H = \frac{\delta f_i(x, \Gamma)}{\delta x} \quad (2.13)$$

$$I = \frac{\delta f_i(x, \Gamma)}{\delta \Gamma} \quad (2.14)$$

Siendo \mathbf{H} la matriz Jacobiana del vector de estado, I representa la matriz identidad y despejando dx de (2.12), se tiene:

$$dx = -H^{-1} d\Gamma \quad (2.15)$$

El diferencial dx representa la variación infinitesimal entre dos puntos de operación estática (x_1, Γ_1) y (x_2, Γ_2) , y que satisface la ecuación (2.12). Linealizando el diferencial en una relación incremental y considerando un error de proceso w_l , la ecuación (2.16) se puede expresar de la siguiente manera:

$$\Delta x = (x_1 - x_2) = -H^{-1} (\Gamma_1 - \Gamma_2) + w_l \quad (2.16)$$

Considerando que los dos puntos de operación son estáticos dentro de un intervalo de tiempo t y $t+T_s$, permite que el modelo quede como:

$$x [t + T_s] = x[t] - H^{-1} u[t] + w_l \quad (2.17)$$

Siendo $u[t] = \Delta \Gamma[t] = \Gamma [t + T_s] - \Gamma [t]$ el vector de entrada que representa el cambio de operación del sistema en el tiempo y que tiene dependencia de la demanda. En la ecuación (2.17) se describe el modelo que asocia el nuevo punto de operación y el anterior, en donde la entrada $u[t]$ representa la variación de potencia cuando el sistema cambia su punto de operación determinado por la demanda.

2.4.3. Filtro de Kalman (EKF)

El Filtro de Kalman Extendido (EKF) es un algoritmo recursivo y óptimo utilizado para estimar el estado de un sistema que evoluciona en el tiempo. Este filtro es considerado óptimo debido a que minimiza un criterio específico y utiliza toda la información disponible del estado anterior para realizar el filtrado. Además, es recursivo, lo que significa que no requiere almacenar datos previos, lo que facilita su implementación en sistemas de procesamiento en tiempo real, [91].

El objetivo principal del EKF es estimar los estados de manera óptima, minimizando el índice del error cuadrático medio. A diferencia del WLS, el EKF aprovecha la información del estado del sistema para mejorar la precisión de la estimación. Esto se logra mediante la utilización de un modelo dinámico que describe la evolución del estado en el tiempo y la propagación de la incertidumbre asociada. A medida que se reciben nuevas medidas, el EKF actualiza la estimación del estado utilizando tanto el modelo dinámico como las mediciones disponibles.

En la literatura, se han realizado diversos trabajos que destacan las ventajas del Filtro de Kalman Extendido en comparación con otros métodos, como el WLS. Estos estudios resaltan el uso de la información del estado del sistema como un factor clave para mejorar la precisión de la estimación, [92, 93].

Bajo estas consideraciones el Filtro de Kalman es implementado, considerando 2 etapas:

1. Etapa de Predicción en $t+1$, donde se determina la predicción de estado, y la matriz de Covarianza,

$$\bar{x}[t + T_s] = \hat{x}[t] - H^{-1}u[t] \quad (2.18)$$

$$\bar{P}[t + T_s] = \hat{P}[t] + Q \quad (2.19)$$

2. Etapa de Corrección de la estimación, considerando la medición en $t+1$, se calcula el vector de Ganancia, se actualiza la estimación y Covarianza.

$$K[t + T_s] = \bar{P}[t + T_s] H^T(x) \{H(x)\bar{P}[t + T_s] H^T(x) + R\}^{-1} \quad (2.20)$$

$$\hat{x}[t + T_s] = \bar{x}[t + T_s] + K[t + T_s] \{z[t + T_s] - h(\bar{x}[t + T_s])\} \quad (2.21)$$

$$\hat{P}[t + T_s] = \bar{P}[t + T_s] - K[t + T_s] H(x)\bar{P}[t + T_s] \quad (2.22)$$

donde:

K Ganancia de Kalman

\hat{x} es el estimado en $t + T_s$ (actualización)

H construcción de la matriz Jacobiana

R matriz inversa de la matriz de covarianza de las mediciones w

z mediciones u observaciones del sistema

Este proceso permite estimar el vector de estados, considerando un estado anterior. En la Figura 2.1 se detalla el procedimiento del algoritmo.

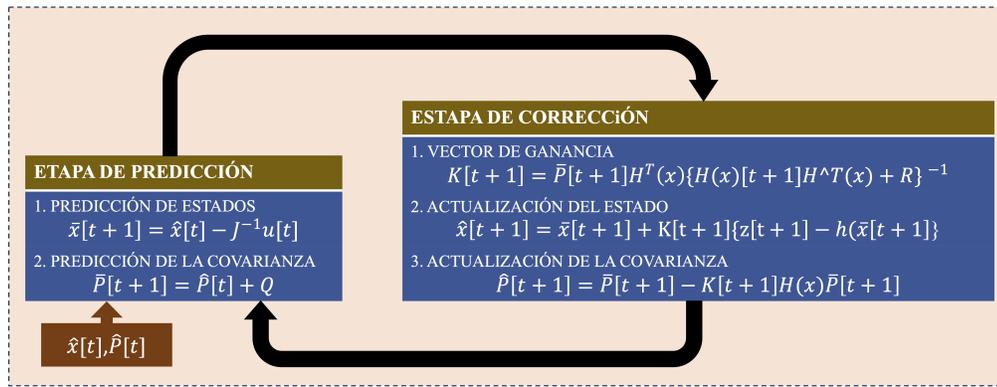


Figura 2.1: Algoritmo Filtro de Kalman

Dado que el EKF aproxima las funciones no lineales del modelo mediante una serie de Taylor de primer orden a los términos óptimos, asumiendo que esta aproximación es suficiente para describir la dinámica del sistema, sin embargo, esta aproximación puede disminuir el desempeño del filtro e incluso la convergencia ya que una característica fundamental del EKF es que siempre aproxima $p(x_t/z_t)$ a una Gaussiana, lo cual puede representar un inconveniente si su *f.d.p.* no es Gaussiana. Otro problema presente es el requerimiento de matrices Jacobianas, su cálculo no es trivial siendo factible cometer errores y que son difíciles de detectar. Es importante mencionar que las ecuaciones que modelan el espacio de estado deben ser derivables caso contrario este filtro no podría ser aplicado. En este contexto la literatura presenta ciertas mejoras tales como el filtro *Unscented de Kalman (UKF)*, que a continuación se describe.

2.4.4. Filtro Unscented de Kalman (UKF)

La transformación "unscented" (UT) es una técnica desarrollada por Julier y Uhlman [94], que aborda las limitaciones de la linealización en el filtro de Kalman extendido (EKF). En lugar de linealizar la función no lineal, el enfoque UT selecciona un conjunto de puntos sigma de manera determinística alrededor de la media estimada. Estos puntos sigma se eligen de tal manera que capturan la media y la covarianza de manera más precisa que la aproximación lineal.

Una vez seleccionados los puntos sigma, se propagan a través de la función no lineal. Esto implica evaluar la función no lineal en cada punto sigma para obtener un conjunto de puntos transformados. Estos puntos transformados capturan la no linealidad del sistema y proporcionan una mejor aproximación de la distribución del estado. Este enfoque se ilustra en la Figura 2.2.

Luego, se calcula la media y la covarianza utilizando los puntos transformados. Estas estadísticas actualizadas representan una estimación más precisa del estado y su incertidumbre, ya que tienen en cuenta la no linealidad del sistema de una manera más directa y explícita.

La transformación UT proporciona una alternativa más robusta y precisa a la linealización

utilizada en el EKF. Al evitar la necesidad de calcular matrices Jacobianas y asumir una distribución gaussiana, el filtro UT puede manejar mejor las no linealidades y proporcionar estimaciones más confiables en situaciones donde la aproximación lineal del EKF puede ser insuficiente, [95].

En resumen, la transformación "unscented" (UT) es una técnica utilizada en el filtro de Kalman extendido para abordar las limitaciones de la linealización. Proporciona una manera más directa y explícita de capturar la no linealidad en la estimación del estado, mejorando así la precisión y robustez del filtro.

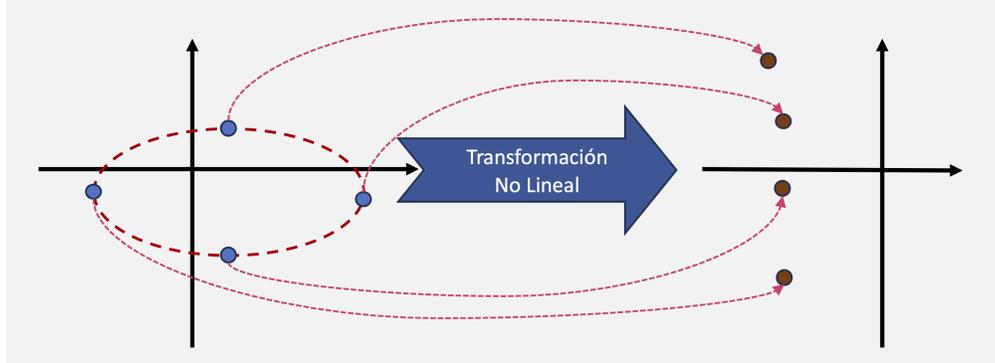


Figura 2.2: Transformación Unscented, conjunto de puntos distribuidos sobre un error elipsoidal son transformados a un nuevo espacio

Al igual que el EKF se asume un espacio de estados, con un modelo de la forma:

$$x_t = f(x_{t-1}, w_{t-1}) \quad (2.23)$$

$$z_t = h(x_t, v_t) \quad (2.24)$$

El filtro UKF combina la teoría clásica del filtro de Kalman con la transformación "Unscented". Una de las principales ventajas del UKF sobre el EKF es que en el modelo dinámico presentado en las ecuaciones (2.23) y (2.24) no se realiza la linealización. Esta transformación evita la pérdida de información de órdenes superiores y, por lo tanto, mejora las propiedades del estimador.

Además, en el proceso numérico del UKF no es necesario determinar ni calcular las matrices Jacobianas o Hessianas, lo que reduce los costos computacionales y ofrece ventajas de procesamiento en comparación con el EKF. Sin embargo, se requieren múltiples evaluaciones de un número limitado de σ -points. En otras palabras, para requisitos computacionales similares, el UKF proporciona una mayor precisión que el EKF al considerar términos de orden superior en las ecuaciones del modelo no lineal.

Para aplicar el UKF, se deben seguir tres pasos, que se describen a continuación:

1. Se debe realizar el cálculo de los σ -points, consiste en crear un conjunto $2n + 1$ puntos que captura la media m a partir del vector de estado x_t en $t - 1$ y la correspondiente matriz de covarianza P_{t-1} , [96].

$$X_0 = m \quad (2.25)$$

$$X_i = m + (\sqrt{(n + \lambda)P})_i \quad i = 1 \dots n \quad (2.26)$$

$$X_{n+i} = m - (\sqrt{(n + \lambda)P})_i \quad i = 1 \dots n \quad (2.27)$$

Siendo λ parámetro definido como:

$$\lambda = \alpha^2(n + \kappa) - n \quad (2.28)$$

Los valores de κ y α se presentan en [97]. En tanto que para la inicialización de estimación (es decir, cuando $t = 0$), el vector de estado inicial y la matriz de covarianza inicial tienen que ser definidas de acuerdo a un conocimiento a priori del sistema.

2. Luego corresponde desarrollar la etapa de predicción, para lo que se evalúa uno a uno el conjunto de σ - *points*, en el modelo de planta $\widehat{\mathbf{X}}_t$ que corresponde a una matriz de $nx(2n + 1)$ que permite la propagación de los σ - *points*. En un proceso posterior se calcula la predicción del estado y de su matriz de covarianza.

$$\widehat{X}_t^i = f(X_{t-1}^i) \quad i = 0 \dots 2n \quad (2.29)$$

$$\tilde{\mathbf{x}}_t = \sum_0^{2n} W_i^m \widehat{\mathbf{X}}_t^i \quad (2.30)$$

$$\widetilde{\mathbf{P}}_t = \sum_0^{2n} W_i^m \left[(\widehat{\mathbf{X}}_t^i - \tilde{\mathbf{x}}_t) (\widehat{\mathbf{X}}_t^i - \tilde{\mathbf{x}}_t)^T \right] + \mathbf{Q}_{t-1} \quad (2.31)$$

Donde W_i^m son los pesos asignados a los σ - *points*, [73].

3. Para completar el proceso de estimación se aplica la etapa de corrección en la que se calcula los σ - *points* de la etapa de predicción $\tilde{\mathbf{x}}_t \approx X_t$ y se propagan en la ecuación de medida.

$$\hat{\mathbf{z}}_t = h(\mathbf{X}_t) \quad (2.32)$$

Donde la media de los puntos propagados resulta de:

$$\boldsymbol{\mu}_t = \sum_0^{2n} W_i^m \hat{\mathbf{z}}_t \quad (2.33)$$

En tanto la matriz de covarianza de las medidas y la correlación entre el estado y las medidas resultan de las siguientes ecuaciones:

$$\mathbf{S}_t = \sum_0^{2n} W_i^m \left[(\hat{\mathbf{z}}_t - \boldsymbol{\mu}_t) (\hat{\mathbf{z}}_t - \boldsymbol{\mu}_t)^T \right] + \mathbf{R}_t \quad (2.34)$$

$$\mathbf{C}_t = \sum_0^{2n} W_i^m \left[(\mathbf{X}_t^i - \tilde{\mathbf{x}}_t) (\hat{\mathbf{z}}_t - \boldsymbol{\mu}_t)^T \right] \quad (2.35)$$

Por último calculamos la ganancia de Kalman, el valor estimado y la covarianza en t .

$$K_t = C_t S_t^{-1} \quad (2.36)$$

$$x_t = \tilde{x}_t + K_t (z_t - \mu_t) \quad (2.37)$$

$$P_t = \tilde{P}_t + K_t S_t K_t^T \quad (2.38)$$

En términos generales, el filtro UKF es más fácil de implementar que el filtro EKF en sistemas no lineales debido a que no requiere el cálculo de derivadas o matrices Jacobianas. Además, el UKF proporciona aproximaciones precisas hasta el tercer orden en el caso de distribuciones Gaussianas y al menos hasta el segundo orden en el caso de distribuciones no Gaussianas.

Una de las principales ventajas del UKF es que ofrece una estimación más precisa en comparación con el EKF, ya que no linealiza las ecuaciones del modelo. Esto significa que el UKF es capaz de capturar de manera más precisa la no linealidad del sistema y, por lo tanto, puede proporcionar una estimación más precisa del estado y su incertidumbre.

En resumen, la transformación "unscented" (UT) es una técnica utilizada en el filtro de Kalman extendido para abordar las limitaciones de la linealización. Proporciona una manera más directa y explícita de capturar la no linealidad en la estimación del estado, mejorando así la precisión y robustez del filtro.

2.5. Criterios para partición de sistemas

La identificación de sub-gráficos coherentes en las redes es una tarea importante en diversas aplicaciones. En el caso de los grandes sistemas de energía, se subdividen en áreas y zonas con el objetivo de facilitar la planificación y el control. En el contexto de la estimación distribuida, es crucial que la partición del sistema en subsistemas cumpla con criterios como la observabilidad y redundancia.

Es importante tener en cuenta que no todas las particiones son adecuadas para todas las aplicaciones, ya que pueden tener diferentes objetivos o atributos. Sin embargo, estudios recientes han demostrado que la partición de la red puede ser beneficiosa para la integración de fuentes de energía renovable, como se ha mencionado en [98]. Es necesario tener en cuenta que la partición óptima para la integración de fuentes renovables puede no ser la misma que la requerida para la estimación distribuida.

En el trabajo de [99], se propone un criterio de descomposición basado en el número de enlaces existentes entre los subsistemas. Utilizando una variante del algoritmo K-means, se busca minimizar la cantidad de enlaces entre los subsistemas. El objetivo de este enfoque es reducir el impacto de las barras vecinas y limitar la cantidad de información que se transmite entre las áreas.

Otros criterios se plantean en [100, 101], lo que consiste en realizar una partición de áreas en función de las empresas que conforman el sistema eléctrico. Los puntos de enlace entre los

subsistemas estarán definidos por los sistemas de transmisión que los conectan. En este caso, el tiempo de comunicación entre las áreas puede influir en el proceso de estimación, tanto a nivel local como global del sistema.

Para determinar la eficiencia del método de partición nodal. En resumen, la partición de un sistema eléctrico en subsistemas coherentes es una tarea relevante y se pueden utilizar diferentes criterios para lograr una partición adecuada. La elección de la partición óptima dependerá de los objetivos específicos de la aplicación y de los atributos deseados, como la reducción de enlaces o el tiempo de comunicación.

P

2.6. Estimación de Estado Distribuida DSE

Tradicionalmente, el estimador de estado centralizado en los sistemas eléctricos de potencia se basa en un modelo simplificado del sistema y un conjunto de mediciones no simultáneas. Sin embargo, este enfoque centralizado presenta sesgos y errores debido a asimetrías, desequilibrios y errores de instrumentación. Además, el enfoque centralizado requiere una comunicación intensiva y un procesamiento de datos considerable, lo cual puede afectar la confiabilidad del estimador de estado.

Una alternativa que ha surgido en el estado del arte de los estimadores de estado es el enfoque distribuido, que busca mejorar la eficiencia del control y la gestión en grandes sistemas eléctricos de potencia. En los últimos años, los avances en el procesamiento de datos y los cálculos distribuidos, así como en los sistemas informáticos y los transductores para la captura de información (sistemas de medición), han facilitado la implementación de sistemas de procesamiento distribuido en los sistemas de control. Esto se debe tanto a los avances en la modelación matemática como a la drástica reducción de los costos de los ordenadores y el desarrollo de entornos de comunicación avanzados [102].

Cuando se aborda el problema del estimador de estado en grandes sistemas de energía de manera distribuida, resulta crucial la forma en que se descompone el sistema en subsistemas que no se superpongan. Diferentes esquemas de descomposición afectan la precisión y la eficiencia de los resultados de la estimación, ya que las mediciones de cada subsistema tienen un impacto no solo en las barras vecinas, sino también en las barras internas de subsistemas adyacentes. Además, la cantidad de datos transmitidos y los problemas de seguridad aumentan considerablemente si existen más enlaces entre subsistemas.

Hoy en día, el enfoque de estimación distribuida se aplica a la estimación de estado en grandes sistemas eléctricos. Este enfoque implica la descomposición del sistema en subsistemas más pequeños, y se desarrolla teniendo en cuenta las siguientes consideraciones:

1. Observabilidad: La descomposición del sistema en subsistemas debe asegurar que cada subsistema sea completamente observable, es decir, que todas las variables de estado relevantes puedan ser estimadas con base en las mediciones disponibles en ese subsistema. Esto implica que cada subsistema debe tener un conjunto suficiente de mediciones

que permitan estimar sus variables de estado de forma independiente.

2. Reducción de la comunicación: Al descomponer el sistema en subsistemas, se busca minimizar la cantidad de información que necesita ser transmitida entre los subsistemas. Esto se logra limitando las interconexiones entre los subsistemas a través de líneas de enlace y reduciendo la necesidad de comunicación entre ellos. Una reducción eficiente de la comunicación contribuye a la eficiencia y la escalabilidad del estimador de estado distribuido.
3. Coherencia de los subsistemas: Los subsistemas resultantes de la descomposición deben ser coherentes en términos de su conexión física y funcional en el sistema eléctrico. Esto significa que los subsistemas deben representar áreas o zonas lógicas del sistema eléctrico, de modo que reflejen la estructura y las características del sistema en su conjunto.
4. Precisión y eficiencia: La descomposición del sistema debe ser capaz de proporcionar estimaciones precisas de las variables de estado, al tiempo que optimiza la eficiencia computacional y el rendimiento del estimador distribuido. Esto implica encontrar un equilibrio entre la granularidad de la descomposición (tamaño de los subsistemas) y la calidad de las estimaciones resultantes.

La estimación distribuida de estado se basa en la descomposición de grandes sistemas eléctricos en subsistemas coherentes y observables, con el objetivo de reducir la comunicación y mejorar la eficiencia del estimador, sin comprometer la precisión de las estimaciones resultantes. Esta descomposición de grandes sistemas eléctricos en subsistemas se desarrolla en base a las siguientes consideraciones:

1. Dividir el sistema de potencia en subsistemas definiendo sus límites.
2. Obtener las medidas de cada subsistema
3. Realizar una estimación local, detección e identificación de bad data
4. Solucionar el problema de coordinación, chequear condiciones de frontera.
5. Resolver el ángulo de referencia del sistema
6. Ensamblaje del sistema mediante un coordinador.

De acuerdo a [20], las ventajas de una estimación distribuida permiten que:

- i. Se reduzca el esfuerzo de los recursos computacionales,
- ii. Se minimize el volumen de información a ser transferida entre el centro de control y los subsistemas operando en paralelo y con una coordinación central,
- iii. Se reduzca el tiempo de estimación para todo el sistema, y
- iv. Se mejore la eficiencia de algoritmos para la detección de bad data pues se reduce el problema de dimensión.

Como desventaja se tiene:

- i. Se necesita un proceso iterativo para el problema de coordinación
- ii. La presencia de bad data en las fronteras debido a la imprecisión sincronizadas de mediciones que reduce la eficiencia de los métodos.

En [43], se presenta un enfoque de estimación distribuida que aborda la evaluación del ángulo de referencia entre los subsistemas en los que se descompone el sistema para la estimación. En este enfoque, se distinguen dos tipos de estimación distribuida:

1. Estimación distribuida basada en el consenso: En este enfoque, los subsistemas estiman sus variables de estado de forma independiente y luego intercambian información entre ellos para llegar a un consenso sobre el ángulo de referencia global del sistema. Cada subsistema actualiza su estimación local del ángulo de referencia en función de la información recibida de los subsistemas vecinos, utilizando técnicas de consenso como el algoritmo de consenso promedio. De esta manera, se logra una estimación distribuida del ángulo de referencia global sin necesidad de una referencia centralizada.
2. Estimación distribuida basada en la optimización: En este enfoque, los subsistemas estiman sus variables de estado de forma independiente y luego se realiza una optimización para determinar el ángulo de referencia global que minimiza una función objetivo global. Cada subsistema formula su propia función objetivo local, que tiene en cuenta las mediciones locales y la información recibida de los subsistemas vecinos. Luego, se lleva a cabo una optimización distribuida en la que los subsistemas intercambian información y ajustan su estimación local del ángulo de referencia para alcanzar un óptimo global.

Estos dos enfoques de estimación distribuida tienen como objetivo principal lograr una estimación precisa y consistente del ángulo de referencia global del sistema, teniendo en cuenta las mediciones y la información disponible en los subsistemas individuales. La elección entre estos enfoques depende de las características y las restricciones del sistema específico, así como de los objetivos de la estimación distribuida.

En los trabajos [6, 10, 72, 82], se propone un criterio de estimación distribuida multi-área que se basa en la descomposición del sistema eléctrico en áreas geográficas. Cada área cuenta con su propio centro de control y define una barra de referencia local para realizar la estimación de estado de forma independiente.

El enfoque se basa en establecer líneas de enlace entre las áreas para permitir la transferencia de información entre ellas y coordinar una estimación global de todo el sistema. En el proceso de estimación para cada área individual, los agentes locales utilizan las mediciones disponibles en su zona correspondiente.

Sin embargo, se enfrenta al desafío de que las mediciones en las fronteras entre áreas son una función de las variables de estado tanto de la zona local como de las zonas vecinas. Para resolver este problema, se propone que las áreas se superpongan, lo que implica que algunas barras o nodos pueden pertenecer a más de un área. Esto permite que las mediciones en las fronteras se utilicen de manera más efectiva en el proceso de estimación, ya que se consideran las variables de estado de las áreas adyacentes.

De esta manera, el enfoque de estimación distribuida multi-área propuesto permite una mejor coordinación y aprovechamiento de la información entre las diferentes áreas del sistema eléctrico. Esto ayuda a mejorar la precisión y la eficiencia de la estimación de estado global, al considerar tanto las mediciones locales como las mediciones compartidas en las fronteras de las áreas superpuestas.

Es importante tener en cuenta que no todas las mediciones en un sistema eléctrico se obtienen simultáneamente, lo que significa que las mediciones tomadas en una exploración pueden tener un sesgo temporal de varios segundos. Esto implica que la estimación de estado no es en tiempo real, sino que proporciona una representación cuasi-estática de las condiciones en la red eléctrica.

Para lograr una estimación en tiempo real verdaderamente dinámica, se requerirían sistemas de telemetría más sofisticados, como mediciones con etiquetado de tiempo obtenidas a través del Sistema de Posicionamiento Global (GPS) [103], por ejemplo. Estas tecnologías avanzadas permitirían un monitoreo más preciso y sincronizado de las variables eléctricas en el sistema.

En la Figura 2.3, se ilustran los elementos que deben definirse en una estimación distribuida, considerando su ubicación geográfica y su relación con los subsistemas vecinos. Esta representación visual puede ayudar a comprender la estructura y la conectividad de los subsistemas en el contexto de la estimación de estado distribuida. Aunque debido a las limitaciones temporales en la adquisición de mediciones, la utilización de tecnologías avanzadas y enfoques distribuidos puede mejorar la precisión y eficiencia de la estimación, permitiendo un monitoreo más dinámico de la red eléctrica.

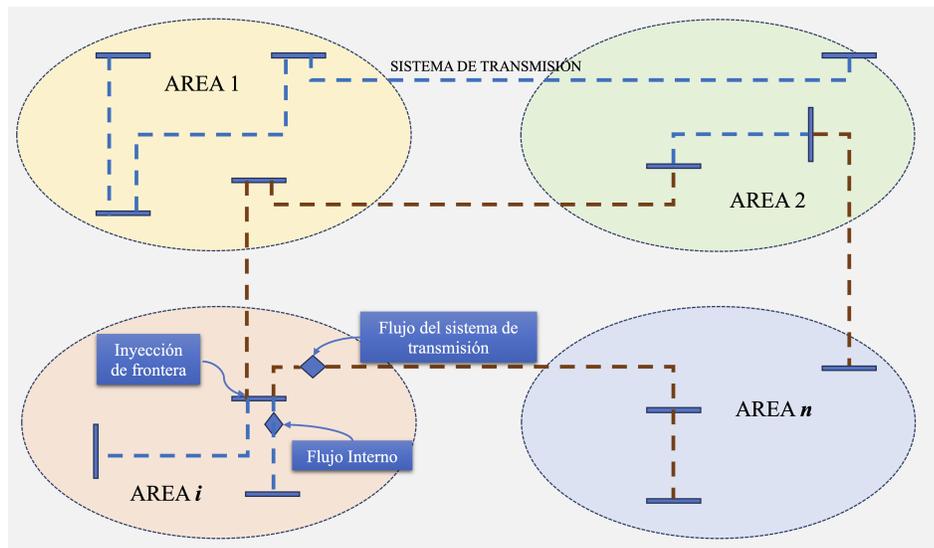


Figura 2.3: Partición de un sistema en n subsistemas, extraído de [1]

La estimación de estado distribuida en un Sistema Eléctrico de Potencia (EPS) implica dividir el sistema en subsistemas más pequeños y realizar una estimación conjunta de un vector de estados. En lugar de depender de un único estimador centralizado, se distribuye la tarea de estimación en subsistemas más pequeños, lo que permite aprovechar el poder de

cálculo y la información local de cada uno de ellos.

