



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Laís de Oliveira Dalle Mulle

**Processamento de Erros Grosseiros para Estimadores de Estados Híbridos
Baseados na Arquitetura de Fusão de Estimativas**

Florianópolis
2023

Laís de Oliveira Dalle Mulle

**Processamento de Erros Grosseiros para Estimadores de Estados Híbridos
Baseados na Arquitetura de Fusão de Estimativas**

Dissertação submetida ao Programa de Pós-Graduação
em Engenharia Elétrica da Universidade Federal de
Santa Catarina para a obtenção do título de mestre
em Engenharia Elétrica.

Orientador: Prof. Antonio José Alves Simões Costa,
Ph.D

Florianópolis

2023

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Dalle Mulle, Laís de Oliveira
Processamento de Erros Grosseiros para Estimadores de
Estados Híbridos Baseados na Arquitetura de Fusão de
Estimativas / Laís de Oliveira Dalle Mulle ; orientador,
Antonio José Alves Simões Costa, 2023.
112 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Engenharia Elétrica, Florianópolis, 2023.

Inclui referências.

1. Engenharia Elétrica. 2. Estimação Híbrida de Estados
em Sistemas de Potência. 3. Processamento de Erros
Grosseiros. 4. Fusão de Estimativas. 5. Medidas Fasoriais
Sincronizadas. I. Simões Costa, Antonio José Alves. II.
Universidade Federal de Santa Catarina. Programa de Pós
Graduação em Engenharia Elétrica. III. Título.

Laís de Oliveira Dalle Mulle

**Processamento de Erros Grosseiros para Estimadores de Estados Híbridos
Baseados na Arquitetura de Fusão de Estimativas**

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca
examinadora composta pelos seguintes membros:

Prof. Diego Issicaba, Dr.
Universidade Federal de Santa Catarina

Prof. Leonardo Elizeire Bremermann, Dr.
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi
julgado adequado para obtenção do título de mestre em Engenharia Elétrica.

Prof. Telles Brunelli Lazzarin, Dr.
Coordenação do Programa de
Pós-Graduação

Prof. Antonio José Alves Simões Costa,
Ph.D
Orientador

Florianópolis, 2023.

Este trabalho é dedicado a todos que estiveram ao meu
lado durante esta jornada.

AGRADECIMENTOS

Primeiramente, agradeço à Universidade Federal de Santa Catarina (UFSC) e ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEEL), por seu compromisso com a excelência acadêmica.

Também gostaria de expressar minha gratidão ao meu orientador, Professor Dr. Antonio José Alves Simões Costa, pelo apoio, confiança e sabedoria prestados durante esta pesquisa. Agradeço por investir seu tempo e esforço em me ajudar a crescer academicamente e profissionalmente.

Aos meus pais, Iêda Maria e José Cássio, que estiveram ao meu lado durante toda essa caminhada, me apoiando, incentivando e acreditando em mim. Sou imensamente grata por tudo o que fizeram por mim. À Maria Teresa Silva Santos, minha parceira de vida, que me incentiva e inspira a cada dia. E é com quem compartilho os desafios, as alegrias e as conquistas.

Agradeço aos meus colegas do Laboratório de Sistemas de Potência (LabSpot), em especial Edson Zanlorensi Junior e Larah Brüning Ascari pelo auxílio durante este trabalho. Ao Eng. Julio Oliveira da Silva pelas horas de estudo e parceria que tivemos ao longo desta trajetória.

Por fim, agradeço a Deus por me dar saúde e iluminar meu caminho.

“Nunca permita que a imaginação limitada dos outros limite você.”
(Mae Jemison)