En un enfoque distribuido, cada subsistema tiene acceso a datos parciales o información local que puede utilizar para realizar su propia estimación. Estas estimaciones individuales se combinan luego con la información de frontera entre subsistemas para obtener una estimación global más completa.

La estimación distribuida es especialmente útil en escenarios donde los datos están dispersos, son sensibles o están distribuidos geográficamente, y no es factible o deseable centralizar todos los datos en un solo lugar debido a limitaciones de comunicación, privacidad o seguridad. La estimación distribuida en un EPS asume que el sistema es observable a través de un sistema de medición y puede llevarse a cabo una reducción de Kron para simplificar y agilizar los cálculos.

En resumen, la estimación distribuida es un enfoque que permite realizar estimaciones conjuntas utilizando múltiples fuentes de datos o agentes distribuidos, aprovechando la información local y los recursos computacionales de un sistema de control. Este enfoque tiene aplicaciones significativas en la estimación de estado de un Sistema Eléctrico de Potencia, ya que puede mejorar la eficiencia, la precisión y la resiliencia del proceso de estimación

2.7. Impacto de Recursos Renovables en la estimación de estado

La generación de energía renovable, como la solar y la eólica, introduce incertidumbre en las variables de estado de la red eléctrica. Estas fuentes de energía son conocidas como Variable Energy Resources (VER). La variabilidad de la generación solar y eólica, así como su integración en la red eléctrica, requieren una mejor supervisión en tiempo real debido a sus características de incertidumbre e intermitencia [104].

La incertidumbre se debe a que las entradas de radiación solar y velocidad del viento son estocásticas, lo que implica la necesidad de modelos de predicción. En los últimos años, se ha mejorado la precisión de estos modelos de predicción, pero aún sigue siendo un campo de investigación activo. Por otro lado, los VERs son intermitentes, lo que significa que no se pueden despachar de manera controlada como los generadores convencionales. Esto introduce nuevas dinámicas en la red eléctrica que deben ser consideradas.

En un estudio empírico presentado en [105], se muestra que los recursos eólicos tienen una fuerte influencia en las variables del sistema eléctrico. Las observaciones realizadas a partir de datos de sincro-fasores y la salida de energía eólica revelan una correlación entre la velocidad del viento y las fluctuaciones en los ángulos de fase de la tensión. La integración de fuentes de generación renovable, como la solar y la eólica, introduce incertidumbre e intermitencia en las variables de estado de la red eléctrica. La mejora en la supervisión en tiempo real y la precisión de los modelos de predicción son aspectos clave para garantizar una gestión eficiente y segura de la red eléctrica en presencia de estos Variable Energy Resources.

2.8. Error en los procesos de estimación

El método para detectar medidas erróneas en un estimador de estado se basa en la comparación de las mediciones obtenidas en tiempo real con las predicciones generadas por el modelo del sistema eléctrico de potencia (*EPS*). Si la diferencia entre la medición real y la predicción del modelo es demasiado grande, se considera que la medición es errónea y se elimina de la estimación de estado.

Este método se conoce como detección de datos errados (*BDD*¹), y se utiliza comúnmente en la estimación de estado para detectar y eliminar medidas erróneas en la red eléctrica. El *BDD* se realiza en dos etapas: la detección de datos maliciosos y la eliminación de datos maliciosos.

La **primera etapa**, compara las mediciones reales con las predicciones del modelo, si la diferencia entre la medición real y la predicción del modelo es mayor que un umbral predefinido, se considera que la medición es errónea. El umbral se establece para garantizar que las mediciones que tienen una diferencia menor que el umbral se consideren mediciones precisas y no se eliminen de la estimación.

En la **segunda etapa**, las mediciones identificadas como erróneas se eliminan de la estimación de estado. Esto se logra utilizando técnicas de corrección de errores, como la técnica de eliminación de mediciones o la técnica de sustitución de mediciones.

Bajo estos escenarios se han desarrollado técnicas que permiten la eliminación de mediciones erróneas, para posterior a este proceso aplicar nuevamente el modelo de estimación de estado utilizando las mediciones restantes. De igual manera se aplica una técnica de sustitución de mediciones, se reemplazan las mediciones identificadas como erróneas por otras mediciones disponibles o se utiliza una técnica de interpolación para estimar las mediciones faltantes (**pseudo-mediciones**).

La capacidad para identificar medidas erróneas en el proceso de estimación de estado es crucial para un centro de control de un sistema de energía, el origen puede provenir de diversas fuentes, como instrumentos de medición defectuosos, errores en la transmisión de datos o fallas en los transductores.

Las mediciones erróneas tienen consecuencias significativas en la confiabilidad y seguridad del *EPS*, ya que pueden derivar estimaciones incorrectas de las variables de estado del sistema, lo que a su vez puede afectar el proceso en la toma de decisiones ya sea para el despacho de carga o acciones de control. Por lo tanto, detectar e identificar las mediciones erróneas es fundamental para mantener la integridad y la operación óptima del sistema eléctrico de potencia.

Para la identificación de medidas erróneas utilizadas en el estimador, se han desarrollado diversas técnicas y algoritmos, los cuales incluyen:

1. Análisis estadístico: mediante métodos estadísticos se identifican valores atípicos o mediciones que se desvíen significativamente del comportamiento esperado. Esto implica

¹BDD:Bad Data Detection

el análisis de la distribución de las mediciones, calcular parámetros estadísticos como la media y la desviación estándar; y, marcar las mediciones que se encuentren fuera de un rango determinado.

2. Análisis de residuos: Los residuos representan las diferencias entre los valores medidos y estimados, son examinados para la detección de posibles errores. Residuos grandes o cambios repentinos en los patrones de residuos pueden indicar la presencia de datos incorrectos. Entre las técnicas estadísticas más utilizadas está la prueba de chi-cuadrado, que evalúa los residuos para identificar posibles valores atípicos.
3. Métodos basados en la observabilidad: Estos métodos aprovechan el concepto de observabilidad en los sistemas de energía para identificar datos incorrectos. Al analizar la sensibilidad de las mediciones a las variables de estado, se pueden identificar como posibles valores atípicos aquellas mediciones que tienen poco impacto en la solución de estimación de estado.
4. Enfoques de aprendizaje automático: Los algoritmos de aprendizaje, tales como las redes neuronales, pueden ser entrenados para reconocer patrones en datos históricos e identificar mediciones que no se ajusten a esos patrones. Estos modelos pueden aprender de instancias pasadas de datos incorrectos y hacer predicciones sobre la probabilidad de que nuevas mediciones sean erróneas.

La elección específica del método depende de las características del sistema de energía y los datos disponibles. También se puede utilizar una combinación de diferentes técnicas para mejorar la precisión de la detección de datos incorrectos.

Al identificar y abordar rápidamente los datos incorrectos en las mediciones de estimación de estado, los centros de despacho de carga pueden mejorar la confiabilidad y eficiencia de la operación del sistema de energía, lo que lleva a una mayor estabilidad y reducción de riesgos.

En conclusión, existen varios métodos para identificar medidas erróneas en la estimación de estado distribuido en **EPS**, incluyendo el método de detección de observabilidad, el método de detección de patrones y los métodos basados en técnicas de aprendizaje automático. Estos métodos son importantes para mejorar la precisión de la estimación de estado y garantizar la seguridad y confiabilidad de la red eléctrica [106, 107].

Un proceso general para detectar medidas erróneas en un estimador de estado:

1. Estimación de estado inicial: Se realiza una estimación de estado inicial utilizando todas las mediciones disponibles.
2. Cálculo de residuos: Se calcula el residuo para cada medición utilizando la diferencia entre la medición real y la medición estimada con el estado estimado del sistema. El residuo se define como la magnitud de la discrepancia y puede ser calculado utilizando diferentes normas, como la norma euclidiana.
3. Establecimiento de umbrales: Se establecen umbrales de tolerancia para los residuos. Estos umbrales se definen de acuerdo a criterios de calidad y confiabilidad del sistema, y pueden variar según el tipo de medición (voltaje, corriente, potencia, etc.).

4. Comparación de residuos: Se compara cada residuo con los umbrales establecidos. Si un residuo excede el umbral, se considera que la correspondiente medición es errónea y se procede a su identificación.
5. Identificación de medidas erróneas: Una vez identificadas las medidas erróneas, se pueden aplicar diferentes técnicas para su eliminación. Algunos enfoques comunes incluyen la eliminación directa de las mediciones erróneas, la sustitución de las mediciones por valores promedio o la realización de una estimación ponderada utilizando técnicas de estimación robusta.

Se debe destacar que este proceso de detección y eliminación de medidas erróneas se puede repetir en forma iterativa para mejorar la precisión de la estimación de estado.

2.9. Comentarios Finales

Explorar el estado del arte en relación a la propuesta presentada requiere tener un conocimiento previo sobre los estimadores de estado. En la literatura especializada, este tema ha sido ampliamente investigado, y se pueden encontrar contribuciones significativas y diversas aplicaciones.

En nuestra propuesta, nos hemos centrado en el concepto del estimador de estado y su enfoque en la distribución. Hemos explorado los elementos fundamentales y los procesos que deben considerarse al dividir un sistema, lo cual permite acoplar la partición nodal en este proceso. La efectividad de este método se ha evaluado a través de simulaciones realizadas en modelos de prueba, como el sistema de IEEE 14 barras y el sistema de IEEE 118 barras.

Como contribución adicional al estado del arte del tema abordado, se ha completado un artículo académico que analiza la eficiencia del filtro de Kalman Iterativo (IKF) aplicado al método de partición propuesto. Además, se planea explorar en el futuro la eficacia del Uncensored Kalman Filter, para lo cual se deberá desarrollar el modelo matemático correspondiente.

Capítulo 3

Validación del modelo

La importancia de contar con un estimador de estado robusto es fundamental para la operación de un sistema eléctrico, ya que la información proporcionada por la estimación permite al operador tomar decisiones adecuadas que garantizan la seguridad y confiabilidad del sistema. Sin embargo, la presencia de medidas erróneas compromete la robustez del estimador y los valores estimados.

En este trabajo, se propone una técnica dirigida a la detección e identificación de medidas erróneas, considerando las características de redundancia del sistema, la precisión de los datos estimados y la carga computacional. Dado que se emplea una estimación de estado distribuida, se ha desarrollado una nueva técnica como parte del proceso de partición, basada en el criterio de redundancia nodal.

El objetivo de este trabajo es detectar e identificar medidas erróneas en un sistema eléctrico. Para lograrlo, se ha desarrollado una nueva técnica que tiene en cuenta la redundancia del sistema, la precisión de los datos estimados y la carga computacional durante su implementación. Esta propuesta se enmarca en la aplicación de una estimación de estado distribuida, y se ha diseñado una nueva técnica que se integra en el proceso de partición, utilizando como criterio la redundancia nodal.

3.1. Planteamiento

- Se puede separar un sistema de gran escala en “áreas/zonas observables”, logrando que en cada uno de ellos la redundancia sea la máxima posible
- Se puede mejorar el resultado de estimación maximizando el número de medidas en un subsistema
- Es factible mejorar el proceso de detección e identificación de medidas erróneas mejorando la redundancia de los subsistemas.
- Es posible reducir la carga computacional y su tiempo de procesamiento al reducir el tamaño de los sistemas.

3.2. Procesamiento

La metodología propuesta combina la detección e identificación de medidas erróneas con la implementación de una nueva técnica de partición para la estimación distribuida, utilizando como criterio la redundancia nodal. Para ello, se crearon bases de datos que representan el conjunto de mediciones del sistema, utilizando curvas de demanda típicas de un sistema eléctrico. A través de un flujo de potencia, se obtuvieron los datos reales del sistema, como tensiones de barra, ángulos de referencia, potencias y flujos.

Estos datos de prueba se condicionaron y se evaluaron en los sistemas de prueba IEEE 14 bus y IEEE 118 bus [108]. La metodología se desarrolló siguiendo los siguientes lineamientos dentro del proceso de estimación:

1. **Caracterización de barras nodales (BN):** se hace un análisis del sistema de medición para extraer que barras tienen asociado el mayor número de medidas mediante el criterio de redundancia nodal (RN), esto permite identificar las barras del sistema conformadas con el mayor número de medidas, Barras Nodales (BN), así como al mismo tiempo generar un proceso de jerarquización entre ellas.
2. **Partición del sistema-construcción de subsistemas:** Identificadas las barras nodales se dan los siguientes pasos para la construcción de los subsistemas:
 - (a) Los subsistemas se generan localizando las barras nodales, la construcción inicia por sus barras nodales y sus barras adyacentes que se encuentren conectadas físicamente mediante su sistema de transmisión, en este proceso iterativo de construcción se evalúa la redundancia de cada subsistema, Figura 3.1.
 - (b) Una segunda etapa consiste que a través de un proceso iterativo permite crecer a los subsistemas, agregando barras adyacentes conectadas. Este proceso finaliza cuando las barras y líneas se encuentren localizadas en algún subsistema. De igual manera, en cada iteración de construcción se evalúa la redundancia de cada subsistema, Figura 3.2.

Para evitar el solapamiento de la(s) barra(s), mediante la evaluación de la redundancia en los subsistemas se define a que subsistema debe pertenecer la barra solapada aplicando la siguiente relación.

$$R_i > R_j \quad B_n \in \text{Área } i \quad (3.1)$$

Donde:

R_i redundancia Área i

B_n Barra n -ésima.

Para finalizar el proceso de construcción de los subsistemas, se determina su vector de estado $(V, \theta)^k$, barras internas, barras vecinas, líneas de enlace y sus mediciones.

3. **Estimación:** para determinar el conjunto de variables de estado de los subsistemas se aplicará un método de estimación de estado jerárquico [6, 10, 54, 109], y el cual comprende dos etapas principales:

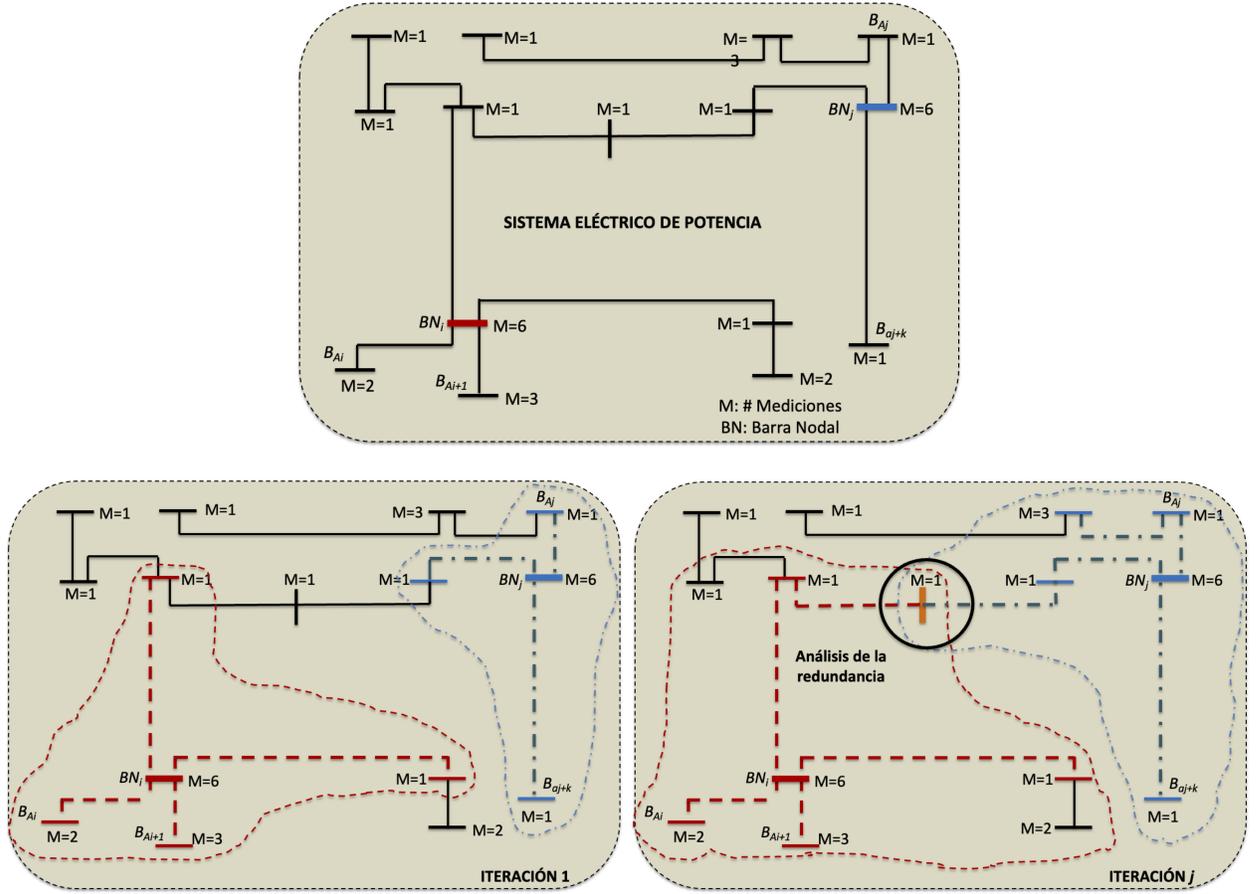


Figura 3.1: Proceso de construcción de los Susistemas

- (a) Las soluciones locales que se obtienen en el ámbito de la zona, ignorando totalmente o en parte de la información y las restricciones derivadas de las áreas vecinas.
 - (b) Las soluciones locales son coordinadas por una unidad central de proceso con el fin de hacer frente a las interacciones entre las zonas ignoradas durante la primera etapa. Cada paso se analiza por separado a continuación.
4. **Primer Paso Soluciones Locales:** Durante la primera etapa, cada área k se resolverá independientemente, considerando el modelo estático y el modelo dinámico. El conjunto de mediciones se representa mediante la ecuación de medida:

$$y_k = h(y_k) + e_k \quad (3.2)$$

Donde los ángulos de fase en y se refieren a la referencia de fase local de la zona k . Los componentes de y_k y z_k son determinadas por el nivel de solapamiento adoptado de la siguiente manera:

$$y_k = \begin{bmatrix} y_{ik} \\ y_{bk} \end{bmatrix} ; \quad z_k = z_{ik} \quad (3.3)$$

En este esquema, cada variable de estado se calcula una sola vez, dentro de su respectiva área, teniendo en cuenta que los flujos de potencia de líneas de enlace y las inyecciones de fronteras no se pueden utilizar de forma individual en este esquema, ya que implican

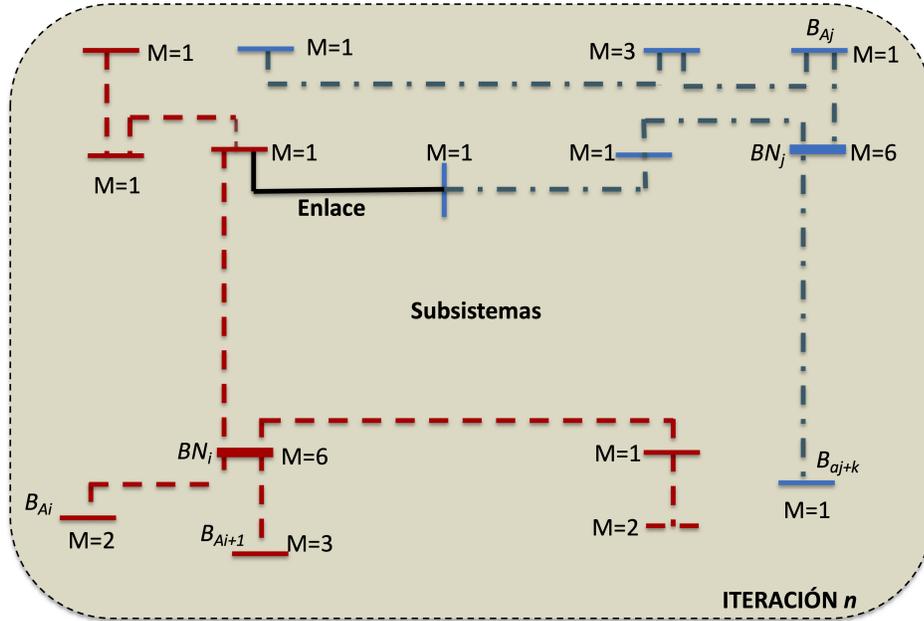


Figura 3.2: Determinación de los Subsistema en la Iteración n

variables de estado externos. Por lo tanto, z_k puede incluir además, ciertas pseudo-mediciones las cuales se obtienen mediante el procesamiento previo de mediciones de frontera inicial. Por ejemplo, si la inyección en una barra de frontera dada, junto con toda la potencia fluye dejando las líneas de enlace incidentes, se miden, luego una pseudo-medición que representa la inyección de potencia neta que se puede agregar a z_k . En resumen, el ámbito geográfico de cada problema local determinará el conjunto de variables incluidas en el vector de estado y, en consecuencia, el conjunto de medidas que pueden ser manejados a nivel local.

5. **Segundo Paso coordinación centralizada:** El ámbito geográfico de este paso se determina por el nivel de solapamiento adoptado y la cantidad de información que cada área está dispuesta a intercambiar con sus vecinos. El vector de estado en esta etapa comprende al menos de las variables fronterizas correspondientes a las áreas A, junto con el vector de referencia de fase \mathbf{u} , es decir:

$$x_k = \begin{bmatrix} x_b \\ u \end{bmatrix} \quad \text{con} \quad x_b = [x_{b1} \dots x_{bk} \dots x_{bA}]^T \quad (3.4)$$

Mientras el vector de medidas en este paso incluye dos componentes:

$$z_c = \begin{bmatrix} \hat{y}_b \\ z_b \end{bmatrix} \quad (3.5)$$

donde \hat{y}_b es la estimación local de x_b , con ángulo de fase referenciado a las barras locales, y representa el conjunto de medidas de borde no usadas en el paso anterior. Tenga en cuenta que para cada componente del vector de estado x_b dos o más estimaciones pueden estar disponibles en y_b , lo que aumenta la redundancia para estimar el vector \mathbf{u} .

$$z_b = [z_{b1} \dots z_{bk} \dots z_{bA}]^T \quad (3.6)$$

6. **Detección e identificación:** este modulo captura las variables estimadas locales para la detección e identificación de medidas erróneas se realizarán los siguientes pasos:
- (a) Luego del proceso de estimación de cada subsistema, se determinará que test de hipótesis se aproxima a su *f.d.p* calculada, de tal manera que permita verificar la presencia de medidas erróneas de forma óptima.
 - (b) Si del paso anterior se detecta la presencia de medidas erróneas, para la identificación y eliminación se aplicará el residual normalizado *LNR* [33].

$$r_i^N = \frac{|r_i|}{\sigma_i \sqrt{S_{ii}}} \quad (3.7)$$

3.3. Agrupación Nodal

En el ámbito de la agrupación en sistemas eléctricos de potencia (EPS), el proceso de partición desempeña un papel crucial y tiene diversas aplicaciones relevantes. Este proceso implica dividir el sistema en grupos o subconjuntos con el objetivo de lograr el aislamiento controlado de componentes, facilitar la computación paralela para el análisis de sistemas eléctricos, reducir la equivalencia dinámica y apoyar la planificación.

Según la estructura del grafo que representa el sistema, el proceso de partición se clasifica en dos categorías principales: grafo denso y grafo disperso, según se indica en [110]. En aplicaciones como la agrupación basada en coherencia, se requiere un grafo completo en el cual cada nodo está conectado con todos los demás nodos, lo que se conoce como un grafo denso.

Por otro lado, los grafos dispersos se utilizan en aplicaciones de aislamiento controlado. En este contexto, el objetivo es identificar conjuntos coherentes de generadores y definir límites o fronteras que minimicen la pérdida de carga en cada isla resultante. Un requisito fundamental en estas aplicaciones es que los subgrafos formados deben ser contiguos, es decir, cada nodo dentro de una isla debe estar conectado directa o indirectamente con todos los demás nodos.

Estas técnicas de partición tienen aplicaciones prácticas, como la simulación transitoria paralela de sistemas eléctricos y los cálculos paralelos utilizados en el análisis general de sistemas eléctricos. Sin embargo, uno de los desafíos importantes en dichas aplicaciones es el costo de comunicación, que puede limitar el rendimiento y la eficiencia del sistema distribuido.

La agrupación es una técnica utilizada para asociar elementos que comparten características similares. En la literatura, se han desarrollado diversas técnicas de agrupación, como K-means, distancia eléctrica, agrupación espectral y algoritmos de agrupación jerárquica, entre otros [53, 55, 101, 111].

En este trabajo, se propone un método de agrupación nodal basado en las medidas asociadas a las barras de un sistema eléctrico. El objetivo es construir regiones o áreas en el sistema donde las medidas estén distribuidas de manera homogénea, maximizando así la redundancia en cada región.

El principio del agrupamiento nodal consiste en asignar las medidas a una barra específica. Para esto, se distinguen dos tipos de medidas: las medidas de barra (MB) y las medidas de línea (ML). En la Figura 3.3 se muestra la disposición física de las medidas en un sistema eléctrico de potencia, considerando un diagrama unifilar.

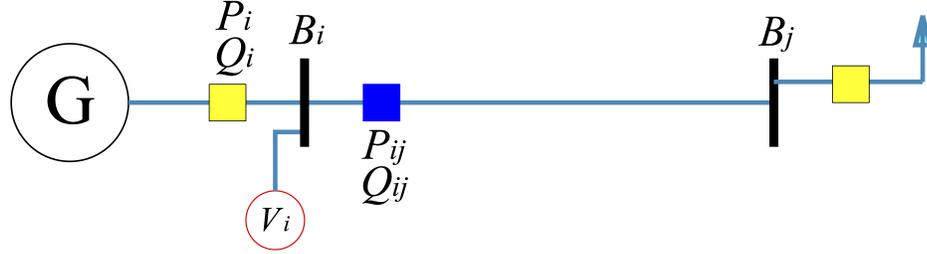


Figura 3.3: Diagrama Unifilar: Disposición física de las mediciones

En las mediciones M_B , se subdividen en dos tipos los que se conectan directamente a la barra del sistema que corresponden las mediciones de tensión (M_V) y las medidas de inyección de potencia P (M_P) y potencia Q (M_Q) que están conectadas entre un generador y barra o una carga y una barra. Así para la barra i -ésima se tiene:

$$M_{B_i} = \begin{cases} M_{V_i} \\ M_{P_i} \\ M_{Q_i} \end{cases} \quad (3.8)$$

Las medidas M_L , son las medidas de flujo de potencia entre un nodo i y nodo j , y la pertenencia de la medida se determinará con la barra más cercana, bajo la siguiente consideración:

$$M_L = \begin{cases} M_{P_{ij}} \in B_i \\ M_{Q_{ij}} \in B_i \end{cases} \quad (3.9)$$

El total de mediciones que se asocian a la barra i se determinan como:

$$M_i = M_{B_i} + M_{L_i} \quad (3.10)$$

En base a lo expuesto el concepto de agrupación nodal establece como métrica de control la redundancia (R), que se calcula como la relación entre las medidas (M) y el número de variables de estado del sistema eléctrico (N).

$$R = \frac{M}{N - 1} \quad (3.11)$$

En cada iteración del proceso de partición se deberá computar la redundancia y compararla entre los subsistemas.

3.4. Método Nodal de Partición

En la aplicación de la estimación distribuida del estado (DSE), el sistema eléctrico inicial se divide en grupos, subsistemas o subáreas. En cada nivel de partición, se calcula una estima-

ción local utilizando las medidas disponibles en cada clúster. Luego, se evalúa la estimación global del sistema eléctrico, lo cual requiere el intercambio de información de medidas vecinas entre los subsistemas, ya que se realiza una corrección en las fronteras.

A continuación, se presentan algunos conceptos clave necesarios para comprender la propuesta desarrollada.

3.4.1. Conceptos preliminares

1. **Estimación de Estado:** El proceso de estimación de estado para un sistema AC, se basa en un modelo matemático compuesto de funciones no lineales, las cuales permiten relacionar el conjunto de medidas con las variables de estado del sistema:

$$z = h(x) + e \quad (3.12)$$

donde:

\mathbf{x} : vector de estado a ser estimado de tamaño $2N$

\mathbf{z} : conjunto de mediciones del sistema de tamaño M ($M \geq 2N$ concepto de observabilidad).

\mathbf{h} : funciones no líneas que relacionan las mediciones y las variables de estado (Ec. de potencia y flujos de potencia).

\mathbf{e} : error presente en las mediciones.

En los modelos convencionales de estimación de estado, el vector de estado se define por el fasor de tensión $[V, \theta^0]$, y el conjunto de mediciones determinado por niveles de tensión, inyecciones de potencia activa y reactiva, flujos de potencia activa y reactiva. En tanto las ecuaciones no lineales que relacionan las variables del modelo son:

$$P_i = \sum_{j=1}^N V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (3.13)$$

$$Q_i = \sum_{j=1}^N V_i V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (3.14)$$

$$P_{ij} = V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) - G_{ij} V_i^2 \quad (3.15)$$

$$Q_{ij} = V_i V_j (G_{ij} \sin \theta_{ij} - \cos \theta_{ij}) - V_i^2 (B_{ij} - b_{ij}) \quad (3.16)$$

La matriz Jacobiana $[H]$ de las medidas según [24] del sistema eléctrico, está estructurado en bloque para las variables de estado $[V, \theta^0]$ como se determina en la siguiente ecuación:

$$H = \begin{bmatrix} \frac{\delta V_1}{\delta V_1} \cdots & \frac{\delta V_1}{\delta V_N} & \frac{\delta V_1}{\delta \theta_1} \cdots & \frac{\delta V_1}{\delta \theta_n} \\ \frac{\delta V_m}{\delta V_1} \cdots & \frac{\delta V_m}{\delta V_N} & \frac{\delta V_m}{\delta \theta_1} \cdots & \frac{\delta V_m}{\delta \theta_n} \\ \frac{\delta P_1}{\delta V_1} \cdots & \frac{\delta P_1}{\delta V_N} & \frac{\delta P_1}{\delta \theta_1} \cdots & \frac{\delta P_1}{\delta \theta_n} \\ \frac{\delta P_m}{\delta V_1} \cdots & \frac{\delta P_m}{\delta V_N} & \frac{\delta P_m}{\delta \theta_1} \cdots & \frac{\delta P_m}{\delta \theta_n} \\ \frac{\delta P_{ij1}}{\delta V_1} \cdots & \frac{\delta P_{ij1}}{\delta V_N} & \frac{\delta P_{ij1}}{\delta \theta_1} \cdots & \frac{\delta P_{ij1}}{\delta \theta_n} \\ \frac{\delta P_{ijm}}{\delta V_1} \cdots & \frac{\delta P_{ijm}}{\delta V_N} & \frac{\delta P_{ijm}}{\delta \theta_1} \cdots & \frac{\delta P_{ijm}}{\delta \theta_n} \\ \frac{\delta Q_1}{\delta V_1} \cdots & \frac{\delta Q_1}{\delta V_N} & \frac{\delta Q_1}{\delta \theta_1} \cdots & \frac{\delta Q_1}{\delta \theta_n} \\ \frac{\delta Q_m}{\delta V_1} \cdots & \frac{\delta Q_m}{\delta V_N} & \frac{\delta Q_m}{\delta \theta_1} \cdots & \frac{\delta Q_m}{\delta \theta_n} \\ \frac{\delta Q_{ij1}}{\delta V_1} \cdots & \frac{\delta Q_{ij1}}{\delta V_N} & \frac{\delta Q_{ij1}}{\delta \theta_1} \cdots & \frac{\delta Q_{ij1}}{\delta \theta_n} \\ \frac{\delta Q_{ijm}}{\delta V_1} \cdots & \frac{\delta Q_{ijm}}{\delta V_N} & \frac{\delta Q_{ijm}}{\delta \theta_1} \cdots & \frac{\delta Q_{ijm}}{\delta \theta_n} \end{bmatrix} \quad (3.17)$$

En el modelo de estimador, el de mínimos cuadrados ponderados (WLS) minimiza la función objetivo que evalúa el error relacionado entre los valores estimados de las mediciones y los valores reales medidos, [10].

$$J = \sum_1^M \frac{(z_i - h_i(\hat{x}))^2}{\sigma_i^2} \quad (3.18)$$

Siendo:

$z_i - h_i(\hat{x})$: residual de la medida

\hat{x} : vector de estado estimado

σ_i^2 : varianza de la medición i

Dentro del desarrollo del modelo, se establece un proceso iterativo, que estima los valores de las variables de estado en la k iteraciones:

$$x_{k+1} = x_k + G_k^{-1} H_k^T W [z - h(x_k)] \quad k = 1, \dots, m \quad (3.19)$$

donde:

H_k : matriz Jacobiana evaluado en x_k

$G_k = H_k^T W H_k$ matriz de ganancia

W matriz de pesos

$x(k+1)$ estimación en la $k+1$ iteración.

Se llega a la convergencia del algoritmo cuando el valor del error residual de la función objetivo es menor a un umbral de tolerancia, que es una métrica de control que se debe establecer.

2. **Concepto de Agrupación:** En el proceso de partición del sistema, las áreas interconectadas pueden presentar diferentes configuraciones físicas:

(a) Áreas no solapadas, aquellas cuyas barras pertenecen a una de las áreas, el enlace de las áreas se da mediante su sistema de transmisión, ver Figura 3.4.

Figura 2: Áreas no solapadas

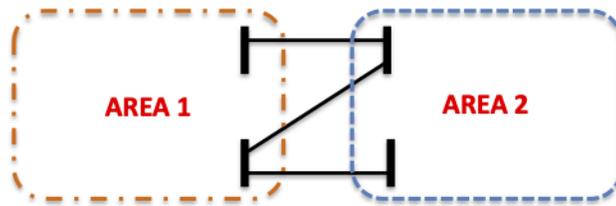


Figura 3.4: Áreas no solapadas

- (b) Barras solapadas, configuración en donde las barras se encuentran contenidas en varias áreas de la partición, ver Figura 3.5.

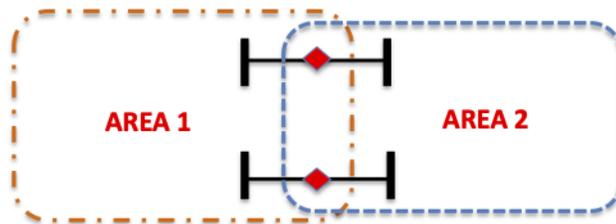


Figura 3.5: Barras solapadas

Figura 3: Barras solapadas

- (c) Enlaces solapados, la configuración considera que el enlace entre dos barras pertenece a varias áreas solapadas, ver Figura 3.6.

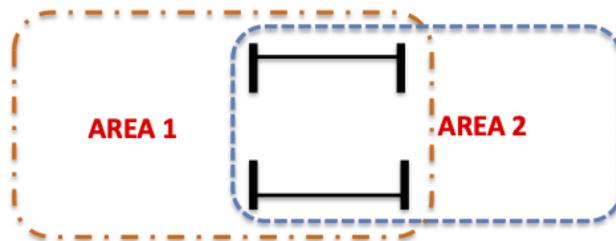


Figura 3.6: Enlaces solapados

3.4.2. Formulación del problema

En la formulación del problema se basa en un sistema eléctrico de potencia que debe ser dividido en áreas no solapadas, asegurando al mismo tiempo la conectividad física de los subsistemas a través de su sistema de transmisión. Es importante destacar que la propuesta no considera sistemas aislados, sino que busca la división del sistema en áreas interconectadas.

Un requisito fundamental es que se debe garantizar la observabilidad del sistema en su totalidad, así como de cada una de las áreas en las que se divide. En caso de que una determinada área no sea completamente observable, se requerirá el uso de pseudomediciones para restaurar la observabilidad. Esto implica la introducción de medidas ficticias que permitan estimar con precisión el estado del sistema en esa área específica.

$$(A_i \cap A_j) = \emptyset \quad (3.20)$$

Aplicando el concepto de agrupación nodal, se determina la cantidad de medidas asociadas a cada barra, lo cual da inicio a la partición del sistema, ver Figura 3.7

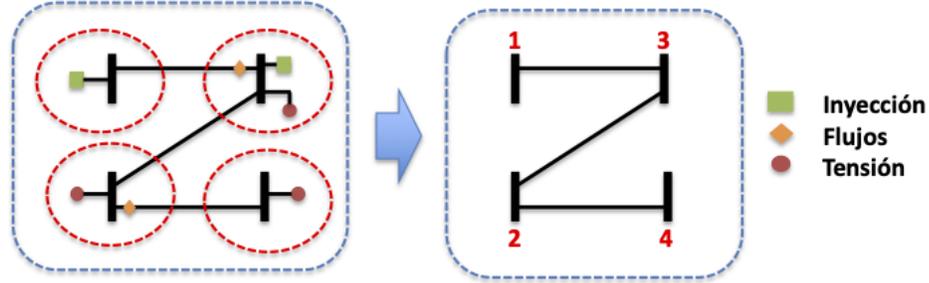


Figura 3.7: # de mediciones por Barra Nodal (BN)

(a) *Barras Nodales*: son aquellas barras que dentro del sistema concentran la mayor cantidad de medidas, bajo este concepto se consideran los siguientes escenarios:

- i. Tener varias barras nodales **BN** con igual cantidad de medidas, en este escenario el número de BN establece el número de áreas en las cuales se dividirá el sistema.

$$BN_k = \text{máx}(\#M) \quad (3.21)$$

- ii. Tener una única barra nodal, implica que el proceso de estimación corresponde a una estimación centralizada, para este caso se debe considerar a las siguientes barras que contengan un menor número de medidas, y se aplica el mismo criterio del literal anterior. Esta jerarquización identifica a las barras nodales que tienen igual número de medidas, las barras nodales únicas se incluyen en la partición mediante la redundancia nodal. ver Figura 3.8

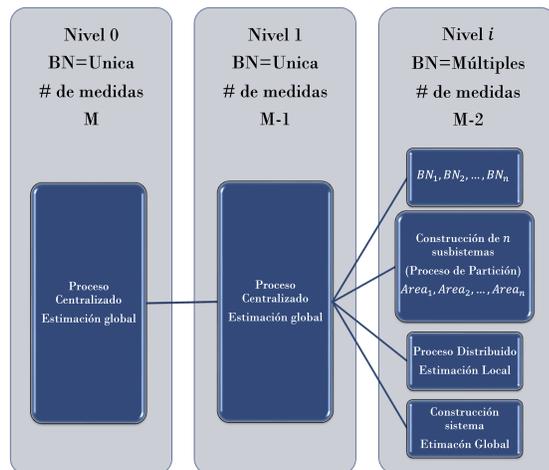


Figura 3.8: Nivel de Jerarquía de la Barra Nodal

- iii. Otro criterio que se puede aplicar como estrategia consiste en establecer una cantidad mínima de mediciones por barra, la división de subsistemas estará en función del número de barras que estén dentro de este umbral, en este caso las cantidades de medidas de cada barra nodal no necesariamente son iguales.

$$BN_k \geq \#M \quad (3.22)$$

- (b) *Enlace de nodos*: Determinadas las BN, se construyen las áreas, para lo cual se debe enlazar las barras adyacentes que se encuentren conectadas mediante el sistema de transmisión, los subsistemas en cada iteración crecen de manera radial, ver Figura 3.9. El sistema se extenderá a través de las líneas entre los nodos y en cada iteración el número de barras se incrementa.

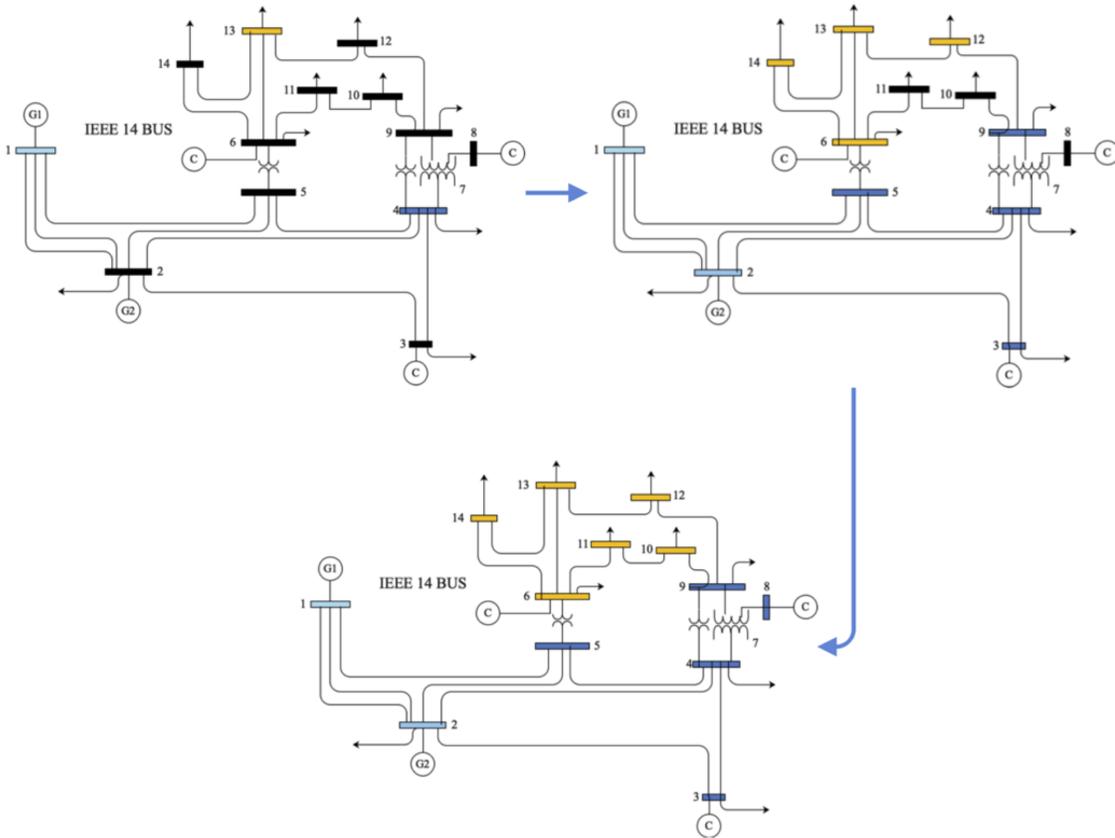


Figura 3.9: Proceso de construcción de los subsistemas

- (c) *Criterio de solapamiento*: En la metodología propuesta la expansión de las áreas puede producir solapamiento, lo cual provoca que una barra pueda estar localizada en más de dos áreas, esto debido a la conexión física que se da entre los elementos a través del sistema de transmisión Tx. Para determinar a que área corresponde una barra solapada, se aplica el criterio de minimización de error de redundancia, el cual posiciona la barra solapada en una de las áreas, ver Figura 3.10. Es necesario calcular las redundancias de las áreas solapadas y se verifica que caso minimiza el error de redundancia. Este proceso permite emplazar la barra solapada en una de las áreas, determinando los valores de redundancia entre áreas sea lo más homogéneo posible.

$$\begin{aligned} \text{mín } e_R &= R_{A_i} - R_{A_j} \\ \text{s.t. } e_R^k &\leq e_R^{K+1} \end{aligned} \quad (3.23)$$

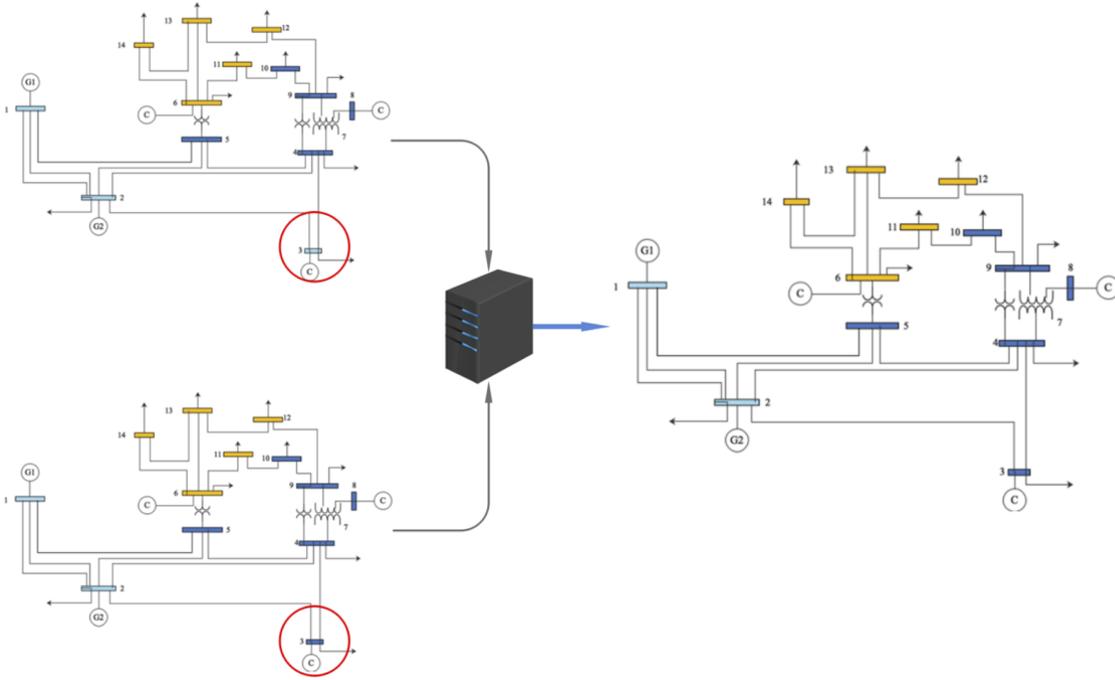


Figura 3.10: Proceso de solapamiento de barras en los Subistemas

El algoritmo de partición de un sistema eléctrico finaliza cuando no se encuentran más barras para asignar a las áreas en las que el sistema se dividió, ver Figura 3.11. Después de la etapa de partición, las condiciones que se deben cumplir para el proceso de estimación distribuida son:

$$BN_i \in A_i \quad (3.24)$$

$$B_i \in A_i \quad (3.25)$$

$$n_i = \sum_{A_i} n_k \quad (3.26)$$

En la Figura 3.12, se describe el proceso de estimación distribuida, en el cual cada subsistema aplica una estimación local, y en la construcción de la información, se hace una corrección de la estimación global en base a la información de sus fronteras, permitiendo obtener los valores estimados de sus variables de estado $[V, \theta^0]$ de todo el sistema.

En la reconstrucción del sistema eléctrico para calcular la estimación global se compara MSE de los valores estimados con una tolerancia de control, si el error está dentro de esta umbral, el proceso termina y se presentan los resultados.

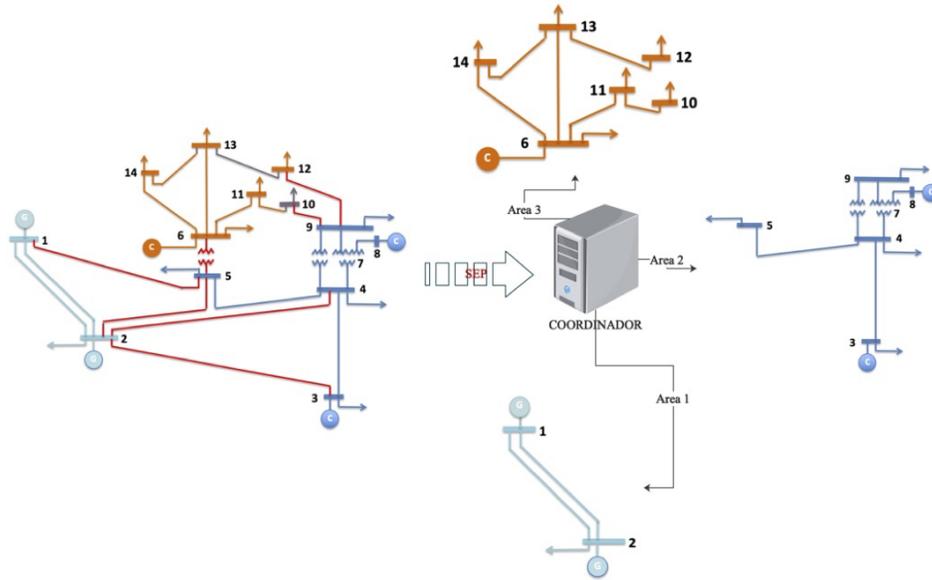


Figura 3.11: Generación de los Subsistemas Caso IEEE14 barras

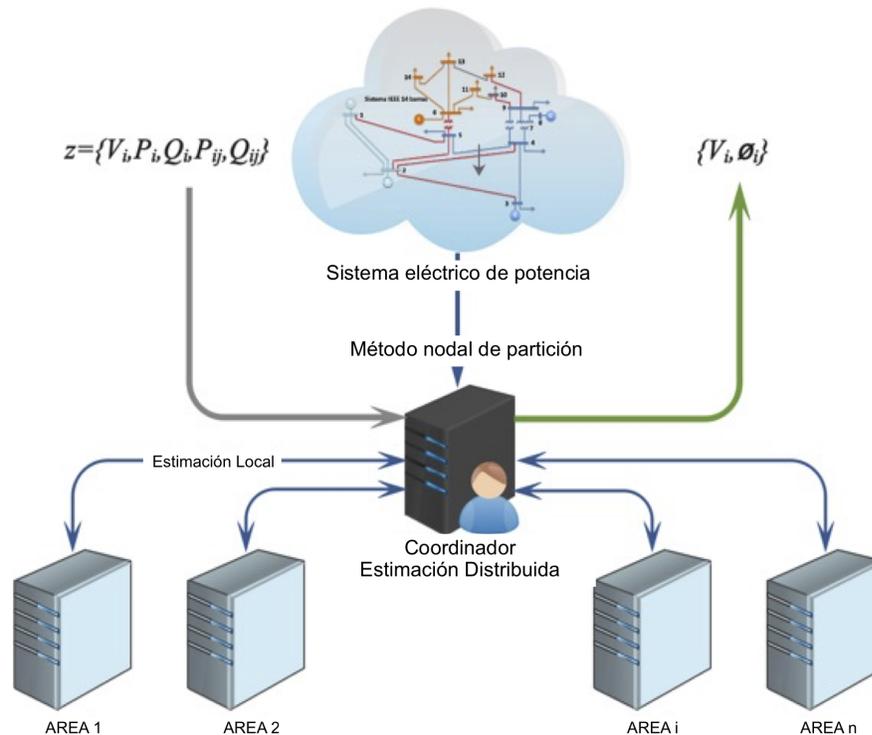


Figura 3.12: Proceso de un Estimador de Estado Distribuido DSE

3.5. Detección e Identificación de mediciones erróneas

Dentro del proceso de estimación de estado, es crucial contar con un sistema confiable para capturar información. En los sistemas eléctricos, los sistemas SCADA son ampliamente utilizados para este propósito. Sin embargo, con los avances tecnológicos, ahora es posible utilizar sistemas de medición basados en GPS, como los PMU, que ofrecen tiempos de pro-

cesamiento más rápidos.

Una vez que se ha ejecutado el estimador y se ha obtenido una estimación de las variables de estado, es importante identificar la presencia de mediciones erradas. Esto se puede lograr eliminando las mediciones erróneas o utilizando pseudomediciones basadas en información histórica o promedios. Una técnica comúnmente utilizada en la literatura es la prueba del chi cuadrado, que permite detectar mediciones anómalas o erradas desde una perspectiva estadística. Esta técnica se basa en los grados de libertad del sistema y ha sido abordada en trabajos de investigación previos [33, 86].

La prueba del chi cuadrado se utiliza para comparar las frecuencias observadas y esperadas en diferentes categorías y determinar si existe una discrepancia significativa. Si se detecta una discrepancia importante, se puede inferir la presencia de mediciones erradas en el sistema.