RESUMO

A estimação de estados em sistemas de potência é uma ferramenta utilizada para a operação segura e eficiente das redes de energia, cuja importância reside na sua capacidade de fornecer informações confiáveis e atualizadas sobre a condição operacional da rede. Um aspecto essencial da estimação de estados é o processamento eficiente de erros grosseiros. A utilização de medidores sincrofasoriais no sistema de potência permitiu o desenvolvimento da estimação híbrida de estados, sendo o método de fusão de estimativas uma abordagem particularmente promissora. No entanto, com o aumento da dimensão das redes elétricas enfrenta-se um problema substancial no processamento de erros grosseiros. A causa deste problema reside na diminuição da sensibilidade do teste- $J(\hat{x})$ com o aumento da dimensão da rede elétrica. Uma solução recentemente proposta para este problema é o particionamento do plano de medição, induzindo a partição da rede em *clusters* de dimensão reduzida. A proposta desta dissertação é ampliar a estratégia de particionamento da rede para aplicação no módulo de processamento de medidas sincrofasoriais de arquiteturas híbridas de fusão de estimativas. A implementação dessa estratégia no contexto da fusão é discutida e sua eficácia é avaliada por meio de sistemas-teste IEEE-57, 118 e 300 barras. Os resultados da pesquisa indicam que a técnica de particionamento aprimora de maneira expressiva a detecção de erros grosseiros em sistemas de energia de grande escala, particularmente aqueles erros de menor magnitude, incrementando a confiabilidade dos resultados gerados pela Estimação de Estados de Sistemas de Potência. Ademais, a metodologia de fusão de estimativas em coordenadas retangulares, em conjunto com a técnica de particionamento, evidencia um desempenho computacional adequado, destacando-se como uma solução viável para a implementação em sistemas de energia elétrica reais.

Palavras-chave: Estimação Híbrida de Estados em Sistemas Elétricos de Potência. Fusão de Estimativas. Processamento de Erros Grosseiros. Medidas Fasoriais Sincronizadas.

ABSTRACT

State estimation in power systems is the basic tool used for the secure and efficient operation of power networks. Its importance lies in its ability to provide reliable and up-to-date information about the operational condition of the network. An essential aspect of state estimation in power systems is the efficient processing of bad data. The use of synchrophasor measurements for power system real-time monitoring, along with data gathered by SCADA systems, has enabled the development of hybrid state estimation, with the fusion estimation method being a particularly promising hybrid approach. However, with the increase in the size of electrical networks, a substantial problem concerned with bad data processing arises. The cause of this problem lies in the decrease of sensitivity of the $J(\hat{x})$ -test with the increase in the size of the electrical network. A recently proposed solution to this problem is the partitioning of the metering scheme, which in turn induces the partition of the network into clusters of reduced size. The main objective of this dissertation is to extend the network partitioning strategy for application in the synchrophasor measurement processing module of the hybrid estimation fusion architecture. The implementation of this strategy in the context of fusion is discussed, and its effectiveness is evaluated using the IEEE-57, 118, and 300 bus test systems. The obtained results indicate that the partitioning technique significantly enhances the detection of bad data in large-scale power systems, and in particular of those errors of smaller magnitude, increasing the reliability of the results generated by hybrid state estimation. Furthermore, the fusion estimation methodology formulated in rectangular coordinates, in conjunction with the partitioning technique, shows an adequate computational performance, and thus stands out as a viable solution for application to real electrical power systems.

Keywords: Hybrid Power System State Estimation. Estimation Fusion. Bad Data Processing. Synchronized Phasor Measurements.

LISTA DE FIGURAS

Figura 1 – Representação de sincrofasores a partir de sinais senoidais (IEEE, 2011).	25
Figura 2 – Senoide com defasagem em relação à frequência nominal f_0 (IEEE, 2011).	26
Figura 3 – Amostragem de uma senoide com defasagem (IEEE, 2011).	26
Figura 4 – Modelo π da rede.	41
Figura 5 – Arquitetura estimador híbrido APSI.	44
Figura 6 – Fusão de dados centralizada.	45
Figura 7 – Fusão de dados descentralizada.	45
Figura 8 – Fusão de dados híbrida.	46
Figura 9 – Arquitetura do estimador híbrido de fusão.	48
Figura 10 – Impedância entre duas áreas (ZANLORENSI, E., 2021).	59
Figura 11 – Grafo de medição fasorial.	62
Figura 12 – Rede de 57 barras com particionamento do plano de medição fasorial de 4 <i>clusters</i> .	75
Figura 13 – Taxas de sucesso de detecção para a rede teste de 57 barras.	77
Figura 14 – Taxas de sucesso de identificação para a rede teste de 57 barras.	79
Figura 15 – Medianas das métricas de tensão para a rede teste de 57 barras.	81
Figura 16 – Rede de 118 barras com particionamento do plano de medição fasorial de 8 <i>clusters</i> .	84
Figura 17 – Taxas de sucesso de detecção para a rede teste de 118 barras.	86
Figura 18 – Taxas de sucesso de identificação para a rede teste de 118 barras.	88
Figura 19 – Medianas das métricas de tensão para a rede teste de 118 barras.	90
Figura 20 – Rede de 300 barras com particionamento do plano de medição fasorial de 20 <i>clusters</i> .	92
Figura 21 – Taxas de sucesso de detecção para a rede teste de 300 barras.	94
Figura 22 – Taxas de sucesso de detecção para a rede teste de 300 barras.	96
Figura 23 – Medianas das métricas de tensão para a rede teste de 300 barras.	97
Figura 24 – Taxas de sucesso de detecção em diferentes magnitudes de erro para os sistemas de 57, 118 e 300 barras nas configurações particionadas e não particionadas.	99
Figura 25 – Taxas de sucesso de identificação em diferentes magnitudes de erro para os sistemas de 57, 118 e 300 barras nas configurações particionadas e não particionadas.	100