Es importante destacar que la prueba del chi cuadrado es una herramienta estadística que proporciona una visión objetiva de la presencia de mediciones erradas en función de su desviación con respecto al modelo teórico. Sin embargo, su aplicación precisa puede variar dependiendo del contexto y las características específicas del sistema eléctrico de potencia, [79]. El procedimiento general de la prueba del chi cuadrado en sistemas eléctricos de potencia implica los siguientes pasos:

1. Definir la hipótesis nula (H_0): Se establece una distribución de probabilidad teórica esperada para las mediciones, asumiendo que las mediciones se ajustan a esta distribución.
2. Calcular las frecuencias esperadas: Se determina la frecuencia esperada para cada categoría o intervalo de valores en función de la distribución teórica y el número de mediciones.

$$\chi_{\text{calc}}^2 = \sum \frac{(f_o - f_e)^2}{f_e} \quad (3.27)$$

3. Calcular la estadística de prueba chi cuadrado: Se calcula la estadística de prueba chi cuadrado, que representa la diferencia entre las frecuencias observadas y las frecuencias esperadas ponderadas por el número de mediciones.
4. Determinar el valor crítico: Se compara la estadística de prueba con un valor crítico de la distribución chi cuadrado, correspondiente al nivel de significancia deseado y los grados de libertad del sistema.
5. Tomar una decisión: Si la estadística de prueba es mayor que el valor crítico, se rechaza la hipótesis nula y se concluye que las mediciones no se ajustan a la distribución teórica esperada. En este caso, se puede inferir la presencia de mediciones erradas o anómalas. En cambio, si la estadística de prueba es menor que el valor crítico, se acepta la hipótesis nula y se considera que las mediciones se ajustan a la distribución teórica.

En un escenario ideal, donde el modelo del sistema es correcto y las mediciones son exactas, la estimación de los datos del vector de estado sería confiable y no requeriría un proceso adicional de detección y eliminación de errores.

Sin embargo, en la práctica, es común encontrar mediciones que contienen errores o anomalías significativas. Estos errores pueden ser causados por diversos factores, como problemas en los equipos de medición, interferencias externas o problemas de comunicación. Por lo tanto, es necesario implementar técnicas de detección y eliminación de errores para garantizar la integridad y confiabilidad de los datos estimados.

En otro contexto el error estimado $\hat{e}_j = (z_j - \hat{z}_j)$ es una variable aleatoria Gaussina con media cero, lo cual permite evaluar su varianza mediante la ecuación:

$$\hat{e}\hat{e}^T = (z - \hat{z})(z - \hat{z})^T \quad (3.28)$$

El resultado da una matriz cuadrada que corresponde el valor estimado de \mathbf{R} , que representa la matriz de la varianza de las mediciones:

$$\mathbf{e}\mathbf{e}^T = \begin{bmatrix} e_1 \\ e_2 \\ e_3 \\ e_4 \end{bmatrix} \begin{bmatrix} e_1 & e_2 & e_3 & e_4 \end{bmatrix} = \begin{bmatrix} e_1^2 & e_1e_2 & e_1e_j & e_1e_n \\ e_2e_1 & e_2^2 & e_2e_j & e_2e_n \\ e_i e_1 & e_i e_2 & e_j^2 & e_i e_n \\ e_n e_1 & e_n e_2 & e_n e_j & e_n^2 \end{bmatrix} \quad (3.29)$$

Calculando el valor esperado tenemos que:

$$E[\hat{e}^T] = [\mathbf{I} - \mathbf{H}\mathbf{G}^{-1}\mathbf{H}^T\mathbf{R}^{-1}] E[\mathbf{e}\mathbf{e}^T] [\mathbf{I} - \mathbf{R}^{-1}\mathbf{H}\mathbf{G}\mathbf{G}^{-1}\mathbf{H}^T] \quad (3.30)$$

Siendo $E[\mathbf{e}\mathbf{e}^T] = \mathbf{R}$, y multiplicando \mathbf{R} por $[\mathbf{I} - \mathbf{R}^{-1}\mathbf{H}\mathbf{G}^{-1}\mathbf{H}^T]$, la ecuación (3.30) se reduce a:

$$E[\hat{e}\hat{e}^T] = [\mathbf{I} - \mathbf{H}\mathbf{G}^{-1}\mathbf{H}^T\mathbf{R}^{-1}] [\mathbf{R} - \mathbf{H}\mathbf{G}^{-1}\mathbf{H}^T] \quad (3.31)$$

Lo cual reduce

$$E[\hat{e}\hat{e}^T] = [\mathbf{I} - \mathbf{H}\mathbf{G}\mathbf{G}^{-1}\mathbf{H}^T\mathbf{R}^{-1}] \mathbf{R} = \mathbf{R} - \mathbf{H}\mathbf{G}^{-1}\mathbf{H}^T \quad (3.32)$$

Tomado los elementos diagonales podemos escribir:

$$E[\hat{e}_j^2] = E[(z_j - \hat{z}_j)^2] = R'_{jj} \quad (3.33)$$

La Ecuación (3.33) es el valor de la varianza de \hat{e}_j de la medición j , en tanto matriz \mathbf{R} y \mathbf{R}' representan la matriz de covarianza, por lo tanto y debido a que el error verdadero se desconoce podemos aplicar el error estimado y reemplazar en la función objetivo:

$$\hat{f} = \sum_{j=1}^{N_m} w_j \hat{e}_j^2 = \sum_{j=1}^{N_m} \frac{\hat{e}_j^2}{\sigma_j^2} = \sum_{j=1}^{N_m} \frac{(z_j - \hat{z}_j)^2}{\sigma_j^2} \quad (3.34)$$

Siendo N_m el número de mediciones y $w_j = \frac{1}{\sigma_j^2}$, aplicando la matriz de covarianza \mathbf{R}' y ejecutando el desarrollo matemático presentado en [24], podemos escribir la expresión como:

$$E[\hat{f}] = \sum_{j=1}^{N_m} E\left[\frac{(z_j - \hat{z}_j)^2}{\sigma_j^2}\right] = N_m - N_s \quad (3.35)$$

Como el error estimado sigue una distribución gaussiana debido al comportamiento estadístico del modelo. Se compara el valor calculado del chi-cuadrado con un umbral predefinido de la función objetivo.

Si este valor es menor o igual al umbral establecido, se aceptan los datos estimados. Caso contrario, se considera la presencia de mediciones erróneas en el sistema.

$$\hat{f} < \chi_{k,\alpha}^2 \quad (3.36)$$

Si el valor calculado del chi-cuadrado supera el umbral establecido, se procede a identificar y eliminar el error en las mediciones calculando el error de cada medición en relación con la estimación actual del vector de estado del sistema.

Identificado el error en las mediciones, se realiza la corrección correspondiente para eliminar el impacto de las mediciones erróneas. A continuación, se vuelve a estimar el vector de estado del sistema utilizando las mediciones corregidas.

Este proceso de identificación y eliminación de errores se repite iterativamente hasta que el valor calculado del chi-cuadrado cumpla con el umbral establecido, lo que indica que las mediciones estimadas son aceptables y se ha logrado una estimación confiable del vector de estado del sistema.

$$\frac{z_j - \hat{z}_j}{\sqrt{R'_{jj}}} \quad (3.37)$$

3.6. Comentarios Finales

El diseño del método se fundamenta en la identificación de las barras con mayor cantidad de mediciones asociadas, lo cual establece el concepto nodal y sirve como punto de partida para el algoritmo de partición. La determinación y configuración de los subsistemas se logra mediante una expansión de barras que se interconectan a través de su sistema de transmisión en cada etapa del proceso.

Es importante resaltar que el método no genera conflictos de pertenencia entre barras vecinas, lo que simplifica el cálculo de la redundancia local en cada fase de la partición. La simplicidad del proceso asegura que esta métrica sea lo más homogénea posible. Sin embargo, es necesario tener en cuenta que esta condición de homogeneidad no se cumple necesariamente en la distribución de elementos y mediciones en cada subsistema, y esto se verifica mediante simulaciones.

Para validar los resultados de estimación se aplica la prueba del chi-cuadrado, para lo cual se considera los mismos subsistemas, es decir localmente se identifica y elimina el error, debiendo considerar que al eliminar una medición errónea implica que el sistema puede aunque no necesariamente cambiar su configuración si esta no es cambiada por otra medida dentro de su subsistema.

Capítulo 4

Análisis de los Resultados

4.1. Datos de Simulación

El algoritmo de estimación de estado, tanto en su versión centralizada como distribuida, ha sido implementado en un ordenador monoprocesador convencional. En este caso, se utilizó un ordenador con un procesador Intel i7 con una velocidad de reloj de 3.40 GHz y 4 GB de memoria RAM.

Para evaluar el rendimiento y la efectividad del método propuesto de partición mediante agrupación nodal, se realizó una prueba utilizando el sistema de la IEEE 14 barras. Este sistema es ampliamente utilizado en la literatura como un caso de estudio de tamaño moderado para probar algoritmos de estimación de estado.

Además, con el objetivo de analizar la confiabilidad del método y su aplicabilidad en escenarios con grandes volúmenes de información, se evaluó en el sistema de la IEEE 118 barras. Este sistema es más complejo y cuenta con un mayor número de barras, lo que representa un desafío adicional para el algoritmo de partición y estimación de estado.

Estos casos de estudio permitieron analizar y verificar el desempeño del método propuesto en diferentes configuraciones de sistemas eléctricos de potencia. Los resultados obtenidos en estas pruebas proporcionan una base para evaluar la viabilidad y la escalabilidad del algoritmo en sistemas más grandes y complejos.

En las simulaciones desarrolladas, se utilizó el algoritmo de estimación de estado en corriente alterna (AC) propuesto en el artículo [10]. Este algoritmo, basado en el enfoque heurístico observable, fue empleado para llevar a cabo la estimación de estado en los casos de prueba.

Para ejecutar la estimación de estado, se utilizó el paquete MATPOWER, una herramienta ampliamente utilizada en la comunidad de sistemas eléctricos de potencia. MATPOWER proporciona una implementación eficiente y robusta de algoritmos para el análisis y la simulación de sistemas eléctricos de potencia. Específicamente, se utilizó la plataforma MATLAB, que es compatible con el paquete MATPOWER, para llevar a cabo la estimación de estado

en las simulaciones.

La elección de esta combinación de algoritmo y herramientas fue con el objetivo de garantizar una estimación de estado precisa y confiable, utilizando métodos establecidos y bien validados en la literatura técnica. Al emplear el paquete MATPOWER en MATLAB, se aprovechó su amplia funcionalidad y facilidad de uso para realizar las simulaciones de manera eficiente y efectiva.

Para evaluar la eficiencia del método de partición propuesto, se lleva a cabo una estimación distribuida en la cual se consideran dos métricas importantes: el tiempo de procesamiento y el error cuadrático medio de los estados estimados (MSE).

El tiempo de procesamiento es una medida de la velocidad y eficiencia del algoritmo de estimación de estado. Se registra el tiempo que tarda el algoritmo en realizar la estimación distribuida para cada subsistema o subárea. Esto permite evaluar el rendimiento del método en términos de velocidad de procesamiento y su capacidad para manejar grandes volúmenes de datos.

El error cuadrático medio (MSE) es una medida de la precisión de la estimación de estado. Se calcula la diferencia cuadrática promedio entre los valores reales de los estados del sistema y los valores estimados por el algoritmo. Un MSE más bajo indica una estimación más precisa y cercana a los valores reales del sistema.

Al evaluar el método de partición mediante la estimación distribuida, se busca encontrar un equilibrio entre un tiempo de procesamiento razonable y un bajo MSE. Esto implica que el algoritmo debe ser capaz de realizar la estimación de estado de manera eficiente y rápida, sin comprometer la precisión de los resultados.

La evaluación de estas métricas permitirá determinar la eficiencia y la calidad de la estimación distribuida basada en el método de partición propuesto, brindando información valiosa para la toma de decisiones en la gestión de sistemas eléctricos de potencia.

$$MSE = \sum_1^n \frac{(x_i - \hat{x}_i)^2}{n} \quad (4.1)$$

Los errores de medición utilizados en las simulaciones se generan mediante la adición de un componente aleatorio al flujo de carga del sistema. En nuestros casos, asumimos que estos errores siguen una distribución gaussiana independiente e idénticamente distribuida (i.i.d.).

En la Tabla 4.1 se muestran los valores de la varianza de las medidas utilizadas en las simulaciones. La varianza es una medida de dispersión que indica cuánto varían los valores de las mediciones alrededor de su valor promedio. En el contexto de los errores de medición, una varianza más alta implica una mayor incertidumbre en las mediciones y, por lo tanto, puede tener un impacto en la precisión de la estimación de estado.

Es importante destacar que estos valores de varianza son específicos de las simulaciones realizadas y pueden variar según el sistema eléctrico de potencia y las características de las mediciones reales. Estos valores se utilizan como parámetros para generar los errores de

medición en las simulaciones y permiten evaluar el desempeño del algoritmo de estimación de estado en condiciones de incertidumbre.

Tabla 4.1: Varianza del sistema de medición

Type of Measure	Variable	Values
Voltage	σ_V^2	0.01
Power Injection $P_i + jQ_i$	σ_I^2	0.15
Power Injection $P_{ij} + jQ_{ij}$	σ_F^2	0.2

4.2. Validación del Modelo

En el proceso de simulación, es crucial validar el modelo de partición propuesto. Para ello, se realizaron simulaciones utilizando dos sistemas eléctricos de referencia ampliamente utilizados en la literatura: el sistema de la IEEE 14 barras y el sistema de la IEEE 118 barras.

En primer lugar, se simuló un flujo de potencia en el sistema de la IEEE 14 barras para determinar las mediciones del sistema. Estas mediciones se utilizaron como entrada para el algoritmo de partición y estimación de estado.

Posteriormente, se aplicó el modelo de partición propuesto en el sistema de la IEEE 14 barras, dividiendo el sistema en áreas o regiones no solapadas. Este proceso permitió obtener estimaciones locales de las variables de estado en cada área.

Además, se evaluó la aplicación del método de partición en un sistema más grande, como el sistema de la IEEE 118 barras. Se siguió el mismo procedimiento, simulando un flujo de potencia en el sistema para obtener las mediciones y luego aplicando el algoritmo de partición para obtener estimaciones locales de las variables de estado.

Estas simulaciones en sistemas de referencia permitieron verificar la validez y eficacia del modelo de partición propuesto en diferentes escalas, desde sistemas más pequeños hasta sistemas más grandes y complejos.

4.2.1. Simulaciones en el sistema IEEE 14 Barras

En el sistema de IEEE 14 barras, se evaluaron cuatro escenarios diferentes, los cuales se seleccionaron en función del número de mediciones disponibles. Cada escenario representa una distribución de mediciones en el sistema y se generó de manera aleatoria, asegurando la observabilidad del sistema en cada caso.

La Figura 4.1 muestra el sistema de IEEE 14 barras utilizado en estas simulaciones, [112], donde se representan las barras y las líneas que las conectan. Cada barra del sistema tiene asociadas diferentes mediciones, como voltajes, corrientes y flujo de potencia, que son utilizadas en el proceso de estimación de estado.

Los cuatro escenarios evaluados en este sistema se diferencian por el número de mediciones disponibles. Estos escenarios permiten analizar y comparar el desempeño del algoritmo de partición y estimación de estado en diferentes condiciones, desde escenarios con un número reducido de mediciones hasta escenarios con un mayor número de mediciones disponibles.

La distribución aleatoria de las mediciones en cada caso garantiza la observabilidad del sistema, lo que significa que se tienen suficientes mediciones para estimar de manera confiable el estado del sistema eléctrico. Esta distribución aleatoria permite simular diferentes situaciones en las que las mediciones pueden estar disponibles en diferentes barras y en diferentes cantidades, lo que refleja la variabilidad y complejidad de los sistemas eléctricos reales.

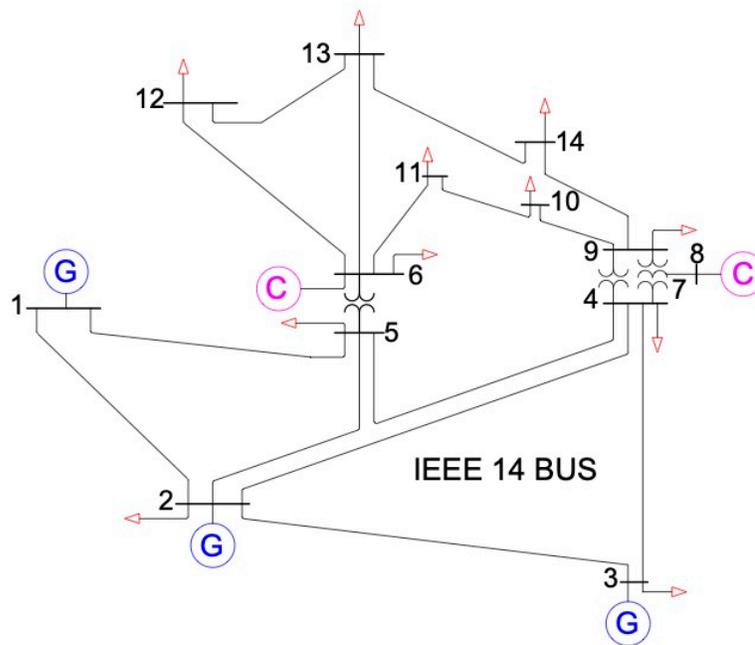


Figura 4.1: Caso Estudio Sistema Eléctrico IEEE 14, extraído de [111]

En las Tablas 4.2, 4.3, 4.4 y 4.5 se muestran los resultados del proceso de partición del sistema IEEE 14 barras para cada uno de los casos simulados. Estas tablas presentan la configuración de los subsistemas y su respectiva redundancia local.

El proceso de partición se basa en determinar cómo se agrupan las barras del sistema en subsistemas, de manera que se maximice la redundancia local en cada subsistema. La redundancia local se refiere a la presencia de mediciones en un subsistema que proporcionan información redundante sobre las variables de estado estimadas en ese subsistema.

En cada tabla, se presenta la configuración de los subsistemas y se indica qué barras pertenecen a cada subsistema. Además, se muestra la redundancia local de cada subsistema, que se calcula como la proporción de mediciones redundantes en relación con el número total de mediciones en el subsistema.

Estos resultados son importantes para evaluar el desempeño del algoritmo de partición

y determinar cómo se distribuyen las mediciones en los subsistemas. Una mayor redundancia local indica una distribución efectiva de las mediciones, lo cual es beneficioso para la estimación de estado.

Es importante destacar que los resultados presentados en estas tablas son específicos para el sistema IEEE 14 barras y los casos simulados. En otros sistemas o casos de estudio, los resultados pueden variar dependiendo de la configuración y características del sistema eléctrico.

Tabla 4.2: Resultados: partición del sistema eléctrico IEEE 14 barras con 82 mediciones

Área	BN	Barra	Redundancia	Medidas/Área
1	2	1 – 2 – 3	4.2	21
2	4	4 – 5 – 7 – 8 – 9 – 10 – 14	3	39
3	6	6 – 11 – 12 – 13	3.14	22

Tabla 4.3: Resultados: partición del sistema eléctrico IEEE 14 barras con 60 mediciones

Área	BN	Barra	Redundancia	Medidas/Área
1	2	1 – 2 – 3	2.6	13
2	4	4 – 5 – 7 – 8 – 9 – 10	2.36	26
3	6	6 – 11 – 12 – 13 – 14	2.33	21

Tabla 4.4: Resultados: partición del sistema eléctrico IEEE 14 barras con 55 mediciones

Área	BN	Barra	Redundancia	Medidas/Área
1	1	1 – 2 – 3 – 4 – 5 – 7 – 8 – 9	2.13	32
2	6	6 – 10 – 11 – 12 – 13 – 14	2.09	23

Tabla 4.5: Resultados: partición del sistema eléctrico IEEE 14 barras con 49 mediciones

Área	BN	Barra	Redundancia	Medidas/Área
1	1	1 – 2 – 3 – 4 – 5 – 7 – 8 – 9 – 10	1.8824	32
2	6	6 – 11 – 12 – 13 – 14	1.8889	17

Puedes encontrar las configuraciones físicas de cada caso considerado en la figura 4.2, la cual muestra visualmente la distribución de las barras y la forma en que se agrupan en subsistemas.

Es evidente que la configuración física varía cuando el número de medidas del sistema de medición cambia. Esta modificación implica que las barras nodales (BN) no son las mismas para cada caso simulado. Aunque el número de subsistemas en los que se divide el sistema sigue siendo el mismo, como se puede observar en los casos de 82 y 60 mediciones, hay una variación en la ubicación de las BN. Esto indica que la distribución de las medidas y la ubicación de los subsistemas pueden ser diferentes según la cantidad de mediciones disponibles.

En la Tabla 4.6 se muestran los resultados del error cuadrático medio (MSE) y el tiempo de procesamiento para cada una de las simulaciones realizadas. El análisis de estos resultados

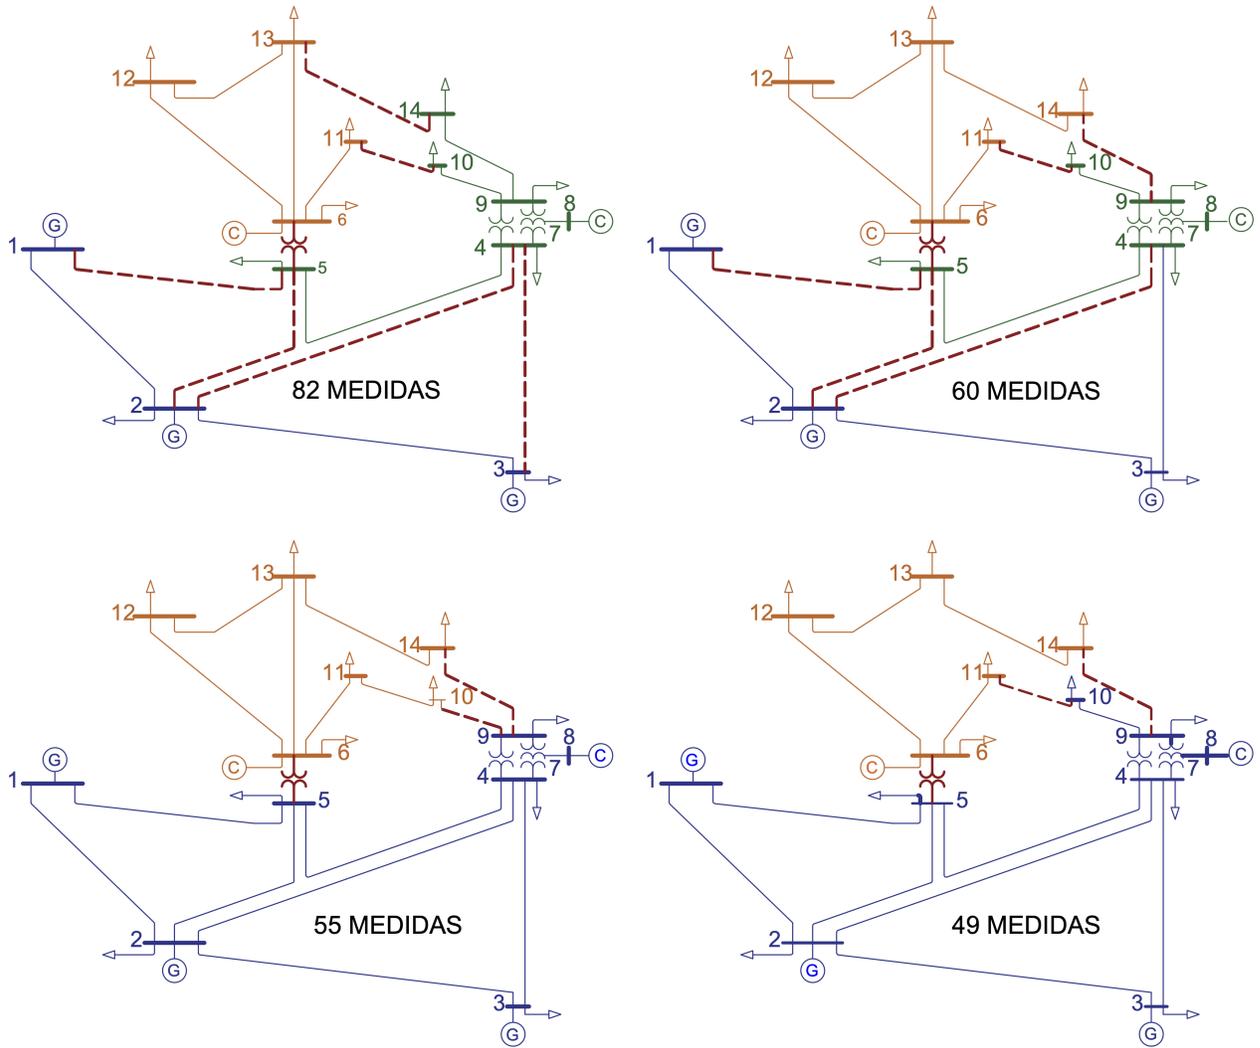


Figura 4.2: Partición del Sistema Eléctrico IEEE 14 Barras

revela que un aumento en el número de mediciones conduce a una mejora y reducción en el valor del MSE de las estimaciones. Esto se logra aplicando el método de partición nodal propuesto en el proceso de estimación distribuida.

Tabla 4.6: Comparación del tiempo de procesamiento entre estimación distribuida y estimación centralizada

Medidas	Área	MSE	Tiempo [s]	
			Distribuido	Centralizado
82	3	0,0087 %	1.16	5.54
60	3	0,0367 %	0.78	3.44
55	2	0,0734 %	1.03	3.17
49	2	0,0923 %	0.77	2.78

En relación al tiempo de procesamiento, se observa que para cada caso analizado en el sistema IEEE 14 barras, no hay una diferencia significativa en comparación con la estimación centralizada. Este análisis se puede observar en la Figura 4.3.

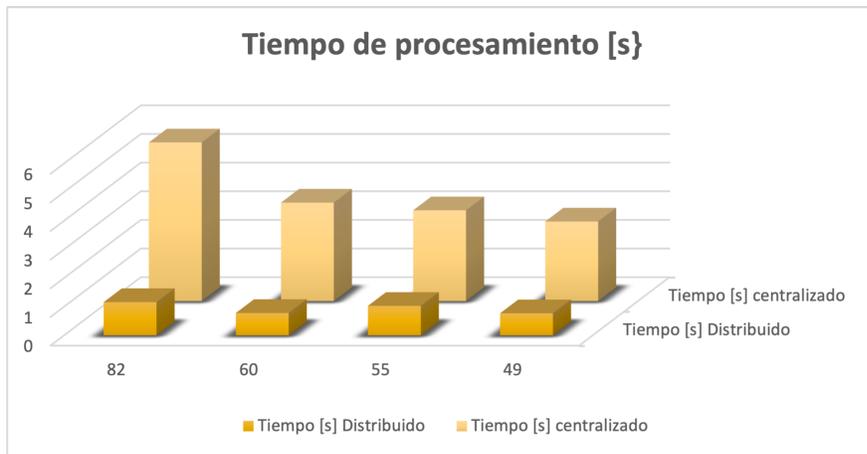


Figura 4.3: Tiempo de procesamiento Distribuido vs Centralizado

La Figura 4.4 presenta el grafo de partición del sistema IEEE14 barras para un caso con 82 mediciones. Estas mediciones se distribuyen en 14 medidas de tensión, 14 medidas de inyección $P_i + jQ_i$, y 20 medidas de flujo de potencia $P_{ij} + jQ_{ij}$. En esta partición se crean tres subsistemas, y se localizan las BN's en las barras 2, 4 y 6 del sistema

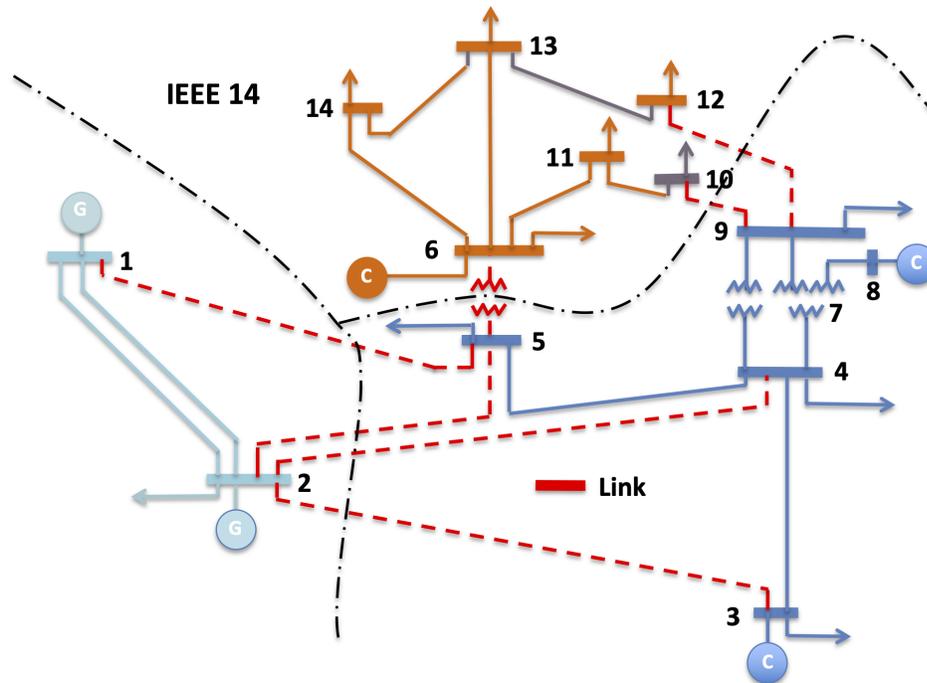


Figura 4.4: Caso estudio Sistema eléctrico IEEE 14 barras-82 mediciones, dividido en 3 subsistemas.

4.2.2. Simulaciones en el sistema IEEE 118 Barras

En la extensión de la aplicación del método de partición en las simulaciones de grandes sistemas eléctricos, se utilizó el sistema eléctrico de la IEEE118 barras como modelo. Como

punto de referencia, se consideró el método aplicado en los estudios [3, 6, 103], donde se propone una partición en tres áreas utilizando las barras 25, 66 y 69 como barras de referencia para las estimaciones locales.

Para la distribución de las medidas, se tomó como referencia los datos del caso desarrollado en [83], que incluye un sistema de 441 mediciones. Estas mediciones se distribuyen en 134 medidas de flujo de potencia $P_{ij} + jQ_{ij}$, 56 medidas de inyecciones de potencia $P_i + jQ_i$, y 61 medidas de tensión.

La Figura 4.5 muestra el diagrama del sistema eléctrico de potencia de la IEEE118 barras, [113] .

En el proceso de partición del sistema IEEE118 barras, se identificaron diferentes jerarquías basadas en el número de mediciones en cada barra. La primera jerarquía incluye las barras nodales con un total de nueve mediciones, que en nuestro caso corresponden a las barras 80 y 100 del sistema. A medida que se avanza en la jerarquización, se consideran las barras nodales con ocho mediciones por barra, que se localizan en las barras 8, 49 y 70. Además, se incluyó una tercera jerarquía para las barras nodales con siete mediciones, que se encuentran en las barras 40, 69 y 92.

No se evaluaron jerarquías inferiores en nuestras simulaciones, ya que la distribución de mediciones en esos casos implicaba la presencia de más de dos BN continuos en el sistema, lo que impedía la partición del sistema. En los tres escenarios analizados, debido al número de mediciones por barra, tanto la configuración del sistema como las barras nodales se modifican. Es importante tener en cuenta que estas barras nodales actuarán como barras de referencia local en sus respectivos subsistemas durante el proceso de estimación distribuida.

La distribución y el número de mediciones en cada barra del sistema se muestran en la Figura 4.6. Estas mediciones se utilizarán en el proceso de partición y estimación de estado distribuido en el caso base, así como en los escenarios propuestos, utilizando el concepto de barra nodal y teniendo en cuenta el proceso de jerarquización mencionado anteriormente.

La Tabla 4.7 muestra los resultados del proceso de partición nodal del sistema IEEE 118 barras, utilizando la metodología propuesta. En la tabla se detalla el número de áreas resultantes, el número de buses en cada sistema y el número de medidas en cada sistema.

Tabla 4.7: Partición Nodal Sistemas IEEE118 Barras: Caso Base

Área	BN	No Barras	Mediciones	
			por Barra	por Área
1	25	36	3	134
2	66	34	3	126
3	69	48	7	181

La Figura 4.7 muestra las particiones del sistema del caso base considerado en la literatura para el sistema IEEE 118 barras. En la figura se pueden observar las diferentes áreas resultantes de la partición, identificadas por diferentes colores, y las barras nodales de referencia en cada área.

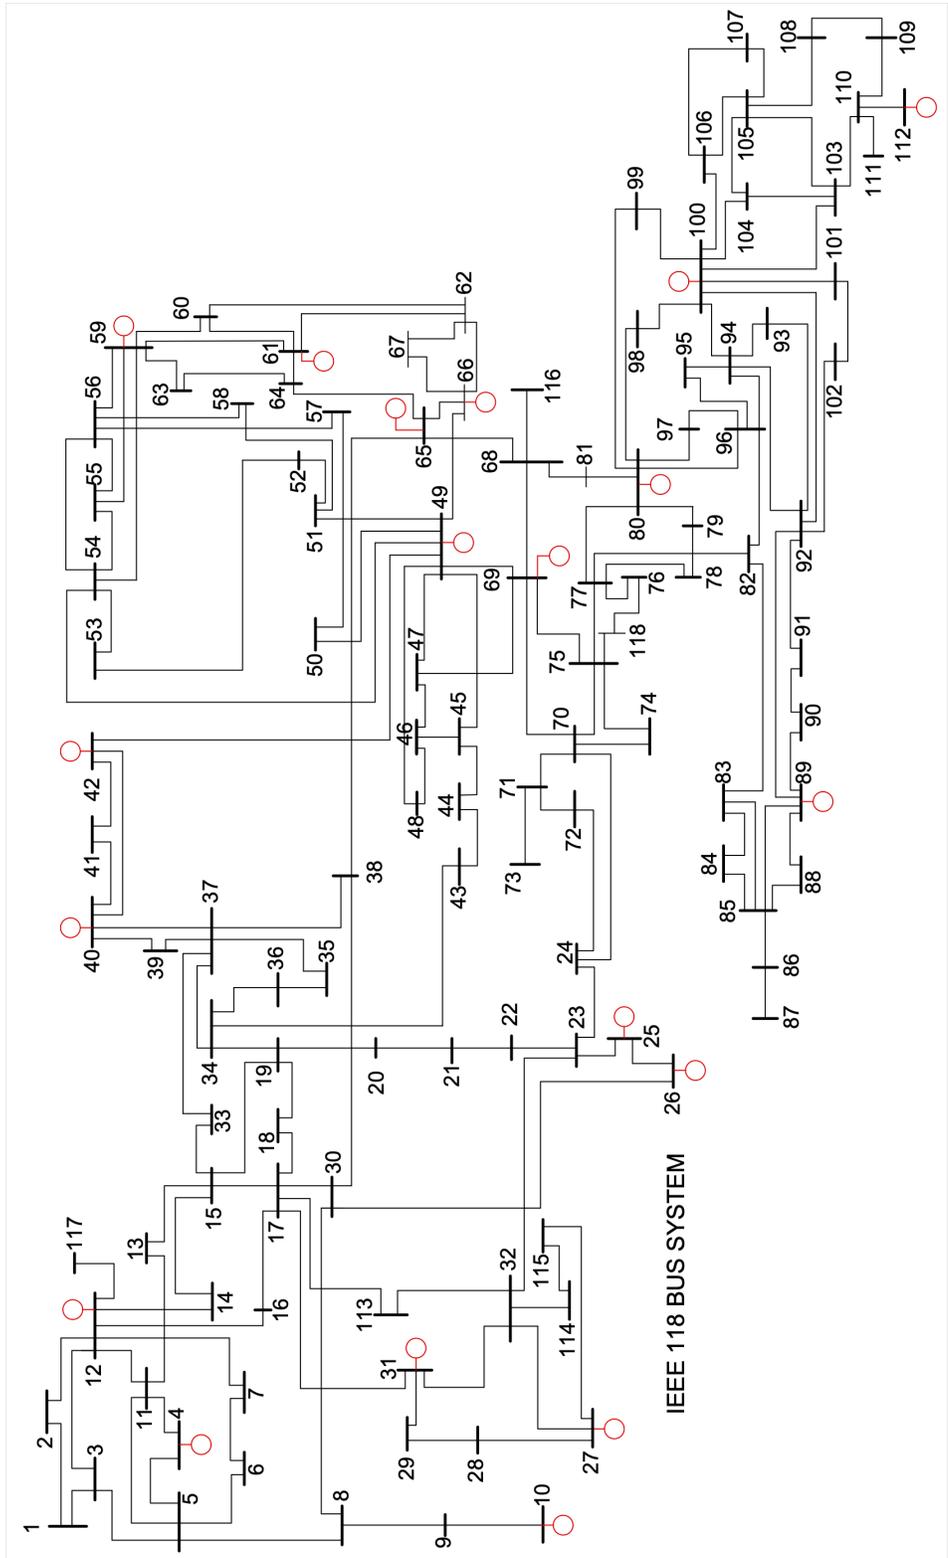


Figura 4.5: Case estudio para grandes Sistemas Eléctricos de Potencia Sistema IEEE118 Barras, extraído de [112]

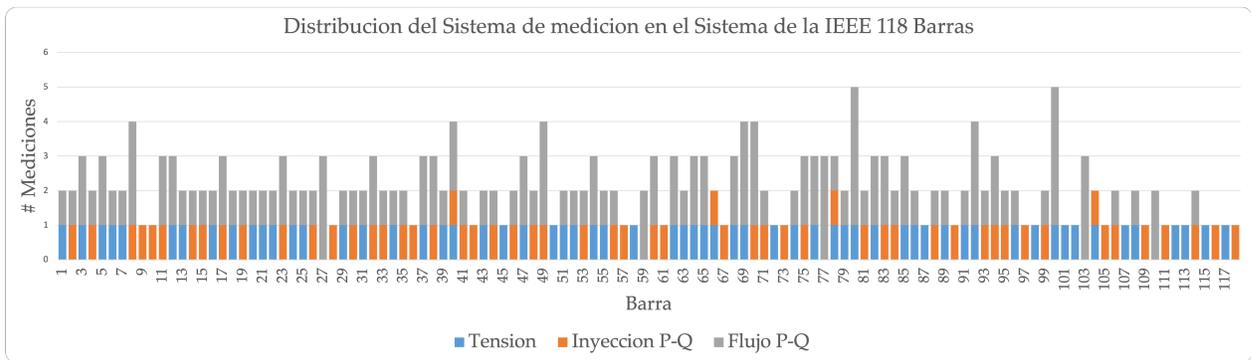


Figura 4.6: Distribución de mediciones por barra en el Sistema IEEE118 Barras

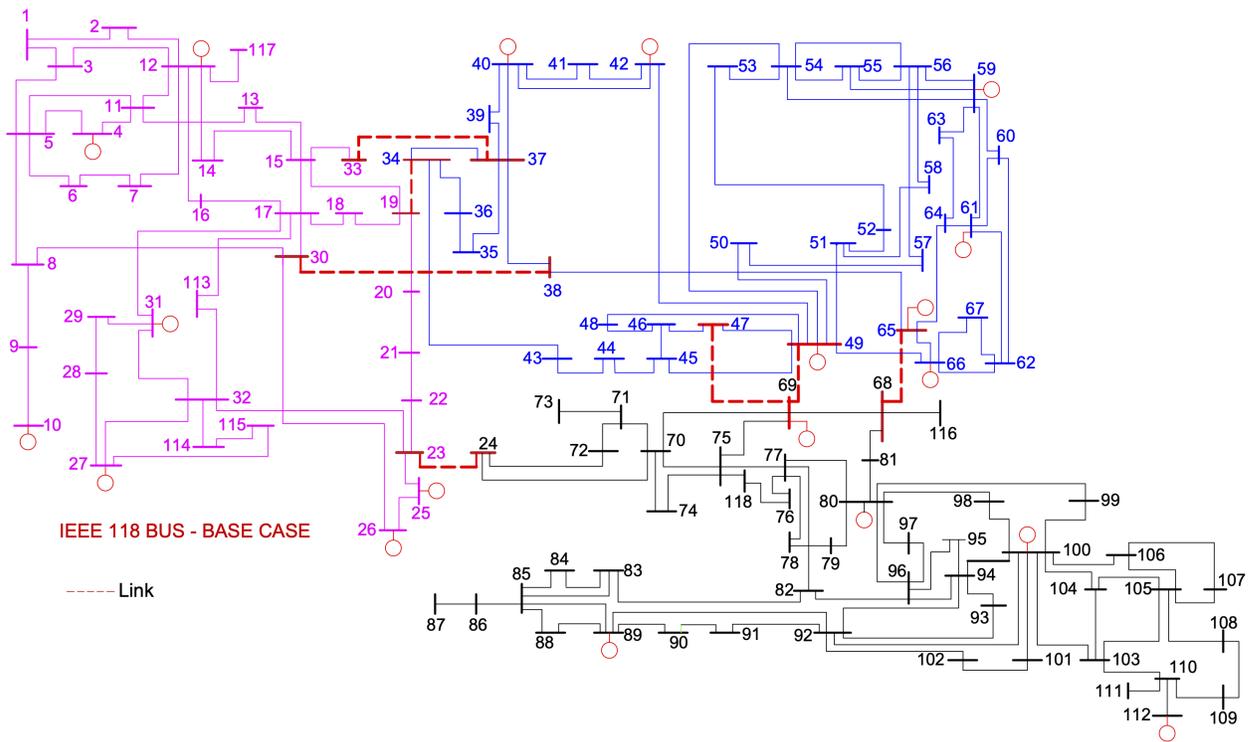


Figura 4.7: Sistema eléctrico IEEE118: caso base desarrollado en [107]

En la Tabla 4.8 se presentan los resultados considerando la jerarquización de 9 mediciones en las barras nodales. En la tabla se muestran los detalles de la partición, incluyendo el número de áreas, el número de buses en cada área y el número de medidas en cada área.

Por otro lado, en la Figura 4.8 se puede observar la configuración de los subsistemas y su distribución física para este caso de partición de dos áreas. En la figura se muestra cómo se agrupan las barras nodales y cómo se distribuyen en las dos áreas resultantes.

En la Tabla 4.9 se presentan los resultados de la partición nodal considerando la jerarquización de 8 mediciones en las barras nodales. En la tabla se detallan el número de áreas, el número de buses en cada área y el número de medidas en cada área.

Asimismo, en la Figura 4.9 se muestra la distribución física de los elementos en este caso de partición con dos áreas. La figura ilustra cómo se agrupan las barras nodales y su distribución

Tabla 4.8: Partición Nodal Sistemas IEEE118 Barras: Caso BN9-2Areas

Área	BN	No Barras	Mediciones	
			por Barra	por Área
1	80	92	9	355
2	100	26	9	86

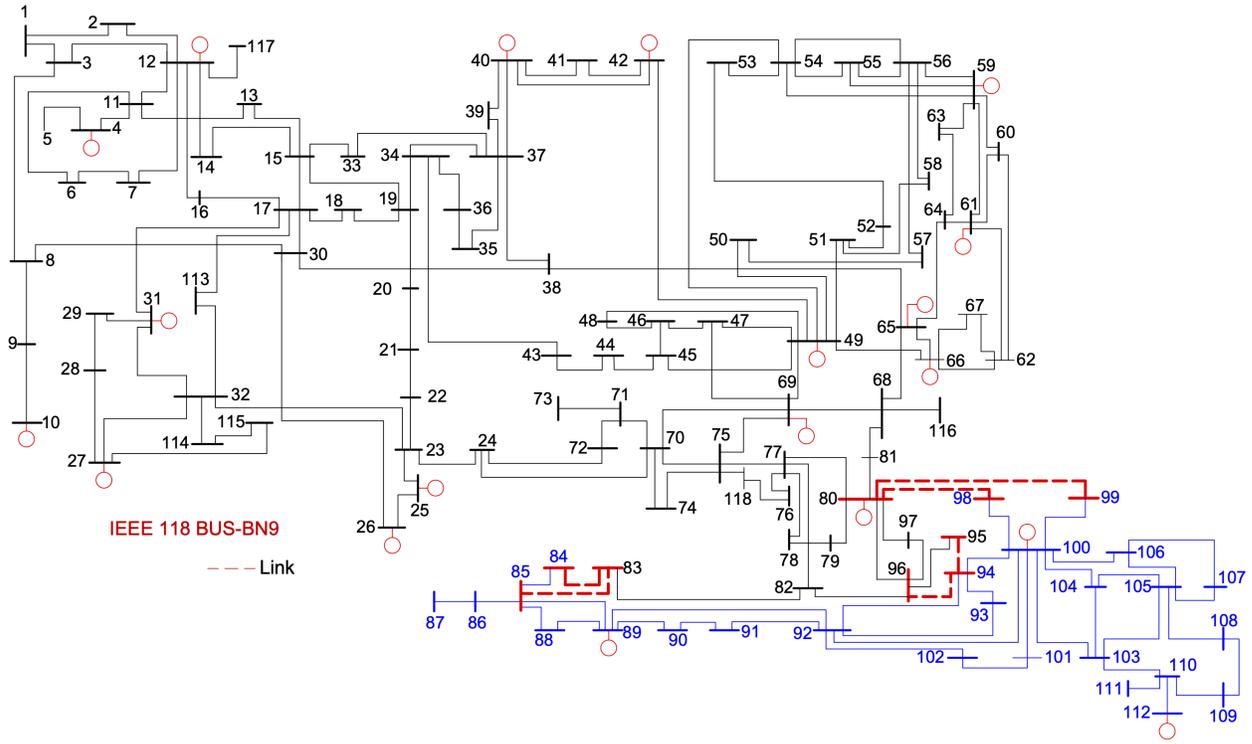


Figura 4.8: Sistema eléctrico IEEE118: caso BN9

Tabla 4.9: Partición Nodal Sistemas IEEE118 Barras: Caso BN8-3Areas

Área	BN	No Barras	Mediciones	
			por Barra	por Área
1	25	36	3	134
2	66	34	3	126
3	69	48	7	181

en las dos áreas resultantes.

En la Tabla 4.10, por otro lado, se presentan los resultados de la partición nodal considerando la jerarquización de 7 mediciones en las barras nodales. La tabla proporciona información sobre el número de áreas, el número de buses en cada área y el número de medidas en cada área.

Finalmente, en la Figura 4.10 se muestra la distribución física de los elementos en este caso de partición con tres áreas. La figura representa cómo se agrupan las barras nodales y

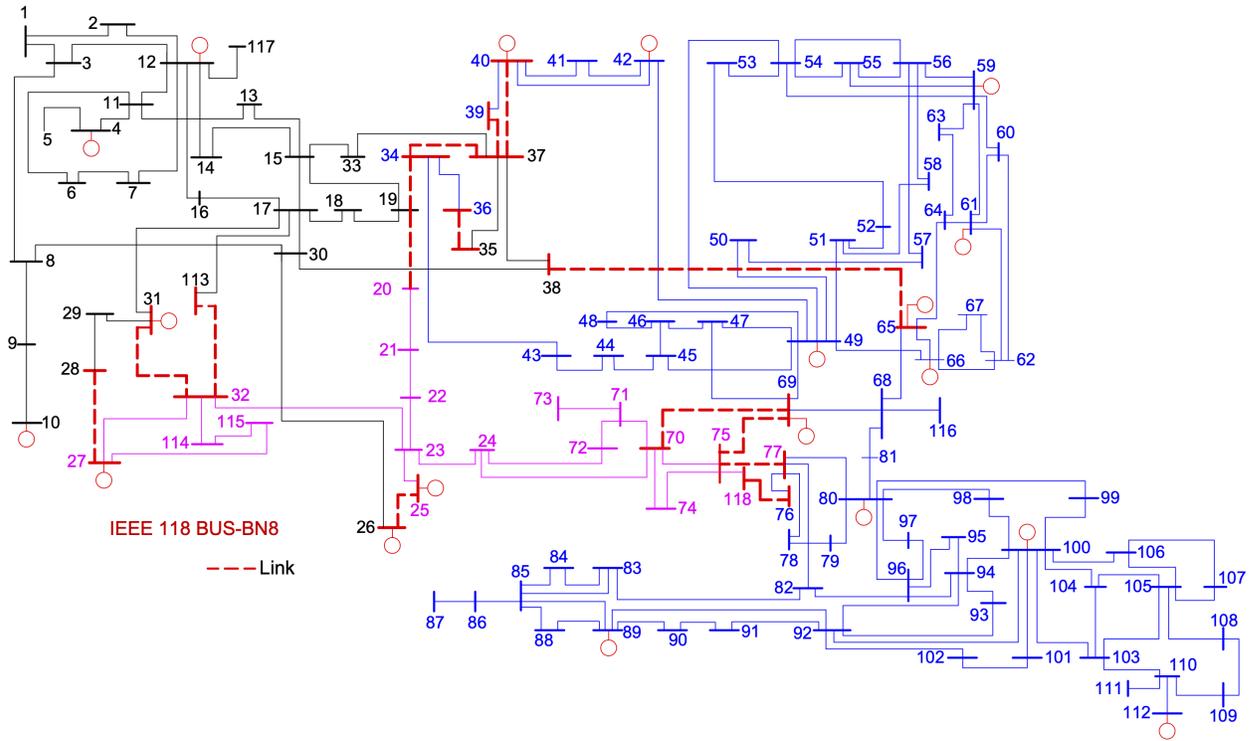


Figura 4.9: Sistema eléctrico IEEE118: caso BN8

Tabla 4.10: Partición Nodal Sistemas IEEE118 Barras: Caso BN7-3Áreas

Área	BN	No Barras	Mediciones	
			por Barra	por Área
1	25	36	3	134
2	66	34	3	126
3	69	48	7	181

su distribución en las tres áreas resultantes.

En la Figura 4.11 se muestra la distribución de barras del sistema después de aplicar la metodología propuesta en el caso de partición con jerarquización de 9 mediciones en las barras nodales. Esta figura permite visualizar cómo se distribuyen las barras en el sistema eléctrico.

En la Figura 4.12 se presenta la redundancia en cada área resultante de la partición. La redundancia se refiere al número de mediciones redundantes disponibles en cada área y es una métrica importante para evaluar la calidad de la partición. En este caso, se busca que la redundancia sea lo más homogénea posible en todas las áreas.

En la Figura 4.13 se muestra el número de mediciones por área en el caso de partición con jerarquización de 7 mediciones en las barras nodales. Esta figura proporciona información sobre la distribución de las mediciones en cada área y permite verificar si existe un equilibrio en la asignación de mediciones entre las áreas resultantes.