LISTA DE TABELAS

Tabela 1 – Número de medidas e índices de redundância SCADA.	72
Tabela 2 – Número de medidas e índices de redundância PMU.	72
Tabela 3 – Taxas de sucesso de detecção para os casos de rede particionada e não particionada na rede teste de 57 barras.	76
Tabela 4 – Taxas de sucesso de identificação para os casos de rede particionada e não particionada na rede teste de 57 barras.	78
Tabela 5 – Medianas das métricas para os diferentes casos de magnitude do erro na rede teste de 57 barras.	80
Tabela 6 – Taxas de sucesso de detecção para os casos de rede particionada e não particionada na rede teste de 118 barras.	85
Tabela 7 – Taxas de sucesso de identificação para os casos de rede particionada e não particionada na rede teste de 118 barras.	87
Tabela 8 – Medianas das métricas para os diferentes casos de magnitude do erro na rede teste de 118 barras.	89
Tabela 9 – Taxas de sucesso de detecção para os casos de rede particionada e não particionada na rede teste de 300 barras.	94
Tabela 10 – Taxas de sucesso de identificação para os casos de rede particionada e não particionada na rede teste de 300 barras.	95
Tabela 11 – Medianas das métricas para os diferentes casos de magnitude do erro na rede teste de 300 barras.	97
Tabela 12 – Tempos de processamento computacional em segundos.	101

LISTA DE ABREVIATURAS E SIGLAS

APSI	<i>A Priori State Information</i>
EESP	Estimação de Estados em Sistemas de Potência
EGs	Erros Grosseiros
FDMS	Fusão de Dados com Múltiplos Sensores
GPS	<i>Global Positioning System</i>
MQP	Mínimos Quadrados Ponderados
PDC	<i>Phasor Data Concentrator</i>
PMUs	<i>Phasor Measurement Units</i>
SCADA	<i>Supervisory Control and Data Acquisition</i>
SMF	Sistemas de Medição Fasorial
SMFS	Sistema de Medição Fasorial Sincronizada
SSC	Sistema de Supervisão e Controle
TVE	<i>Total Vector Error</i>
WLS	<i>Weighted Least Square</i>

LISTA DE SÍMBOLOS

N	Número total de barras da rede elétrica
\mathbf{z}	Vetor de medidas
\mathbf{z}_0	Vetor de valores verdadeiros das grandezas medidas
$\boldsymbol{\eta}$	Vetor de erros aleatórios de medição
\mathbf{x}	Vetor de estados
$\mathbf{h}(\mathbf{x})$	Função vetorial das grandezas medidas
\mathbf{R}	Matriz de covariâncias dos erros de medição
σ	Desvio-padrão
ρ	Redundância global de medidas
m	Número de medidas
n	Número de estados da rede
J	Soma ponderada dos quadrados dos resíduos
$\hat{\mathbf{x}}$	Vetor de estados estimados
r_i	Resíduo de estimação da medida i
\mathbf{H}	Matriz Jacobiana
\mathbf{G}	Matriz de ganho ou matriz de informação
Δ	Operador de incrementos
ε	Tolerância estabelecida
\mathbf{Q}	rotações de Givens Tradicional
δ	Peso de ponderação
ω	Peso de ponderação
$\tilde{\mathbf{H}}$	Matriz de observação ponderada
\mathbf{P}	Matriz de transformação ortogonal
\mathbf{U}	Matriz triangular superior
$\bar{\mathbf{U}}$	Matriz triangular superior com elementos unitários
\mathbf{P}_S	Matriz de covariância dos erros de estimação para medidas SCADA
\mathbf{x}^*	Solução ótima da estimação híbrida
\mathbf{P}_F	Matriz de covariância dos erros de estimação para medidas sincrofasoriais
ν	Graus de liberdade
K	Limiar do teste- $J(\hat{\mathbf{x}})$
α	Probabilidade de falso alarme
χ^2	Distribuição do qui-quadrado
\mathbf{W}	Matriz de covariância dos resíduos
$r_{N,i}$	Resíduo normalizado para uma medida i
$z_{i,rec}$	Medida i recuperada
N_{medio}	Quantidade média de barramentos
P_{min}	Limiar mínimo pré-definido do número de partições
$\varepsilon_{\vec{V}}$	Métrica de tensão