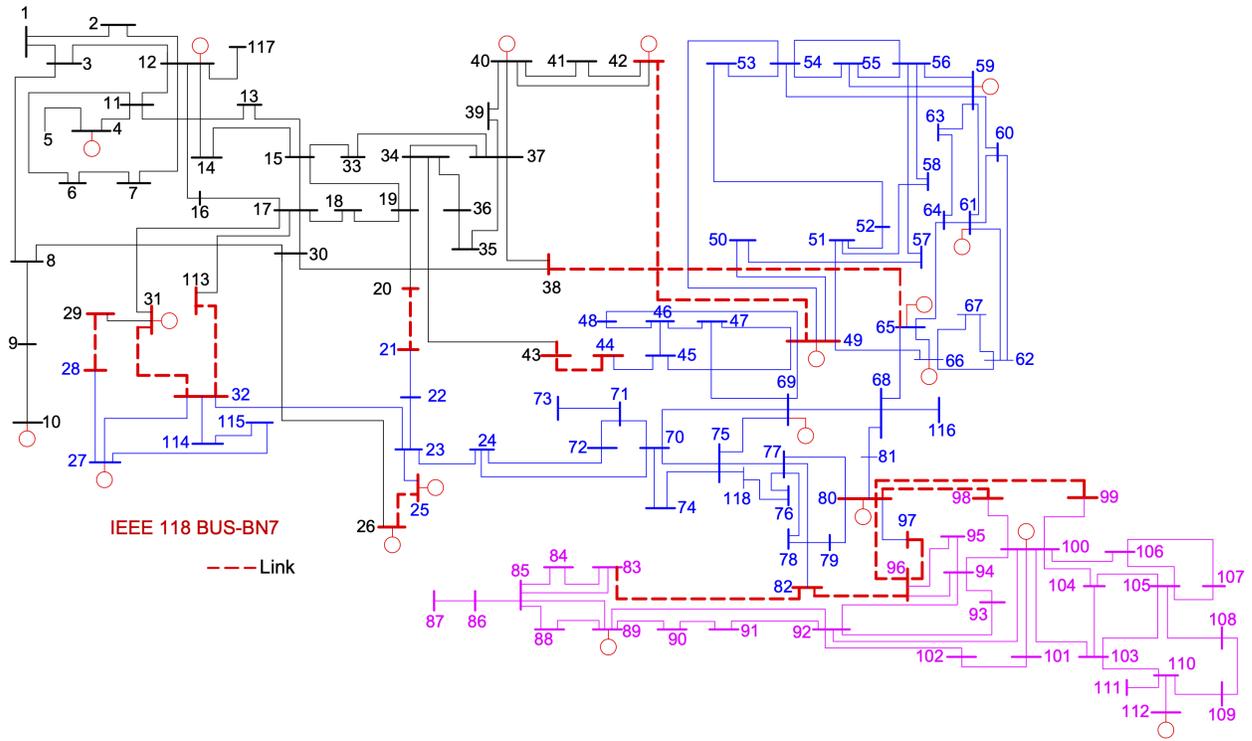


Figura 4.10: Sistema eléctrico IEEE118: caso BN7

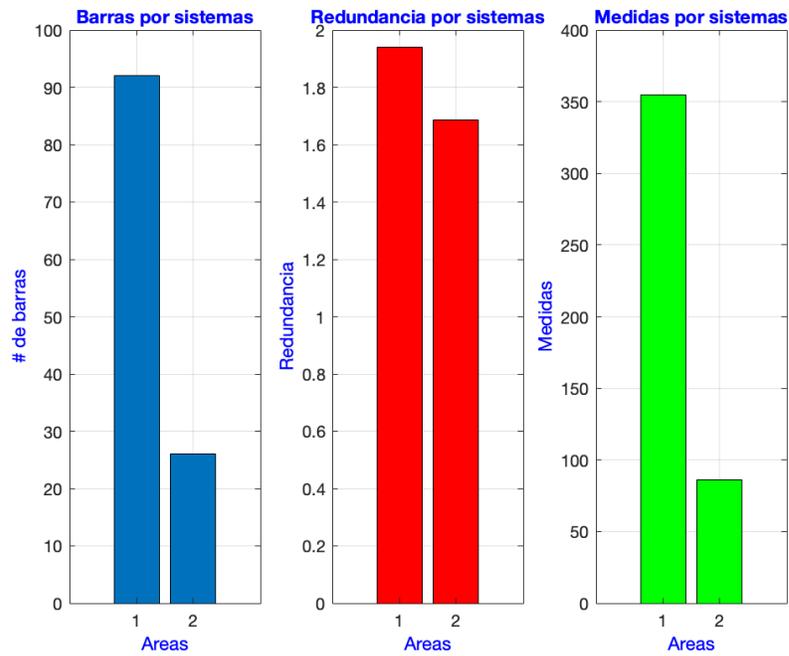


Figura 4.11: Barra Nodal 9 mediciones

En conjunto, estas figuras ofrecen una visión general de la distribución de barras, la redundancia y el número de mediciones por área en los casos en los que se aplicó la metodología propuesta, lo cual es relevante para evaluar la calidad de la partición y la distribución de las

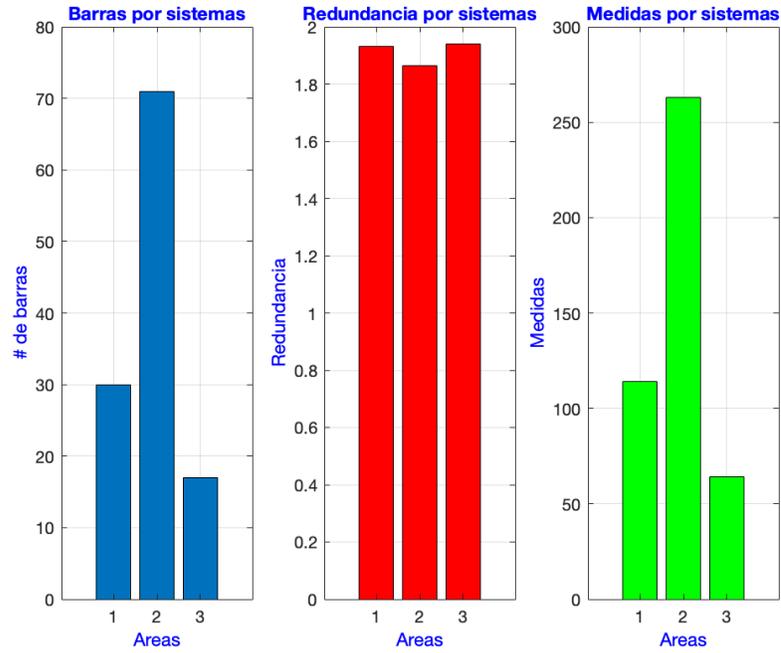


Figura 4.12: Barra Nodal 8 mediciones

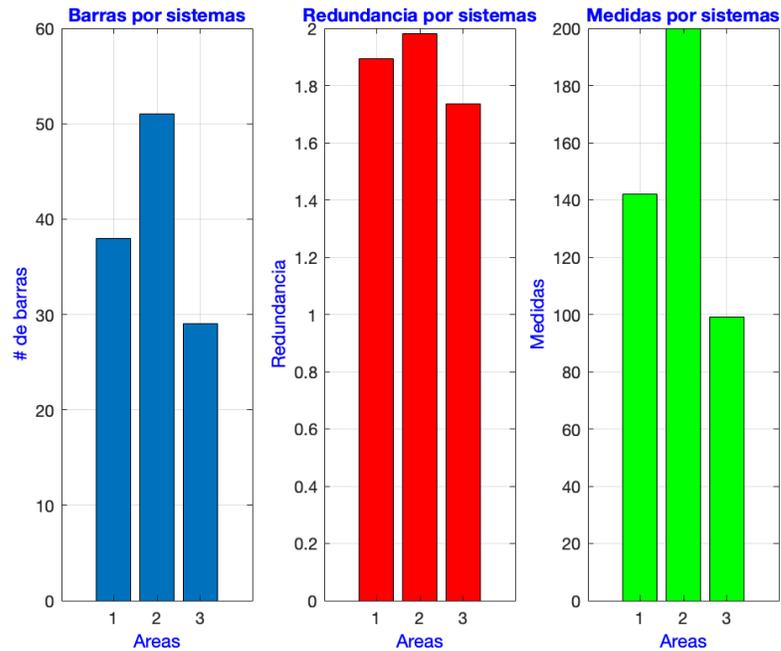


Figura 4.13: Barra Nodal 7 mediciones

mediciones en el sistema.

En la Tabla 4.11 se presentan los resultados del error cuadrático medio (MSE) en los diferentes casos simulados: Caso Base, BN9, BN8 y BN7. Estos valores permiten evaluar la calidad de las estimaciones obtenidas en cada caso.

Tabla 4.11: Error cuadrático medio (MSE) y el tiempo de procesamiento en los casos evaluados.

Caso	CB-3	BN9-2	BN8-3	BN7-3
MSE	$0,6149 \times 10^{-4}$	$0,28 \times 10^{-5}$	$0,3603 \times 10^{-4}$	$0,3447 \times 10^{-4}$
Tiempo (mín)	3.667	18.937	10.674	4.645

Se puede observar que en los casos de BN9, BN8 y BN7, hay una reducción en el valor del MSE en comparación con el Caso Base. Esto indica que la estimación distribuida utilizando el método de partición propuesto ha mejorado la precisión de los resultados en términos de ajuste a los datos observados.

Sin embargo, es importante destacar que los tiempos de procesamiento en los escenarios de BN9 y BN8 son mayores en comparación con el Caso Base. Esto se debe a que el proceso de partición propuesto busca obtener una redundancia homogénea entre las áreas, lo cual implica la convergencia de subsistemas más grandes en el proceso de estimación. Como resultado, se requiere más tiempo para alcanzar la convergencia numérica en la estimación de estado.

En resumen, los resultados de la tabla indican una mejora en la precisión de las estimaciones (menor MSE) al aplicar el método de partición propuesto, pero a costa de un mayor tiempo de procesamiento debido a la convergencia de subsistemas más grandes. Esto resalta la importancia de encontrar un equilibrio entre la precisión y la eficiencia computacional al aplicar técnicas de estimación distribuida en sistemas eléctricos de potencia.

Al comparar los tiempos de procesamiento, se observa que el Caso Base tiene un tiempo menor en comparación con los casos de BN8 y BN9. Sin embargo, al analizar el caso BN7, se observa una reducción considerable en el tiempo de procesamiento. Esta diferencia en los tiempos se debe a la distribución de las medidas en los subsistemas.

En el Caso Base y en BN7, la partición del sistema resulta en tres áreas, lo que conduce a una distribución más homogénea de las medidas entre los subsistemas. Esto permite que los cálculos numéricos se realicen de manera más eficiente y rápida.

Por otro lado, en los casos de BN8 y BN9, la partición implica tres y dos áreas respectivamente, lo que resulta en una distribución menos homogénea de las medidas entre los subsistemas. Esta distribución desigual puede llevar a un mayor tiempo de procesamiento, ya que se requiere un mayor número de iteraciones para lograr la convergencia en la estimación de estado.

Es importante tener en cuenta que los cálculos numéricos en la estimación de estado involucran operaciones matriciales, y el aumento en el tamaño del sistema resultará en un mayor tiempo de procesamiento. Por lo tanto, la distribución de las medidas en los subsistemas puede tener un impacto significativo en el rendimiento computacional de la estimación distribuida.

En resumen, la distribución más homogénea de las medidas en el Caso Base y BN7 resulta en tiempos de procesamiento más bajos, mientras que en los casos de BN8 y BN9, donde la distribución de las medidas es menos homogénea, los tiempos de procesamiento son mayores, Figura 4.14. Es esencial considerar tanto la precisión de las estimaciones como la

eficiencia computacional al seleccionar la partición y distribución de medidas en un sistema de estimación de estado distribuido

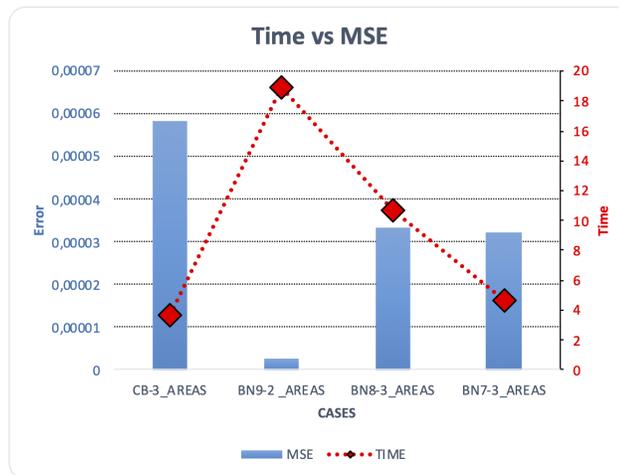


Figura 4.14: Tiempo de Procesamiento vs MSE en IEEE 118 Barras

En la Figura 4.15 se muestra el perfil de tensión de cada barra del sistema, evaluado tanto en una estimación centralizada como en una estimación distribuida. Se presentan los resultados para el Caso Base, así como para los casos en los que se aplicó la redundancia nodal.

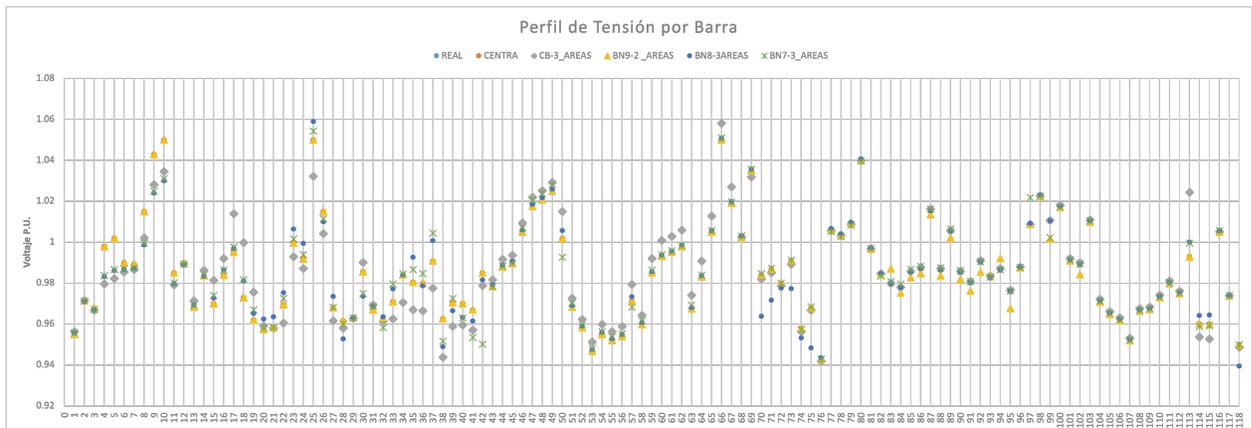


Figura 4.15: Perfil de Tensión de los casos simulados

En el perfil de tensión obtenido mediante la estimación centralizada, se puede observar una distribución uniforme de los valores de tensión en todas las barras del sistema. Esto indica que la estimación centralizada logra mantener un equilibrio en la asignación de tensiones en todo el sistema eléctrico.

En cuanto a la estimación distribuida, se observan algunas variaciones en los perfiles de tensión de las barras. Estas variaciones pueden atribuirse a las diferencias en la configuración de los subsistemas y la distribución de las medidas en cada caso.

En el Caso Base, donde se aplicó la partición en tres áreas homogéneas, se obtiene un perfil de tensión bastante similar al de la estimación centralizada, lo que indica una buena aproximación de los resultados.

En los casos de redundancia nodal, como BN8 y BN9, se observan algunas variaciones más pronunciadas en los perfiles de tensión de algunas barras. Esto puede deberse a la distribución menos homogénea de las medidas en los subsistemas, lo que puede afectar la precisión de la estimación en esas áreas específicas.

Es importante destacar que, a pesar de las variaciones en los perfiles de tensión, los resultados de la estimación distribuida aún son aceptables y cumplen con los requisitos de operación del sistema eléctrico.

La comparación de los perfiles de tensión entre la estimación centralizada y la estimación distribuida muestra que, en general, la estimación distribuida logra aproximarse a los resultados de la estimación centralizada. Sin embargo, pueden existir variaciones en los perfiles de tensión debido a la configuración de los subsistemas y la distribución de las medidas en cada caso específico.

En un Estimador de Estado Distribuido (DSE), los procesos numéricos se pueden reducir gracias al uso de conjuntos de datos distribuidos en clústeres. En contraste, en un proceso centralizado, la gestión de la información se realiza para todo el sistema, lo que puede requerir un mayor esfuerzo de recursos en el cálculo numérico.

En el contexto de los procesos de simulación, considerando el modelo centralizado como caso base, se puede observar en la Figura 4.16 la distribución física del sistema y el número de particiones en cada caso analizado.

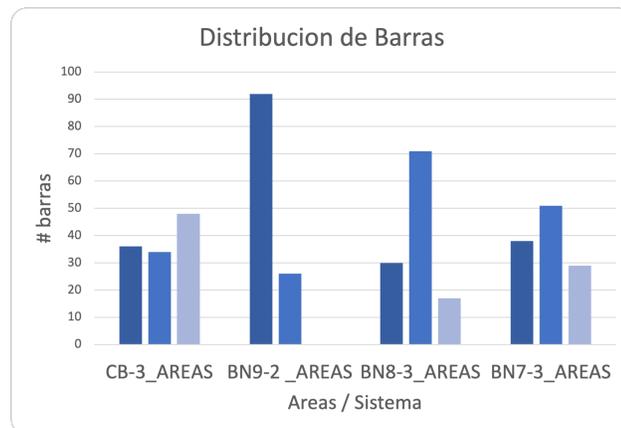


Figura 4.16: Distribución física de las Barras en el Proceso de partición de los casos de estudios

En el caso base, se muestra la configuración original del sistema eléctrico de potencia sin aplicar particiones. En este caso, todas las barras se consideran en una sola partición, lo que implica un enfoque centralizado en la estimación de estado.

En los casos de estimador distribuido, se aplican particiones para dividir el sistema en áreas más pequeñas. Cada partición representa un subsistema que puede ser estimado de manera independiente. En la figura se muestra la distribución física del sistema y se resaltan las particiones con diferentes colores, lo que indica la separación de las áreas.

En cada caso, se observa un número diferente de particiones, lo que implica una distri-

bución distinta de la carga computacional entre los subsistemas. Esto permite una mayor eficiencia en los procesos numéricos, ya que cada partición puede ser procesada de forma paralela, lo que reduce el tiempo de cálculo total.

En la simulación se realizó un flujo de potencia en el sistema IEEE118, y se evaluó el error entre los valores estimados y los valores reales. En la Tabla 4.12 se puede observar que, en comparación con el Caso Base, los casos simulados BN9 y BN7 presentan errores menores. La

Tabla 4.12: Error Cuadrático del vector de estado (V, θ)

CD-3_Áreas	BN9-2_Areas	BN8-3Areas	BN7-3_Areas
0.004918	0.001950	0.005453	0.003812

Tabla 4.12 muestra los valores del error cuadrático medio (MSE) para cada caso analizado. En los casos BN9 y BN7, se observa una reducción significativa en el MSE en comparación con el Caso Base, lo que indica una mejor precisión en la estimación de los valores.

Además, en la Figura 4.17 se presenta la dispersión del error en relación al Caso Base. Se puede observar que los casos BN9 y BN7 presentan una dispersión más baja en comparación con el Caso Base, lo que indica una mayor precisión en la estimación de los valores.

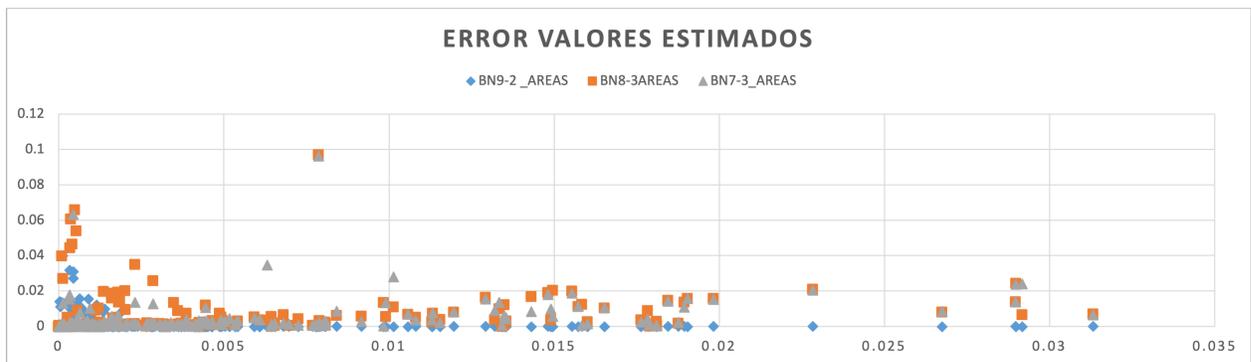


Figura 4.17: Dispersión del Error del Vector de estado (V, θ)

Estos resultados respaldan la efectividad de la metodología propuesta, ya que se logra una reducción en el error de los valores estimados en comparación con el enfoque centralizado. Esto demuestra la capacidad del método de partición nodal para mejorar la precisión de la estimación de estado en sistemas eléctricos de potencia de gran escala.

4.3. Detección e Identificación de Mediciones Erróneas

En el proceso de finalización de la estimación de estado y la obtención del vector de estado (V, θ), es necesario verificar la calidad de las mediciones para asegurar que los valores estimados sean válidos y reflejen el estado real del sistema. Esto es crucial para realizar las correcciones necesarias en la operación del sistema.

En este contexto, se aplicó el residual, que cumple con los siguientes objetivos fundamentales:

1. Detección de errores en las mediciones: El residual se calcula como la diferencia entre las mediciones reales y las mediciones estimadas utilizando el vector de estado. Al comparar el residual con un umbral de aceptación, es posible detectar mediciones que presenten errores significativos. Estas mediciones pueden ser eliminadas o corregidas para mejorar la precisión de la estimación.
2. Evaluación de la bondad de ajuste: El residual también permite evaluar la calidad global de la estimación. Si el residual se encuentra dentro de los límites de aceptación, indica que el vector de estado estimado se ajusta de manera adecuada a las mediciones. En caso contrario, es necesario revisar el modelo o las mediciones para identificar posibles incongruencias o fuentes de error.
3. Evaluación de la precisión de las mediciones: El análisis de residuos también puede proporcionar información sobre la precisión y confiabilidad de las mediciones individuales. Si las mediciones tienen residuos grandes y consistentes, esto podría indicar que dichas mediciones tienen una mayor incertidumbre o error asociado. Esto nos permite identificar aquellas mediciones que pueden requerir una mayor atención o calibración para mejorar su precisión y confiabilidad.

Al analizar el residual y su comportamiento en relación con los umbrales establecidos, es posible evaluar la calidad de las mediciones y validar los valores estimados del vector de estado. Esto proporciona una base sólida para la toma de decisiones en la operación del sistema eléctrico de potencia

En concordancia con la explicación teórica previa, se emplea un enfoque estadístico basado en el cálculo del residual normalizado para determinar si existen mediciones erróneas. Se establece un umbral para identificar aquellas mediciones que se desvían significativamente de los valores esperados.

Para ilustrar el proceso de identificación de mediciones erróneas, se utiliza el caso base denominado BN7-3_Areas, el cual se caracteriza por una jerarquización de una barra nodal compuesta por 7 mediciones. En este caso, se han agregado mediciones erróneas a las barras 12, 68 y 101, con el propósito de analizar los resultados obtenidos durante el proceso de identificación. Los detalles de la configuración de este caso se encuentran especificados en la tabla adjunta. La Tabla 4.13 muestra la distribución de las medidas aplicada al proceso de partición correspondiente a este caso.

Tabla 4.13: Configuración IEEE118 barras BN7-3_Areas

	Sistema BN7-3_Areas		
	Área 1	Área 2	Área 3
No de Barras	30	51	29
Redundancia	1.8933	1.9802	1.736
mediciones/Area	142	200	99

La distribución de las mediciones por cada barra se muestra en la Figura 4.18. Estas mediciones pueden ser de tensión, potencia inyectada o flujo de potencia entre dos barras, cada barra del sistema tiene asignadas una serie de mediciones específicas.

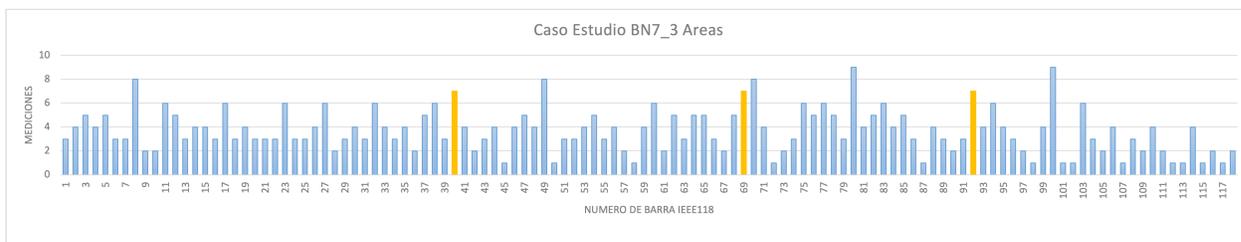


Figura 4.18: Número de mediciones por barra en el sistema IEEE118

La Figura 4.19 proporciona una visualización detallada de la estructura de cada sistema y el número de barras asociadas a cada uno de ellos. Se puede observar cómo se agrupan las barras en subsistemas dentro del sistema global.

Estas figuras permiten comprender mejor la distribución de las mediciones en el sistema eléctrico y la forma en que se organiza en diferentes subsistemas.

En el proceso de identificación de mediciones erróneas utilizando el estadístico de chi-cuadrado, se estableció un intervalo de confianza del 95 % y un margen de error de 0.05. Los resultados de la identificación de las mediciones erróneas se muestran en la Tabla 4.14. Cabe destacar que en la estimación centralizada, se realiza todo el proceso de estimación para determinar cada error y corregirlo, mientras que en la estimación distribuida se realizan identificaciones locales.

El grado de libertad en el DSE (Estimación de Estado Distribuida) depende de la configuración de los subsistemas. En nuestros casos de estudio, se cumple la condición de que $k > 30$, lo que asegura la validez de los resultados estadísticos utilizados en el proceso de identificación de mediciones erróneas.

Tabla 4.14: Análisis del Residual normalizado para la identificación de medidas erróneas

	CHI	$\sum_{j=1}^{N_m} \frac{(z_j - \hat{z}_j)^2}{\sigma_j^2}$	$r_i^N = \frac{r_i}{\sqrt{R_{ii}}}$	$k = m - n$
Centralizado	322.57	322.57	14.038	125
BN7_Area1	107	1312	66.34	66
BN7_Area2	149	431	22	98
BN7_Area3	81	2055	60.9	41

En el proceso final, se evalúa nuevamente el estimador, pero esta vez con las mediciones erróneas eliminadas, con el objetivo de garantizar la calidad de los resultados. En la Figura 4.20, se presentan los perfiles de tensión de las barras durante el proceso de estimación del sistema IEEE118, contrastando el vector de estado con la presencia de errores y el vector de estado una vez que se han eliminado los errores.