P	Injeção de potência ativa
Q	Injeção de potência reativa
$ V $	Magnitude de tensão
t	Fluxo de potência ativa
u	Fluxo de potência reativa
\vec{V}	Fasor tensão
\vec{I}	Fasor corrente

SUMÁRIO

1	INTRODUÇÃO	17
1.1	REVISÃO BIBLIOGRÁFICA	18
1.2	OBJETIVOS	20
1.2.1	Objetivo Geral	21
1.2.2	Objetivos Específicos	21
1.3	ORGANIZAÇÃO DA DISSERTAÇÃO	22
2	SISTEMA DE MEDIÇÃO FASORIAL	23
2.1	INTRODUÇÃO	23
2.2	UNIDADES DE MEDIÇÃO FASORIAL	23
2.3	SISTEMA DE MEDIÇÃO FASORIAL SINCRONIZADA	24
2.3.1	Representação Fasorial	25
2.3.2	Precisão	26
2.4	ESTIMAÇÃO DE ESTADOS EM SISTEMAS DE POTÊNCIA E MEDIÇÕES FASORIAIS	27
2.5	CONCLUSÃO	27
3	ESTIMAÇÃO DE ESTADOS	29
3.1	INTRODUÇÃO	29
3.2	MODELO DE MEDIÇÃO	29
3.2.1	Observabilidade da Rede	30
3.3	MÉTODO DOS MÍNIMOS QUADRADOS PONDERADOS	31
3.3.1	Equação Normal de Gauss	31
3.3.2	Método Sequencial Ortogonal	33
3.3.3	Versão rápida das rotações de Givens	34
3.3.4	EESP via Rotações de Givens	36
3.3.5	Rotações rápidas de Givens em blocos	37
3.3.6	Conversão de Coordenadas	38
3.4	CONCLUSÃO	41
4	ESTIMAÇÃO DE ESTADOS HÍBRIDA	43
4.1	INTRODUÇÃO	43
4.2	ESTIMADOR DE ESTADOS APSI	43
4.3	FUSÃO DE ESTIMATIVAS	45
4.3.1	Aplicação à EESP	47
4.4	CONCLUSÃO	49
5	PROCESSAMENTO DE ERROS GROSSEIROS	51
5.1	INTRODUÇÃO	51
5.2	DETECÇÃO	51
5.3	IDENTIFICAÇÃO	53