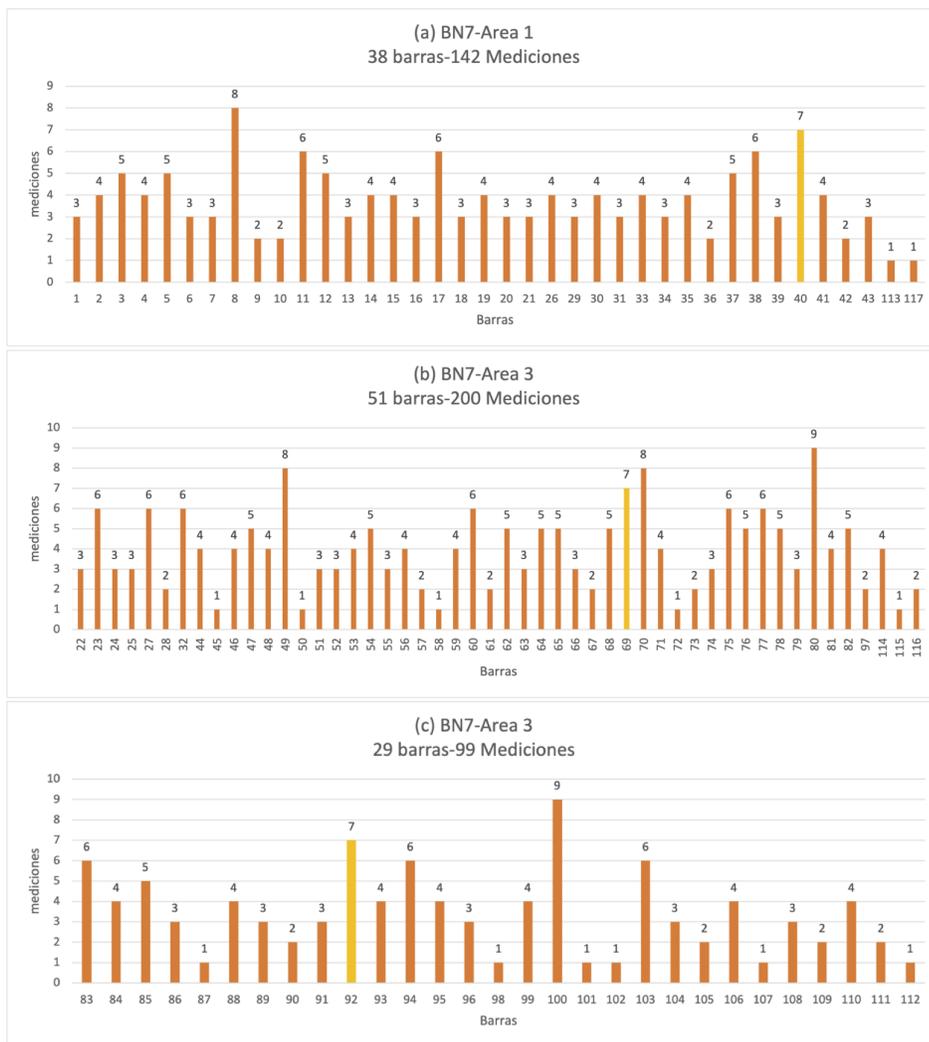


Figura 4.19: Partición del Caso BN7: (a) Área 1, (b) Área 2, (c) Área 3

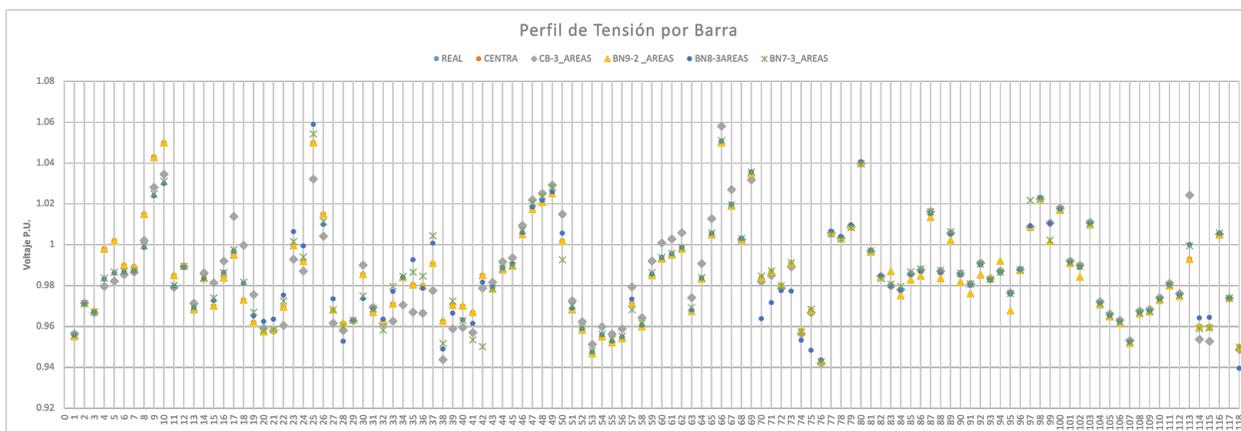


Figura 4.20: Perfil de tensión

En la Figura 4.21, se muestra la dispersión del error antes y después de este proceso de eliminación de errores. Se puede observar que al eliminar los errores, la dispersión se reduce,

lo cual indica que el vector de estado evaluado después de la eliminación de mediciones erróneas es más aceptable. Es importante destacar que el número de mediciones para esta nueva estimación se reduce debido a la eliminación de mediciones erróneas.

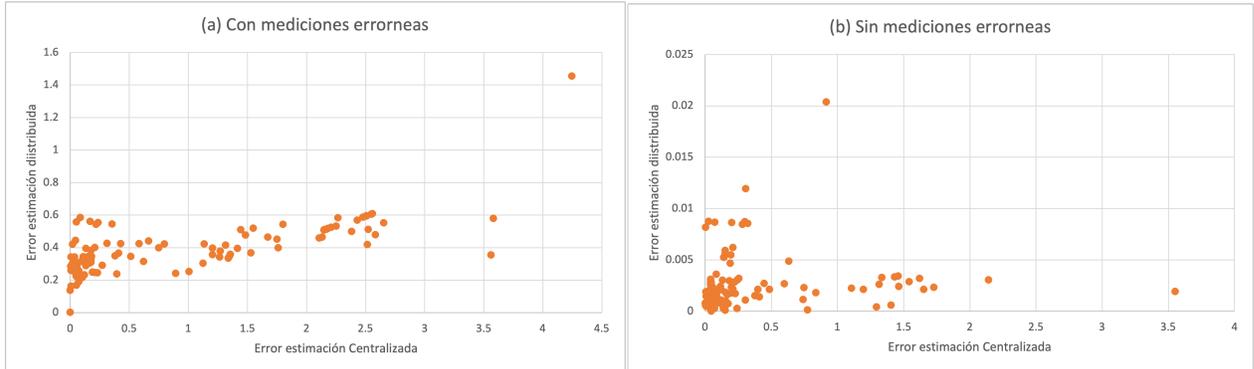


Figura 4.21: Dispersión de error: (a) Con Mediciones Erróneas, (b) Sin Mediciones Erróneas

Estos resultados respaldan la importancia de la identificación y eliminación de mediciones erróneas en el proceso de estimación de estado, ya que contribuyen a mejorar la calidad y confiabilidad de los resultados obtenidos.

Dentro del proceso de eliminación de medidas erróneas, es posible que la configuración del sistema de medidas se vea afectada, lo que implica que el número de barras nodales pueda cambiar. En el caso de simulación que se presenta, al eliminar las medidas erróneas, se incrementó el número de barras nodales de 8 mediciones, que inicialmente era de tres, a cinco. Esto significa que ahora se deberá aplicar una estimación distribuida sobre cinco subsistemas.

La Tabla 4.15 muestra la nueva configuración del sistema después de la eliminación de medidas erróneas, sobre la cual se aplica una estimación distribuida.

Tabla 4.15: Partición del sistema IEEE118 BN8-5Areas

	BN	# de barras	Redundancia	# de medidas/areas
Area 1	8	27	1.9056	101
Area 2	49	37	1.8904	138
Area 3	70	27	1.9393	64
Area 4	80	12	2.3913	55
Area 5	100	25	1.6530	81

Estos resultados demuestran cómo la eliminación de medidas erróneas puede afectar la configuración del sistema de medidas y, en consecuencia, el proceso de estimación distribuida. Es importante adaptar el estimador a los cambios en la configuración del sistema para obtener resultados más precisos y confiables, como se presenta en la Figura 4.22 .

La Tabla 4.16 muestra la conformación de los subsistemas, indicando qué barras corresponden a cada área.

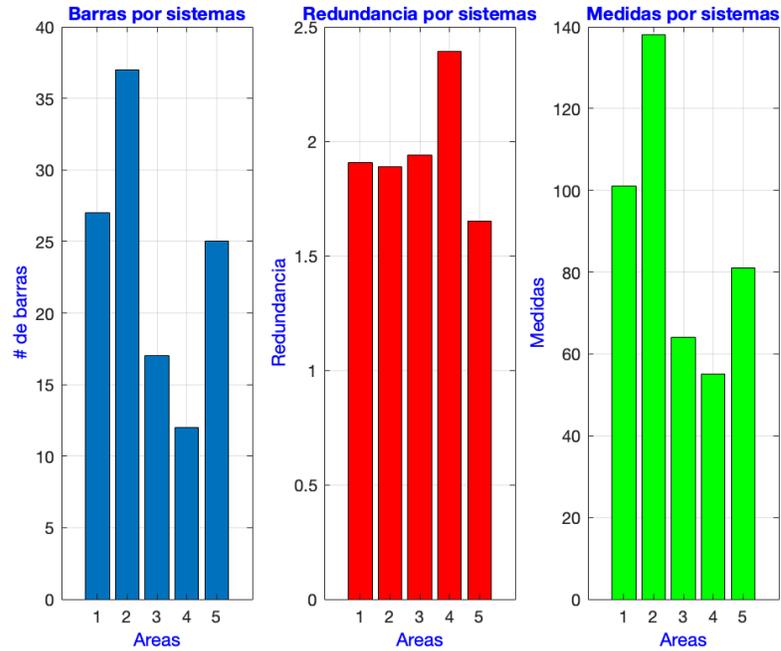


Figura 4.22: Barra Nodal 8 mediciones, cambio de configuración

En la Figura 4.23, se puede observar el resultado de los valores estimados de tensión para cada barra después de aplicar el proceso de estimación distribuida en esta nueva configuración.

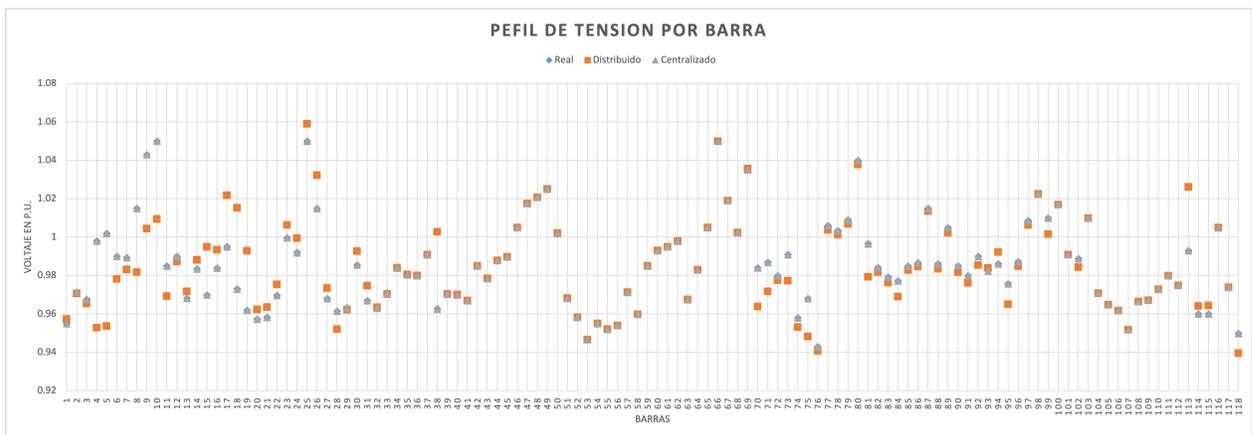


Figura 4.23: Perfil de Tensión Sistema IEEE118 barras - 439 mediciones

4.4. Comentarios Finales

En el capítulo de simulaciones, se aplicó una metodología de estimación de estado distribuida en el sistema de la IEEE 118 barras. Se realizaron particiones del sistema en función del número de mediciones en las barras nodales, utilizando una jerarquización de 9, 8 y 7

Tabla 4.16: Distribución de barras del Sistema BN8-5Areas

Area1	Area2	Area3	Area4	Area5
1	33	20	76	85
2	34	21	77	86
3	35	22	78	87
4	36	23	79	88
5	37	24	80	89
6	39	25	81	90
7	40	27	82	91
8	41	32	83	92
9	42	70	84	93
10	43	71	95	94
11	44	72	96	98
12	45	73	97	99
13	46	74		100
14	47	75		101
15	48	114		102
16	49	115		103
17	50	118		104
18	51			105
19	52			106
26	53			107
28	54			108
29	55			109
30	56			110
31	57			111
38	58			112
113	59			
117	60			
	61			
	62			
	63			
	64			
	65			
	66			
	67			
	68			
	69			
	116			

mediciones. Se presentaron los resultados de las particiones en tablas y figuras, mostrando la distribución de las medidas y la configuración de los subsistemas.

Se analizó el error cuadrático medio (MSE) en los casos simulados, observando una reducción en el MSE en los casos de particiones con mayor número de mediciones. Sin embargo, se notó que los tiempos de procesamiento aumentaron en los casos con mayor particionamiento

debido al mayor tamaño de los subsistemas.

Se evaluó la calidad de las mediciones utilizando el residual normalizado, con el objetivo de identificar mediciones erróneas. Se realizó un análisis de identificación de mediciones erróneas en un caso específico, agregando mediciones erróneas en barras seleccionadas. Se presentaron tablas y figuras que mostraron la distribución de medidas y la configuración del sistema después de la identificación de mediciones erróneas.

Finalmente, se evaluó nuevamente el estimador con las mediciones erróneas eliminadas, mostrando perfiles de tensión y comparando el error antes y después de la eliminación de mediciones erróneas. Se destacó que la configuración del sistema pudo cambiar debido a la eliminación de medidas, lo cual afectó el número de barras nodales y requirió una nueva estimación distribuida en subsistemas reconfigurados.

En resumen, las simulaciones realizadas demostraron la efectividad de la metodología de estimación de estado distribuida en el sistema de la IEEE 118 barras, mostrando mejoras en la precisión de los resultados y la capacidad de identificar y eliminar mediciones erróneas para garantizar la calidad de los resultados.

4.5. Discusión

La importancia de contar con información precisa y confiable, denota dentro de los procesos de estimación una correcta determinación de las variables de estado con el fin de que estos representen la información necesaria del sistema que se desea controlar.

En el caso particular de los sistemas eléctricos de potencia su valor de tensión y ángulo son las variables de estado que dan cuenta de como se encuentra operando el sistema y sobre los cuales a través de las decisiones del Operador garantizar la continuidad del mismo.

Como se ha tratado en los respectivos capítulos, por el gran volumen de información que se puede obtener de un sistema, resulta complejo su tratamiento y procesamiento, pues requieren de sistemas de captura costosos y elevados tiempos de procesamiento, a eso se le debe agregar la fiabilidad de las mediciones que son un problema no menor a considerar, ya que dentro de los modelos no lineales tienen una gran incidencia en los resultados y que pueden dar malas interpretaciones peor aun, una mala decisión en la operación siendo parte fundamental de estos procesos de estimación eliminar o en su defecto sustituir la información para validar el resultado.

El método propuesto de partición busca minimizar estos efectos a través de la métrica propuesta para la construcción de los subsistemas, comparada con el caso base y las técnicas en la literatura, se busca dentro del proceso mantener una redundancia homogénea para cada partición, sin embargo se debe tener presente que la distribución y estructura del sistema obedece a una localización física de las barras de acuerdo a su expansión o crecimiento, obligando a que esta métrica no se cumpla de manera eficiente para ciertos escenarios desarrollados.

Sin embargo en el mismo modelo planteado se ha considerado un proceso de jerarquización con el fin de alcanzar redundancias homogéneas de los subsistemas, proceso detallado,

aplicado y simulado en lo capítulos respectivos.

Capítulo 5

Conclusión

5.1. Conclusión

Dentro de la propuesta, se realiza una revisión de los objetivos planteados y su cumplimiento.

El primer objetivo planteado fue desarrollar un modelo para aplicar un proceso de agrupamiento dentro de un sistema eléctrico de potencia, procurando que en esta distribución de barras y mediciones, permita que la redundancia de cada subsistema sea homogéneo entre ellos. En el análisis de los resultados, se puede concluir que la metodología propuesta de particionamiento en un Sistema Eléctrico mejora los resultados dentro de un proceso de estimación de estado distribuido, esto se refleja en el valor del **MSE** obtenido en el proceso así como una mejora en el tiempo de procesamiento

El método de partición nodal constituye en una técnica valiosa en la estimación de estado de sistemas eléctricos de potencia. Permite dividir el sistema en subconjuntos más pequeños y manejables, lo que mejora la eficiencia computacional y acelera los cálculos de la estimación de estado. Al reducir la dimensionalidad del problema, se simplifica el análisis y se pueden obtener resultados más precisos al considerar las características y patrones específicos de cada subsistema, brindando resultados confiables para la toma de decisiones en tiempo real.

El método de partición nodal ofrece flexibilidad y adaptabilidad que sumado a la jerarquización permite que tanto en sistemas de tamaño moderado como a sistemas extremadamente grandes controlar el número de particiones, lo que lo hace adecuado para una amplia gama de aplicaciones y escenarios. Además, se pueden ajustar y modificar fácilmente para adaptarse a cambios en la topología del sistema o en las condiciones de operación. lo que conduce a estimaciones más confiables.

El establecer una jerarquización de la Barra Nodal, permite que el proceso se puede aplicar con la finalidad de ampliar la división del sistemas en áreas mas pequeñas, es importante acotar que este criterio determina el número de subsistemas que se pueden construir.

La jerarquización como tal resulta una estrategia, no solo para la determinación de las variables de estado sino también para la detección y eliminación de mediciones erróneas ya que es fundamental la validación del vector de estado en la operación y toma de decisiones desde la operación del sistema.

En resumen, el método propuesto de partición basado en agrupamiento nodal y la jerarquía de las barras nodales permite una mejor distribución de las medidas del sistema, reduciendo el tiempo de procesamiento y mejorando los resultados del MSE en la estimación de estado de un sistema eléctrico.

Si bien la literatura especializada trata la eliminación de mediciones erróneas y plantea varios métodos, no deja de ser relevante el tiempo de procesamiento de una estimación de estado distribuido en un **EPS**, incluyendo el método de detección de observabilidad, el método de detección de patrones y los métodos basados en técnicas de aprendizaje automático. Estos métodos son importantes para mejorar la precisión de la estimación de estado y garantizar la seguridad y confiabilidad de la red eléctrica.

5.2. Trabajo futuro

Del trabajo presentado siempre se espera expandir la aplicación desarrollada con la idea seguir mejorando y aplicando el método de partición nodal en la estimación de estado en sistemas eléctricos de potencia. Las posibles áreas de desarrollo como trabajo futuros son los que se describen a continuación:

Mejorar en la técnica de partición nodal considerando la dinámica de la demanda y su efectos en sistemas desequilibrados, la inserción de ERNC, la presencia de generación distribuida o la incorporación de dispositivos de almacenamiento de energía. Estos desarrollos podrían mejorar la precisión y eficiencia de la estimación de estado en sistemas eléctricos cada vez más complejos.

Integración de datos que permitan utilizar eficientemente los datos en tiempo real provenientes de sensores y dispositivos de medición avanzados, como PMUs, para actualizar de manera dinámica las particiones nodales y mejorar la precisión de la estimación de estado en tiempo real.

Verificar la eficacia y precisión de la partición nodal de estimadores dinámicos como el filtro de Kalman EKF aplicado a modelos no lineales (EKF) y el *Uncested* el cual considera en su transformación modelos bajo un concepto de linealización (UKF), donde los modelos realizan una predicción del estado.

A través de la jerarquización optimizar la ubicación de las barras nodales considerando un análisis de sensibilidad para identificar las áreas más críticas o con mayor impacto en la

estimación de estado, lo que permitiría optimizar la asignación de recursos computacionales y mejorar la eficiencia del método de partición nodal.

Explorar cómo abordar la estimación de estado en sistemas eléctricos que abarcan múltiples áreas particionadas. Lo que implica desarrollar técnicas de comunicación y coordinación entre las diferentes áreas para garantizar una estimación coherente y precisa del estado en todo el sistema.

Investigar la viabilidad y eficacia del método de partición nodal en aplicaciones de tiempo real, como la gestión de la operación y control en sistemas eléctricos de potencia. Esto implica la implementación de algoritmos y estrategias que permitan una estimación de estado rápida y confiable para respaldar la toma de decisiones en tiempo real.

Determinar la eficiencia del método propuesto en sistemas con alta penetración de ERNC, dado cuenta que la dinámica presente requiere de valores estimados precisos que permitan tomar acciones adecuadas en la operación del EPS.

Explorar métodos de estimación dinámica implica modelar el método de partición mediante el uso del Uncested Kalman Filter. Esta contribución permitirá enriquecer el estado del arte en el tema que aborda este trabajo, añadiendo una perspectiva específica sobre la aplicación de este filtro en el contexto del método de partición propuesto.

Si bien el estado de arte permite varias oportunidades de investigación y desarrollo para aplicar y mejorar el método de partición nodal en la estimación de estado de sistemas eléctricos de potencia. Estas investigaciones pueden conducir a avances significativos en la eficiencia, precisión y aplicabilidad de este método en el contexto de los sistemas eléctricos modernos.

Bibliografía

- [1] F C Schweppe and D B Rom. Power System Static-State Estimation, Part II: Approximate Model. *IEEE Transactions on Power Apparatus and Systems*, PAS-89(1):125–130, 1970.
- [2] Fred C Schweppe. Power System Static-State Estimation, Part III: Implementation. *IEEE Transactions on Power Apparatus and Systems*, PAS-89(1):130–135, 1970.
- [3] George N Korres and Nikolaos M Manousakis. State estimation and bad data processing for systems including PMU and SCADA measurements. *Electric Power Systems Research*, 81(7):1514–1524, June 2011.
- [4] S Mohagheghi, R H Alaileh, G J Cokkinides, and A P S Meliopoulos. Distributed state estimation based on the supercalibrator concept - laboratory implementation. In *2007 iREP Symposium Bulk Power System Dynamics and Control - VII. Revitalizing Operational Reliability*, pages 1–9, 2007.
- [5] Medine Çolak and Erdal Irmak. A State-of-the-Art Review on Electric Power Systems and Digital Transformation. *Electric Power Components and Systems*, 51(11):1089–1112, 2023.
- [6] G N Korres. A Distributed Multiarea State Estimation. *IEEE Transactions on Power Systems*, 26(1):73–84, 2011.
- [7] Eduardo Caro, Roberto Mínguez, and Antonio J Conejo. Robust WLS estimator using reweighting techniques for electric energy systems. *Electric Power Systems Research*, 104(0):9–17, June 2013.
- [8] Fabio Pasqualetti, Ruggero Carli, and Francesco Bullo. A distributed method for state estimation and false data detection in power networks. In *2011 IEEE International Conference on Smart Grid Communications, SmartGridComm 2011*, pages 469–474, 2011.
- [9] Antonio Gómez Expósito Ali Abur. *Electric Power System State Estimation. Theory and Implementations*. Marcel Dekker, New York, NY, 2004.
- [10] George N Korres, Anastasios Tzavellas, and Evangelos Galinas. A distributed implementation of multi-area power system state estimation on a cluster of computers. *Electric Power Systems Research*, 102:20–32, June 2013.
- [11] Md Jakir Hossain and Mia Naeini. Multi-Area Distributed State Estimation in Smart Grids Using Data-Driven Kalman Filters. *Energies*, 15(19), Oct 2022.

- [12] Valeriu Iulian Presada, Cristian Virgil Cristea, Mircea Eremia, and Lucian Toma. State estimation in power systems with FACTS devices and PMU measurements. In *Proceedings of the Universities Power Engineering Conference*, pages 1–5, 2014.
- [13] Junbo Zhao, Marcos Netto, Zhenyu Huang, Samson Shenglong Yu, Antonio Gomez-Exposito, Shaobu Wang, Innocent Kamwa, Shahrokh Akhlaghi, Lamine Mili, Vladimir Terzija, A P.Sakis Meliopoulos, Bikash Pal, Abhinav Kumar Singh, Ali Abur, Tianshu Bi, and Alireza Rouhani. Roles of dynamic state estimation in power system modeling, monitoring and operation. *IEEE Transactions on Power Systems*, 36(3):2462–2472, 2021.
- [14] Eduardo Caro, Ignacio Arévalo, Carolina García-Martos, and Antonio J. Conejo. Power system observability via optimization. *Electric Power Systems Research*, 104:207–215, Nov 2013.
- [15] Kalyan Dasgupta and K.S. Swarup. Tie-line constrained distributed state estimation. *International Journal of Electrical Power Energy Systems*, 33(3):569–576, Mar 2011.
- [16] Fred C Schweppe and Edmund J Handschin. Static State Estimation in Electric Power Systems. *Proceedings of the IEEE*, 62(7):972–982, 1974.
- [17] F C Schweppe, J Kohlas, and A Fiechter. Bad data analysis for power system state estimation. *IEEE Transactions on Power Apparatus and Systems*, 94(2):329–337, 1975.
- [18] Freek Baalbergen, Madeleine Gibescu, and Lou Der Van Sluis. Modern state estimation methods in power systems. In *2009 IEEE/PES Power Systems Conference and Exposition, PSCE 2009*, pages 1–6, 2009.
- [19] A M Glazunova, I N Kolosok, and E S Korkina. Monitoring of EPS operation by the state estimation methods. In *IEEE PES Innovative Smart Grid Technologies Conference Europe*, pages 1–6, 2011.
- [20] I N Kolosok, E S Korkina, and A S Paltsev. Bad data detection at decomposition of state estimation problem. In *2011 IEEE PES Trondheim PowerTech: The Power of Technology for a Sustainable Society, POWERTECH 2011*, pages 1–6, 2011.
- [21] Hao Hu. Application of Parity Mismatches on Detection of Bad Data in Power System State Estimation. *Procedia Engineering*, 15(0):536–540, 2011.
- [22] Tengpeng Chen, Yi Shyh Eddy Foo, K V Ling, and Xuebing Chen. Distributed state estimation using a modified partitioned moving horizon strategy for power systems. *Sensors (Switzerland)*, 17(10), June 2017.
- [23] Amit Jain and N R Shivakumar. Impact of pmu in dynamic state estimation of power systems. In *40th North American Power Symposium, NAPS2008*, pages 1–8, 2008.
- [24] Bruce F Wollenberg Wood Allen J. *Power, Generation, Operation, and Control*. John Wiley Sons, Inc, 1996.
- [25] Milton Brown Do Coutto Filho and Julio Cesar Stacchini de Souza. Forecasting-aided state estimation - Part I: Panorama. *IEEE Transactions on Power Systems*, 24(4):1667–1677, 2009.