5.4	REMOÇÃO E RECUPERAÇÃO	53
5.5	PROCESSAMENTO DE ERROS E G3M	54
5.5.1	Detecção	54
5.5.2	Identificação	55
5.5.3	Remoção	55
5.5.4	Recuperação	55
5.6	PROCESSAMENTO DE ERROS E G3M EM BLOCOS	56
5.6.1	Detecção	56
5.6.2	Identificação	56
5.6.3	Remoção	56
5.6.4	Recuperação	57
5.7	CONCLUSÃO	57
6	PROCESSAMENTO DE ERROS GROSSEIROS EM SISTEMAS DE GRANDE PORTE: DEFICIÊNCIAS E ESTRATÉGIAS CORRETIVAS	58
6.1	INTRODUÇÃO	58
6.2	DEGRADAÇÃO NO DESEMPENHO DO TESTE- $J(\hat{x})$ PARA REDES DE GRANDE PORTE	58
6.3	PARTICIONAMENTO DO PLANO DE MEDIÇÃO	60
6.3.1	O conceito de agrupamentos de medidas	60
6.3.2	Grafo de medição fasorial	62
6.3.3	Critérios de clusterização	63
6.3.4	Cortes Normalizados no Particionamento do Plano de Medição Fasorial	63
6.4	APLICAÇÃO DA TÉCNICA PARA O PROCESSAMENTO DE ERROS GROSSEIROS	66
6.4.1	Detecção	66
6.4.2	Etapas de Identificação e Remoção ou Recuperação	67
6.5	CONCLUSÃO	67
7	RESULTADOS	69
7.1	INTRODUÇÃO	69
7.2	AMBIENTE COMPUTACIONAL	69
7.2.1	Condições Gerais de Simulação	69
7.2.2	Métricas	71
7.3	PLANOS DE MEDIÇÃO	72
7.4	SIMULAÇÕES COMPUTACIONAIS	73
7.4.1	Sistema Teste de 57 Barras	73
7.4.2	Taxas de sucesso	76
7.4.2.1	Detecção	76

7.4.2.2	Identificação	78
7.4.3	Medianas das Métricas de Tensão	80
7.4.4	Sistema Teste de 118 Barras	82
7.4.5	Taxas de sucesso	85
7.4.5.1	Detecção	85
7.4.5.2	Identificação	87
7.4.6	Medianas das Métricas de Tensão	89
7.4.7	Sistema Teste de 300 Barras	91
7.4.8	Taxas de sucesso	93
7.4.8.1	Detecção	93
7.4.8.2	Identificação	95
7.4.9	Medianas das Métricas de Tensão	97
7.5	ANÁLISE COMPARATIVA DE DESEMPENHO DO PARTICIONA- MENTO DE REDES	99
7.6	DESEMPENHO COMPUTACIONAL	101
7.7	CONCLUSÃO	102
8	CONCLUSÃO	104
8.1	CONSIDERAÇÕES FINAIS	104
8.2	SUGESTÕES PARA TRABALHOS FUTUROS	106
	REFERÊNCIAS	108

1 INTRODUÇÃO

Para que o operador do sistema elétrico possa acompanhar a evolução das condições de operação da rede e opere-a de maneira eficiente, correta e segura, faz-se necessário realizar a modelagem em tempo real do sistema elétrico de potência. Esta é a função da Estimacão de Estados em Sistemas de Potência (EESP), que visa auxiliar o operador para a tomada da melhor decisão em tempo real. A disponibilidade de um estimador de estados eficiente é essencial para uma operacão confiável do sistema elétrico (MONTICELLI, 1999).

Convencionalmente, as medições de variáveis da rede que alimentam os estimadores de estados são realizadas por meio do sistema SCADA (do inglês *Supervisory Control and Data Acquisition*). Através dele são obtidas medidas dos fluxos e injeções de potência ativa e reativa, bem como, das magnitudes de tensões e correntes. Ainda que esta seja uma tecnologia amplamente utilizada, há uma defasagem nos tempos de aquisicão das medidas. Além disso, os valores medidos são escalares, ou seja, não fasoriais, o que conduz à impossibilidade de serem medidas as defasagens angulares entre variáveis fisicamente distantes (MONTICELLI, 1999).

Com a popularizacão da tecnologia de GPS (do inglês *Global Positioning System*), foram desenvolvidas Unidades de Medição Fasorial (PMUs, do inglês *Phasor Measurement Units*). Estas são instaladas em subestações e medem diretamente fasores de tensão e corrente. As PMUs recebem um sinal de sincronizacão via GPS, possibilitando amostragens de dados sincronizados para subestações geograficamente distantes, tornando viável a medição de defasagens angulares entre as variáveis a elas associadas (PHADKE, A. *et al.*, 2009).

Com a gradual instalacão de PMUs nas subestações, surgiu a possibilidade de incorporacão de medições fasoriais à estimacão de estados. É teoricamente possível se conceber arquiteturas de estimacão centralizadas, que combinam as informacões brutas das duas classes de sensores (SCADA e PMU) (SIMÕES-COSTA; MEYER; DECKER, 2008). Entretanto, estas apresentam restrições quanto a aplicacões práticas. Dessa forma, outras arquiteturas, híbridas e descentralizadas, foram propostas, nas quais a estimacão de estados é realizada em múltiplos estágios (BI; QIN; YANG, 2008; BRUNO *et al.*, 2009; ZIVANOVIC; CAIRNS, 1996). Em uma dessas abordagens as medições do sistema SCADA alimentam um estimador convencional no primeiro estágio e, após este processamento, as estimativas resultantes irão servir de informacões *a priori* para a estimacão do segundo estágio, onde serão processadas medidas fasoriais oriundas de PMUs (BEZ, D. M. *et al.*, 2020; ZHAO, 2006). Já no caso da arquitetura de estimacão de fusão descentralizada, o processamento de medidas das duas classes acima tratadas é realizado de maneira distribuída. Posteriormente, na célula de fusão, são recebidos os resultados dos processamentos do estimador de medidas do sistema SCADA e das medidas fasoriais,

obtidos independentemente, sendo estes então combinados, a fim de obter-se um resultado ótimo (ALBUQUERQUE, A. N. C. d., 2011; SIMÕES-COSTA; ALBUQUERQUE, 2011).

Por se tratar de uma ferramenta amplamente utilizada pelo operador, é necessário garantir que os dados utilizados na estimação de estados não contenham medidas espúrias. Para este fim, testes estatísticos são aplicados a funções das estimativas geradas, para que sejam identificados eventuais erros grosseiros presentes nas medidas, tanto fasoriais quanto as provenientes do sistema SCADA (BEZ, D.; SIMOES-COSTA, 2012; GÖL; ABUR, 2015). Um método utilizado para detectar medidas errôneas é baseado em testes de hipóteses aplicado sobre a soma ponderada dos quadrados dos resíduos, ou testes- $J(\hat{\mathbf{x}})$. Ainda que bastante eficiente para redes de pequeno e médio porte, este procedimento sofre de sensível queda em seu desempenho quando aplicado a redes de grande porte, fato que decorre da perda de sensibilidade estatística do modelo (MONTICELLI, A.; GARCIA, 1983; ZANLORENSI; ASCARI; SIMÕES-COSTA, 2020; KORRES; CONTAXIS, 1991). Uma alternativa para melhorar a precisão da estimação de estados em redes elétricas de grande porte é o particionamento da rede elétrica em áreas menores e mais gerenciáveis. Ao dividir a rede em regiões menores, é possível tirar proveito do impacto de medidas espúrias nos resíduos das medidas locais para agudizar a sensibilidade do teste- $J(\hat{\mathbf{x}})$ localmente, e assim melhorar o desempenho da detecção de erros grosseiros. Dessa forma, o particionamento da rede elétrica torna-se uma solução viável para aprimorar o processamento de erros grosseiros na estimação de estados em redes de grande porte (KORRES; CONTAXIS, 1991; ZANLORENSI, E., 2021).

1.1 REVISÃO BIBLIOGRÁFICA

No que diz respeito a propostas de medidas fasoriais na estimação de estados, visando melhorias nos resultados, podem ser citados os trabalhos de (CHEN; ABUR, 2006; SIMÕES-COSTA; ALBUQUERQUE, 2011; DO COUTTO FILHO; SOUZA; GUIMARAENS, 2014; SIMÕES-COSTA; ALBUQUERQUE; BEZ, 2013; ZHOU *et al.*, 2006). No trabalho (SIMÕES-COSTA; ALBUQUERQUE; BEZ, 2013) aborda-se a inclusão de medidas fasoriais em uma arquitetura de fusão de estimativas que preserva a estrutura dos estimadores convencionais baseados em medidas do sistema SCADA. Nele, a metodologia utilizada faz com que as medidas fasoriais sejam processadas separadamente em um módulo de estimação distinto do estimador tradicional. Este tratamento separado das medições convencionais e fasoriais contorna a barreira técnica e física de conciliação, na mesma estrutura de estimação, das variáveis obtidas por diferentes métodos de medição. Os autores consideram que os canais de medição, SCADA e PMU, são sensores de classes distintas, cujos dados são não-correlacionados e que produzem estimativas independentes. Estas hipóteses conduzem a simplificações matemáticas que tornam a modelagem proposta factível, sem gasto computacional elevado. Além disso, consideram-se informações *a priori*, para cada barra não-observável por medições PMU, de modo a garantir a observabilidade

do sistema.