- [26] Milton Brown Do Coutto Filho, Julio Cesar Stacchini de Souza, and Ronaldo Sérgio Freund. Forecasting-aided state estimation - Part II: Implementation. *IEEE Transactions on Power Systems*, 24(4):1678–1685, 2009.
- [27] Jeu Min Lin and Heng Yau Pan. A static state estimation approach including bad data detection and identification in power systems. In *2007 IEEE Power Engineering Society General Meeting, PES*, pages 1–7, 2007.
- [28] Wei Hu, Yong Min, and Yun Yang. Projected unscented Kalman filter for dynamic state estimation and bad data detection in power system. In *12th IET International Conference on Developments in Power System Protection (DPSP 2014)*, pages 12.30–12.30. Institution of Engineering and Technology, 2014.
- [29] Nurul Fauzana Imran Gulcharan, Nursyarizal Mohd Nor, Taib Ibrahim, and Hanita Daud. Power system state estimation bad data detection and identification: A review on issues and alternative formulations. *Indonesian Journal of Electrical Engineering and Computer Science*, 8(1):122–128, Oct 2017.
- [30] Aleksandar Jovicic and Gabriela Hug. Linear state estimation and bad data detection for power systems with RTU and PMU measurements. *IET Generation, Transmission and Distribution*, 14(23):5675–5684, Dec 2020.
- [31] R Martinez-Parrales and C R Fuerte-Esquivel. Noise estimation in measurements to improve the state estimation of electric power systems. In *2019 16th International Conference on Electrical Engineering, Computing Science and Automatic Control, CCE 2019*, pages 1–5, 2019.
- [32] N G Bretas and A S Bretas. Bad data analysis using the composed measurements errors for power system state estimation. In *2010 iREP Symposium Bulk Power System Dynamics and Control (iREP) - VIII (iREP)*, pages 1–7, 2010.
- [33] Ahmad Salehi Dobakhshari, Vladimir Terzija, and Sadegh Azizi. Normalized Deleted Residual Test for Identifying Interacting Bad Data in Power System State Estimation. *IEEE Transactions on Power Systems*, 37(5):4006–4016, June 2022.
- [34] N G Bretas, M R M Castillo, and J B A London. The innovation concept for parameter error identification and correction using the composed measurements errors in power system state estimation. In *2012 IEEE Power and Energy Society General Meeting*, pages 1–7, 2012.
- [35] G.P. Granelli and M. Montagna. Identification of interacting bad data in the framework of the weighted least square method. *Electric Power Systems Research*, 78(5):806–814, May 2008.
- [36] Yunhui Wu, A Onwuachumba, and M Musavi. Bad Data Detection and Identification Using Neural Network-Based Reduced Model State Estimator. In *2013 IEEE Green Technologies Conference*,, pages 183–189, 2013.
- [37] R. A.S. S Benedito, L. F.C. C Alberto, N G Bretas, and J. B.A. A London. Application of the undetectability index to design reliable metering systems for bad data processing. In *IEEE Power and Energy Society General Meeting*, pages 1–5, 2013.

- [38] A Z Gamm, I N Kolosok, A M Glazunova, and E S Korkina. PMU placement criteria for EPS state estimation. In *3rd International Conference on Deregulation and Restructuring and Power Technologies, DRPT 2008*, pages 645–649, 2008.
- [39] A Abur and M K Celik. Least absolute value state estimation with equality and inequality constraints. *IEEE Transactions on Power Systems*, 8(2):680–686, 1993.
- [40] Soliman Abdel-hady Soliman and Ahmad M. Al-Kandari. Electrical Load Forecasting. In *Electrical Load Forecasting*, pages 45–78. Elsevier, 2010.
- [41] Alan Louis, Gerard Ledwich, Geoff Walker, and Yateendra Mishra. Measurement Sensitivity and Estimation Error in Distribution System State Estimation using Augmented Complex Kalman Filter. *Journal of Modern Power Systems and Clean Energy*, 8(4):657–668, 2020.
- [42] Fang Chen, Xueshan Han, Zhiyuan Pan, and Li Han. State estimation model and algorithm including PMU. In *3rd International Conference on Deregulation and Restructuring and Power Technologies, DRPT 2008*, pages 1097–1102, 2008.
- [43] Qinghua Huang, Noel N Schulz, Anurag K Srivastava, and Tomasz Haupt. Distributed state estimation with PMU using grid computing. In *2009 IEEE Power and Energy Society General Meeting, PES '09*, pages 1–7, 2009.
- [44] G Rigatos and P Siano. Distributed state estimation for condition monitoring of nonlinear electric power systems. In *Proceedings - ISIE 2011: 2011 IEEE International Symposium on Industrial Electronics*, pages 1703–1708, 2011.
- [45] Ting Liu, Yun Gu, Dai Wang, Yuhong Gui, and Xiaohong Guan. A novel method to detect bad data injection attack in smart grid. In *2013 IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS)*, pages 49–54, 2013.
- [46] Ravindra Kumar and Dinanath Prasad. Effect of bad measurements on state estimation in power system. In *2012 IEEE 5th Power India Conference, PICONF 2012*, pages 1–5, 2012.
- [47] Dongliang Duan, Liuqing Yang, and L L Scharf. Phasor state estimation from PMU measurements with bad data. In *2011 4th IEEE International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP)*, pages 121–124, 2011.
- [48] E Farantatos, G K Stefopoulos, G J Cokkinides, and A P Meliopoulos. PMU-based dynamic state estimation for electric power systems. In *PES '09. IEEE Power Energy Society General Meeting, 2009.*, pages 1–8, 2009.
- [49] Sandeep Soni, Sudhir Bhil, Dharendra Mehta, and Sushama Wagh. Linear state estimation model using phasor measurement unit (PMU) technology. In *CCE 2012 - 2012 9th International Conference on Electrical Engineering, Computing Science and Automatic Control*, pages 1–6, 2012.
- [50] J Zhang, G Welch, G Bishop, and Z Huang. A Two-Stage Kalman Filter Approach for Robust and Real-Time Power System State Estimation. *IEEE Transactions on Power Systems*, 5(2):629–636, 2014.

- [51] Bráulio César de Oliveira, Igor D Melo, and Matheus A Souza. Bad data detection, identification and correction in distribution system state estimation based on PMUs. *Electrical Engineering*, 104(3):1573–1589, 2022.
- [52] Zhi Gang Lu, Jing Zhang, Tao Feng, and Hui Lin Cheng. Distributed agent-based state estimation considering controlled coordination layer. *International Journal of Electrical Power and Energy Systems*, 54:569–575, June 2014.
- [53] Yafei Yang, Xiaohong Guan, Yuxun Zhou, Jiang Wu, and Ting Liu. Impact of information security on PMU-based distributed state estimation, 2012.
- [54] Antonio Gómez-Expósito, Antonio De La Villa Jaén, Catalina Gómez-Quiles, Patricia Rousseaux, and Thierry Van Cutsem. A taxonomy of multi-area state estimation methods. *Electric Power Systems Research*, 81(4):1060–1069, June 2011.
- [55] V Kekatos and G B Giannakis. Distributed Robust Power System State Estimation. *IEEE Transactions on Power Systems*, 28(2):1617–1626, 2013.
- [56] Mohammad Gholami, Ali Abbaspour Tehrani-Fard, Matti Lehtonen, Moein Moeini-Aghtaie, and Mahmud Fotuhi-Firuzabad. A novel multi-area distribution state estimation approach for active networks. *Energies*, 14(6), June 2021.
- [57] Junbo Zhao, Antonio Gómez-Expósito, Marcos Netto, Lamine Mili, Ali Abur, Vladimir Terzija, Innocent Kamwa, Bikash Pal, Abhinav Kumar Singh, Junjian Qi, Zhenyu Huang, and A P.Sakis Meliopoulos. Power System Dynamic State Estimation: Motivations, Definitions, Methodologies, and Future Work. *IEEE Transactions on Power Systems*, 34(4):3188–3198, June 2019.
- [58] Eduardo Caro, Antonio J Conejo, and Ali Abur. Breaker status identification. *IEEE Transactions on Power Systems*, 25(2):694–702, 2010.
- [59] Liuxi Zhang and Ali Abur. Identifying parameter errors via multiple measurement scans. *IEEE Transactions on Power Systems*, 28(4):3916–3923, 2013.
- [60] Jian Chen and A Abur. Placement of PMUs to Enable Bad Data Detection in State Estimation. *IEEE Transactions on Power Systems*, 21(4):1608–1615, 2006.
- [61] Jian Ma, Yousu Chen, Zhenyu Huang, and Pak Chung Wong. Using state estimation residuals to detect abnormal SCADA data. In *2010 IEEE PES Transmission and Distribution Conference and Exposition: Smart Solutions for a Changing World*, pages 1–7, 2010.
- [62] Sayed Ahmed Nagy, S A Nagy, Y Rihan, I S Ibrahim, and A S Adail. Observability Analysis and multi Bad Data Processing Using Phasor Measurements Units in Power System State Estimation, 2014.
- [63] Zhengnan Gao, Shubo Hu, Hui Sun, Jinsong Liu, Yuanqing Zhi, and Jun Li. Dynamic State Estimation of New Energy Power Systems Considering Multi-Level False Data Identification Based on LSTM-CNN. *IEEE Access*, 9:142411–142424, 2021.

- [64] Dae-Hyun Choi and Le Xie. Fully distributed bad data processing for wide area state estimation. In *2011 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, pages 546–551, 2011.
- [65] A Monticelli, F F Wu, and Maosong Yen. Mutiple Bad Data Identwication for State Estimation by Combinatorial Oftimization. *IEEE Transactions on Power Delivery*, 1(3):361–369, 1986.
- [66] A Tarali and A Abur. Bad data detection in two-stage state estimation using phasor measurements. In *2012 3rd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies (ISGT Europe)*,, pages 1–8, 2012.
- [67] June Ho Park Hee-Myung Jeong. Multiple Bad Data Processing using Binary PSO Algorithm Based on PC Cluster System. *International Journal of Database Theory and Application*, Volumen 5,:11–22, 2012.
- [68] Krish Narendra and Tony Weekes. Phasor Measurement Unit (PMU) Communication Experience in a Utility Environment. *CIGRE*, pages 1–7, 2008.
- [69] Jun Zhu and Ali Abur. Bad data identification when using phasor measurements. In *2007 IEEE Lausanne POWERTECH, Proceedings*, pages 1676–1681, 2007.
- [70] A P S Meliopoulos, G J Cokkinides, F Galvan, B Fardanesh, and P Myrda. Advances in the SuperCalibrator Concept - Practical Implementations. In *40th Annual Hawaii International Conference on System Sciences, 2007. HICSS 2007.*, page 118, 2007.
- [71] A Monticelli. Electric power system state estimation. In *Proceedings of the IEEE*, volume 88, pages 262–282, June 2000.
- [72] Antonio Gomez-Exposito, Ali Abur, Antonio De La Villa Jaen, and Catalina Gomez-Quiles. A multilevel state estimation paradigm for smart grids. In *Proceedings of the IEEE*, volume 99, pages 952–976, 2011.
- [73] James V Candy. *Bayesian Signal Processing: Classical, Modern and Particle Filtering Methods*. WILEY, 2011.
- [74] A M Leite da Silva, M B Do Coutto Filho, and J M C Cantera. An Efficient Dynamic State Estimation Algorithm Including Bad Data Processing. *IEEE Power Engineering Review*,, PER-7(11):49, 1987.
- [75] A M Leite da Silva, M B Do Coutto Filho, and J F De Queiroz. State forecasting in electric power systems. *Generation, Transmission and Distribution, IEE Proceedings C*, 130(5):237–244, 1983.
- [76] K Nishiya, J Hasegawa, M Eng, Prof T Koike, and D Eng. Dynamic state estimation including anomaly detection and identification for power systems, 1982.
- [77] G Durgaprasad and S S Thakur. Robust dynamic state estimation of power systems based on M-estimation and realistic modeling of system dynamics. *IEEE Transactions on Power Systems*, 13(4):1331–1336, 1998.

- [78] Jaratsri Khwanram and Parnjit Damrongkulkamjorn. Multiple bad data identification in power system state estimation using particle swarm optimization. In *2009 6th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, volume 01, pages 2–5. IEEE, May 2009.
- [79] Eduardo Caro, Antonio J Conejo, Roberto Mínguez, Marija Zima, and Göran Andersson. Multiple bad data identification considering measurement dependencies. *IEEE Transactions on Power Systems*, 26(4):1953–1961, 2011.
- [80] Yih Fang Huang, Stefan Werner, Jing Huang, Neelabh Kashyap, and Vijay Gupta. State estimation in electric power grids: Meeting new challenges presented by the requirements of the future grid. *IEEE Signal Processing Magazine*, 29(5):33–43, 2012.
- [81] G Valverde and V Terzija. Unscented kalman filter for power system dynamic state estimation. *Generation, Transmission Distribution, IET*, 5(1):29–37, 2011.
- [82] Xusheng Luo, Miroslav Pajic, and Michael M Zavlanos. An optimal graph-search method for secure state estimation. *Automatica*, 123:109323, 2021.
- [83] Muhammad Musadiq Ahmed, Muhammad Amjad, Muhammad Ali Qureshi, Kashif Imran, Zunaib Maqsood Haider, and Muhammad Omer Khan. A Critical Review of State-of-the-Art Optimal PMU Placement Techniques. *Energies*, 15(6), Mar 2022.
- [84] K D Jones, J S Thorp, and R M Gardner. Three-phase linear state estimation using Phasor Measurements. In *2013 IEEE Power and Energy Society General Meeting (PES)*,, pages 1–5, 2013.
- [85] G M Mathews. An optimal hierarchical algorithm for factored nonlinear weighted least squares state estimation. In *2012 3rd IEEE PES International Conference and Exhibition on Innovative Smart Grid Technologies (ISGT Europe)*,, pages 1–6, 2012.
- [86] Yuqi Zhou and Le Xie. Detection of bad data in multi-area state estimation. In *2017 IEEE Texas Power and Energy Conference, TPEC 2017*. Institute of Electrical and Electronics Engineers Inc., Mar 2017.
- [87] Murat Göl and Ali Abur. PMU based robust state estimation using scaling. In *2012 North American Power Symposium, NAPS 2012*, pages 1–5, 2012.
- [88] Pengwei Du, Zhenyu Huang, Yannan Sun, Ruisheng Diao, K Kalsi, K K Anderson, Yulan Li, and B Lee. Distributed dynamic state estimation with extended Kalman filter. In *2011 North American Power Symposium (NAPS)*, pages 1–6, 2011.
- [89] Basil Angel and Maharajan Duraisamy. Dynamic State Estimation of Electric Power Systems Using Kalman Filtering Techniques. *Journal of Physics: Conference Series*, 2335(1):012053, Sep 2022.
- [90] E A Blood, B H Krogh, and M. D. Ilić. Electric power system static state estimation through Kalman filtering and load forecasting. In *IEEE Power and Energy Society 2008 General Meeting: Conversion and Delivery of Electrical Energy in the 21st Century, PES*, pages 1–6, 2008.

- [91] Xin Wang. Power Systems Dynamic State Estimation with the Two-Step Fault Tolerant Extended Kalman Filtering. *IEEE Access*, 9:137211–137223, 2021.
- [92] Saman A Zonouz and William H Sanders. A Kalman-based coordination for hierarchical state estimation: Algorithm and analysis. In *Proceedings of the Annual Hawaii International Conference on System Sciences*, page 187, 2008.
- [93] Holger Ignacio Cevallos Ulloa, Gabriel Intriago, Douglas Plaza, Roger Idrovo, Holger Ignacio Cevallos Ulloa, Gabriel Intriago, Douglas Plaza, and Roger Idrovo. The Extended Kalman Filter in the Dynamic State Estimation of Electrical Power Systems. *Enfoque UTE*, 9(4 SE -):pp. 120 – 130, Dec 2018.
- [94] Simon J Julier and Jeffrey K Uhlmann. Unscented filtering and nonlinear estimation. *Proceedings of the IEEE*, 92(3):401–422, 2004.
- [95] M Murata, I Kawano, and K Inoue. Extended, Unscented Kalman, and Sigma Point Multiple Distribution Estimation Filters for Nonlinear Discrete State-Space Models. *IEEE Control Systems Letters*, 4(4):982–987, 2020.
- [96] S Sarkka. On Unscented Kalman Filtering for State Estimation of Continuous-Time Nonlinear Systems. *IEEE Transactions on Automatic Control*, 52(9):1631–1641, 2007.
- [97] E Cotilla-Sanchez, P D H Hines, C Barrows, S Blumsack, and M Patel. Multi-Attribute Partitioning of Power Networks Based on Electrical Distance, 2013.
- [98] Ali Reza Abbasi and Ali Reza Seifi. A new coordinated approach to state estimation in integrated power systems. *International Journal of Electrical Power Energy Systems*, 45(1):152–158, Feb 2013.
- [99] S Blumsack, P Hines, M Patel, C Barrows, and E C Sanchez. Defining power network zones from measures of electrical distance. In *2009 IEEE Power Energy Society General Meeting*, pages 1–8, 2009.
- [100] Reza Ebrahimian and Ross Baldick. State estimation distributed processing. *IEEE Transactions on Power Systems*, 15(4):1240–1246, 2000.
- [101] Hasan Mehrjerdi, Serge Lefebvre, Dalal Asber, and Maarouf Saad. Graph partitioning of power network for emergency voltage control. In *2013 9th Asian Control Conference, ASCC 2013*, pages 1–6. IEEE, June 2013.
- [102] S.-Y. Bin and C.-H. Lin. An implementable distributed state estimator and distributed bad data processing schemes for electric power systems. *IEEE Transactions on Power Systems*, 9(3):1277–1284, 1994.
- [103] Nikolaos M Manousakis and George N Korres. Application of state estimation in distribution systems with embedded microgrids. *Energies*, 14(23), June 2021.
- [104] Yun Sung Cho and Yun Hyuk Choi. Methodology for implementing the state estimation in renewable energy management systems. *Energies*, 14(8), Apr 2021.

- [105] Ingabire Erica, Saulo Michael, and Abungu Nicodemus. Dynamic state estimation of a power system network with wind energy integration using ensemble Kalman filter. *International Journal of Engineering Research and Technology*, 11(7):1109–1118, 2018.
- [106] Xu Zhang, Wei Yan, Zhengmei Lu, Hong Tan, and Hui Li. Bad data identification for power systems state estimation based on data-driven and interval analysis. *Electric Power Systems Research*, 217, Apr 2023.
- [107] Mehdi Ganjkhani, Seyedeh Narjes Fallah, Sobhan Badakhshan, Shahaboddin Shamshirband, and Kwok wing Chau. A novel detection algorithm to identify false data injection attacks on power system state estimation. *Energies*, 12(11), June 2019.
- [108] Luis Vargas and Henry Moyano. A Novel Multi-Area Distribution State Estimation Approach with Nodal Redundancy. *Energies*, 16(10):4138, June 2023.
- [109] Th Van Cutsem, J L Horward, and M Ribbens-Pavella. A two-level static state estimator for electric power systems. *IEEE Transactions on Power Apparatus and Systems*, PAS-100(8):3722–3732, 1981.
- [110] Karthikeyan Balasubramaniam, Abdlnam Abdrahem, Ramtin Hadidi, and Elham B Makram. Balanced, non-contiguous partitioning of power systems considering operational constraints. *Electric Power Systems Research*, 140:456–463, 2016.
- [111] Yi Lu, Chen Yuan, Xiang Zhang, Hua Huang, Guangyi Liu, Renchang Dai, and Zhiwei Wang. Graph computing based distributed state estimation with PMUs. In *IEEE Power and Energy Society General Meeting*, volume 2020-Augus, 2020.
- [112] Rich Christie. Power Systems Test Case IEEE 14, 1993.
- [113] Rich Christie. Power Systems Test Case Archive IEEE 118, 1993.
- [114] Mehrdad Tarafdar Hagh, Seyyed Mehdi Mahaei, and Kazem Zare. Improving Bad Data Detection in State Estimation of Power Systems. *International Journal of Electrical and Computer Engineering (IJECE)*, 1(2):85–92, 2011.

ANEXO

Anexo A

Programa Partición

```
uno=1;

num=[sum(NVA) sum(NInyPA) sum(NflujoPA) sum(NInyPA) sum(NflujoPA)];
MedV_P_Q=[refV_PQ(:,1) NVA' NInyPA' NInyPA'];

MedP_Q_ij=[refF_PQ(:,4:5) NflujoPA' NflujoPA'];
linea=MedP_Q_ij(:,1:2);
for i=1:nbarras
    for j=1:nbarras
        if mat_Y(i,j)==0
            else
                mat_G(i,j)=1;
        end
    end

%----division de subsistemas matriz base de medidas
med_barraF=zeros(1,nbarras);
for i=1:nbarras
    n_enl(i)=sum(mat_G(i,:))-1;
    med_barraV(i)=sum(MedV_P_Q(i,2:4));
    aux=0;
    for j=1:nlineas
        if MedV_P_Q(i,1)==MedP_Q_ij(j,1)
            aux=aux+sum(MedP_Q_ij(j,3:4));
        end
    end
    med_barraF(i)=aux;
end
%mediciones asociadas a cada nodo del sistema
med_barras=med_barraV+med_barraF;

max_med=max(med_barras);
max_med=casografo;
ib=0;
clear 'barra'
for i=1:nbarras
    if max_med==med_barras(i)
        ib=ib+1;
    end
%numero de areas a considerar bajo el criterio de BN de medidas
    barra(ib)=i;
    e_barra(ib)=sum(mat_G(i,:))-1;
end
RN=sum(med_barras)/(2*nbarras-1);

%Subrutina Particion
[Area,nb, rn, med]=funbarras118(barra,ib,mat_G,nbarras,med_barras,linea);
Nodos=1:1:nbarras;

for i=1:ib
    Areab(:,i)=Area(:,i).*Nodos';
end
for j=1:length(nb)
    for i=1:nbarras
        if Area(i,j)>0
            Area(i,j)=1;
        end
    end
end
bA=nb;
```

```

%define lineas en el cluster from-to
    AreaL=zeros(nlineas,2*length(nb));
%define elementos de medida de flujos de potencia en el cluster
    fArea=zeros(nlineas,length(nb));
NA=length(nb);
for areas=1:length(nb)%NA
    for i=1:nbarras
        contar=histc(refF_PQ(:,2),Areab(i,areas));
    if contar>=1
        for j=1:nlineas
            if refF_PQ(j,2)==Areab(i,areas)
                for k=1:nbarras
                    if refF_PQ(j,3)==Areab(k,areas)
                        AreaL(j,2*areas-1:2*areas)=refF_PQ(j,2:3);
                        fArea(j,areas)=1;
                    end
                end
            end
        end
    end
end

k=1;
for i=1:nlineas
    if sum(fArea(i,:))==0
        flujoC(i,1)=1;
    else
        flujoC(i,1)=0;
    end
end

%Constuccion de vector de nodos
for i=1:nlineas
    if flujoC(i,1)==1
        refcont(i,:)=refF_PQ(i,2:3);
    end
end
cont=intersect(1:1:nbarras,refcont);
contm=zeros(nbarras,1);
for k=1:length(cont)
    for i=1:nbarras
        if cont(k)==i
            %vector de medidas de tension e inyeccion a considerar
            contm(i)=1;
            break
        end
    end
end
for i=1:length(nb)
    %conjunto de medidas de la Area Si asociadas a la barra frontera de Si
    Xa(:,i)=[Area(:,i).*contm;Area(:,i).*contm];
end
Xb=[contm;contm];

```

Anexo B

Métodos de Detección de errores

En este anexo se presenta el fundamento matemático de las pruebas para la detección de errores desarrollado en [79, 114]

B.1. Método de Chi Cuadrado Prueba de Distribución

Si C_i es una variable aleatoria que representa un Φ de variables aleatorias independientes, tales como S que presenta una distribución de probabilidad en el tiempo, entonces se puede definir otra variable aleatoria U a través de la siguiente expresión

$$U_k = \sum_{i=1}^k C_i^2 \quad (\text{B.1})$$

Por lo tanto U tendrá una distribución C_2 con k grados de libertad

$$U_k \sim C_k^2 \quad (\text{B.2})$$

Evaluando U_k para una probabilidad de $P_r(U_k)=0.05$, $P_r(U_k)=0.01$ y $k = 1$ a $k = 30$ los resultados se dan en una tabla, para $k > 30$ U tiene una distribución normal, en los **EPS** c_i se define como

$$C_i = \frac{Z_i - h_i(\hat{x})}{\sigma_i} \quad (\text{B.3})$$

$$U = J(\hat{x}) \quad (\text{B.4})$$

$$k = 2n - 1 - m \quad (\text{B.5})$$

Para la identificación de las mediciones erróneas, se aplican lo siguientes pasos:

1. Seleccionar la probabilidad dada para la distribución chi-cuadrado $J(x)$ con grados de libertad k .
2. Calcular el valor crítico $J_c(x)$ con sus grados de libertad k y con una probabilidad de 0.05 a partir de la tabla de la distribución chi-cuadrado.
3. Si el resultado de $J(x)$ a partir de la estimación es mayor que $J_c(x)$ ($J(x) > J_c(x)$), implica la presencia de mediciones erróneas.
4. Este método detecta la presencia de mediciones erróneas mas no detecta cual es la medición errónea .

B.2. Método del Gran residual LNR

Finalizado el proceso de estimación de estado y evaluado del vector de estado se aplica el LNR, para lo cual consideremos:

$$H = \left. \frac{\partial h(\hat{x})}{\partial x} \right|_{\hat{x}} = \hat{x}_s \quad (\text{B.6})$$

Linealizando el modelo este se puede escribir como

$$z = Hx + e \quad (\text{B.7})$$

El residual estimado del vector puede ser escrito como

$$r = Sz = S[Hx + e] \quad (\text{B.8})$$

Donde

$$S = I - HG^{-1}H^TW \quad (\text{B.9})$$

De la ecuación B.3 en su desarrollo $SHx = 0$, por lo tanto la misma se puede reformular como:

$$r = Se \quad (\text{B.10})$$

Para normalizar las mediciones residuales se utiliza la matriz de covarianza de la medición de la siguiente manera:

$$r^n = (\text{diag}(R_r))^{0,5} r \quad (\text{B.11})$$

siendo R_r el resultado de $R_r = SR_z^{-1}$

El proceso para identificar errores a través del método de $r_{\text{máx}}^N$ es:

1. Estimación de Estado
2. Obtener la matriz de sensibilidad S .
3. calcular el vector del residual r
4. Determinar el vector del residual normalizado r^n , si $r_i^n > C$, resulta que z_i es una medida errónea.
5. Eliminar la medición errónea y aplicar una nueva estimación del sistema.