A perda de sensibilidade do teste- $J(\hat{\mathbf{x}})$, originalmente revelada em (MONTICELLI, A.; GARCIA, 1983), motivou a pesquisa reportada em (GÖL; ABUR, 2015), onde é proposta uma modificação no teste do χ^2 para melhorar a detecção de medidas espúrias presentes no conjunto utilizado. Os autores mostram que, se for suposto que as medidas seguem a distribuição normal, então $J(\hat{\mathbf{x}})$ apresenta a distribuição χ^2 se $J(\hat{\mathbf{x}})$ for corretamente ponderada. Ao invés de ser utilizada a inversa da matriz de covariância dos erros de medição, como usualmente é feito, são utilizados em (GÖL; ABUR, 2015) os elementos diagonais da matriz de covariância dos resíduos. Os elementos fora da diagonal da matriz de covariância dos resíduos, que representam as correlações entre os resíduos das medidas, são desconsiderados. Para avaliar os resultados, foram comparadas a métrica clássica e a proposta em (GÖL; ABUR, 2015) para a aplicação do teste estatístico do χ^2 a $J(\hat{\mathbf{x}})$. Observou-se que ambas as métricas, para erros da ordem de 100σ (100 desvios padrão) ambos os métodos apontam corretamente os erros e para 3σ ambos falham quanto a isso (muito difícil detectar EGs tão pequenos). Portanto, o que se pode afirmar é que os resultados dos 2 métodos são coerentes entre si. Para erros de magnitude intermediária (40σ), que podem significativamente interferir nos resultados estimados, a métrica proposta pelos autores consegue detectar medidas espúrias que não são detectadas pelo teste convencional do χ^2 .

Seguindo a linha de particionamento da rede elétrica para melhoramento dos testes de detecção de erros grosseiros, deve ser citado o trabalho (KORRES; CONTAXIS, 1991). No artigo é apresentado o conceito de área de espalhamento de erros nas medidas sobre os resíduos, a partir do qual é proposta a divisão da rede elétrica em áreas de propagação de erros sobre os resíduos. Considera-se que um erro em medida crítica não pode ser detectado pelo teste- $J(\hat{\mathbf{x}})$, já que uma medida crítica possui resíduo nulo. Por outro lado, um erro em medida não-crítica afeta apenas os resíduos das medidas contidas em sua área de influência específica; em outros termos, o erro grosseiro não afeta o conjunto inteiro de resíduos. Assim, com base nos índices estatísticos do modelo proposto, é possível aplicar técnicas de detecção e de identificação individualmente para cada área de espalhamento de erro, definidas pelas medidas críticas na rede elétrica. Desta maneira são formadas áreas de propagação de erros sobre os resíduos, as quais são determinadas somente considerando os ramos incidentes em medidas não-críticas.

A arquitetura de estimação de estados híbrida com informações APSI (do inglês *A Priori State Information*) é também abordada em (BEZ, D. M. *et al.*, 2020), em que as informações do sistema SCADA são parte do primeiro estágio e integram o processamento das medidas fasoriais como informações *a priori*. As medidas fasoriais são processadas no segundo estágio, em coordenadas retangulares evitando a necessidade de um processo iterativo para realizar-se a estimação de estados.

Nos estudos realizados em (ZANLORENSI; ASCARI; SIMÕES-COSTA, 2020),

utiliza-se uma arquitetura de estimação de estados da rede descentralizada, em que a fusão é dada pela combinação ótima das estimativas produzidas pelos estimadores convencional e fasorial. A arquitetura de estimação de estados utilizada é chamada de APSI (SIMÕES-COSTA; ALBUQUERQUE, 2011; BEZ, D. M. *et al.*, 2020). Nesse tipo de modelo, a estimação é realizada em dois estágios, sendo que o módulo que processa medidas SCADA é preservado e compõe o primeiro estágio da estimação. Assim, há o aproveitamento dos estimadores não lineares convencionais já existentes para as medidas SCADA, sendo adicionalmente considerados estimadores lineares para as medidas fasoriais. Esta arquitetura conduz a estimadores mais rápidos e eficientes. Mostra-se ainda que a rede elétrica só precisa ser observável em relação às medidas convencionais. Para as medidas fasoriais, admitem-se casos de não-observabilidade, sendo criadas ilhas observáveis nas quais há maior penetração de PMUs. É nestas regiões que se esperam melhorias na qualidade das estimativas providas pelas medidas SCADA. É também ressaltada a importância de considerar a correlação entre as partes real e imaginária das quantidades medidas no módulo de estimação que processa as medidas de sincrofasores. Esse é um aspecto crucial para garantir a precisão e eficiência do processamento de dados em sistemas de energia elétrica. Propõe-se um método para processar as medidas em coordenadas cartesianas, por meio de um estimador ortogonal, utilizando blocos 2x2 para garantir a adequada consideração da correlação entre as partes real e imaginária das quantidades medidas. Esse método permite uma estimação mais precisa dos valores dos ângulos e magnitudes das grandezas elétricas, o que, por sua vez, contribui para uma operação mais eficiente e segura dos sistemas de energia elétrica.

Em (ZANLORENSI, E.; SIMÕES-COSTA, A.; ASCARI, L. B., 2021), é introduzida a metodologia de *clustering* (do inglês agrupamento) aplicada à mesma arquitetura APSI, conduzindo a uma nova estratégia de processamento de erros grosseiros para estimadores híbridos bloco-ortogonais. O conceito é utilizado para aumentar a sensibilidade do teste- $J(\hat{\mathbf{x}})$ para sistemas elétricos de grande porte. O particionamento da rede em *clusters* é feito em função da distribuição na rede das medições fasoriais. O teste $J(\hat{\mathbf{x}})$ é aplicado separadamente a cada *cluster* da rede elétrica, levando a um aumento de desempenho do teste da soma ponderada dos quadrados dos resíduos, o qual é utilizado para detectar possíveis medidas errôneas contidas nos *clusters*. Os autores demonstram que a técnica desenvolvida para o particionamento do sistema elétrico não requer grande esforço computacional, viabilizando o método proposto.

1.2 OBJETIVOS

Esta seção descreve o objetivo geral e os objetivos específicos desta dissertação.

1.2.1 Objetivo Geral

O presente trabalho visa, em linhas gerais, contribuir para a melhoria do desempenho de métodos de processamentos de erros grosseiros associados à arquitetura de fusão de estimativas. Explora-se a propriedade de linearidade do estimador fasorial, diferenciando-se do processo de estimação de estados convencional que envolve uma abordagem iterativa resultante do uso de modelos de medição não lineares. Com isso, pretende-se obter um ganho computacional significativo, uma vez que não são necessárias iterações para obter as estimativas resultantes do processamento das medidas sincrofásoriais. Conforme já demonstrado em trabalhos anteriores (ALBUQUERQUE, A. N. C. d., 2011)(ASCARI, L. B. *et al.*, 2022), a utilização de medidas fasoriais permite a obtenção de estimativas finais com qualidade superior às obtidas com métodos convencionais para as variáveis do sistema elétrico.

1.2.2 Objetivos Específicos

Este trabalho tem como objetivos específicos:

- Implementar algoritmos de fusão de estimativas em coordenadas retangulares;
- Implementar um estimador linear no módulo que processa as medidas fasoriais;
- Implementar algoritmo de processamento de erros grosseiros para estimadores híbridos com arquitetura de fusão de estimativas;
- Implementar algoritmos de particionamento em *clustering* da rede, para aumentar a sensibilidade do teste- $J(\hat{\mathbf{x}})$;
- Obter melhorias significativas na detecção de EGs em medidas sincrofásoriais para sistemas de porte realístico em relação à utilização do teste- $J(\hat{\mathbf{x}})$ sem partição da rede;
- Conduzir simulações computacionais para avaliar o desempenho das estratégias e métodos propostos.

Diferentemente do trabalho (SIMÕES-COSTA; ALBUQUERQUE; BEZ, 2013), este estudo considera que o sistema completo é observável tanto em relação às medidas SCADA quanto sincrofásoriais. Isto já é uma realidade no que diz respeito às medidas SCADA. Quanto às sincrofásoriais, avalia-se que, com a crescente e rápida penetração de PMUs nos sistemas elétricos de potência ao redor do mundo, a observabilidade restrita a esta classe de medidas em breve deixará de ser um problema.

A proposição de particionamento da rede elétrica em áreas menores é inspirada em (KORRES; CONTAXIS, 1991) e (ZANLORENSI, E.; SIMÕES-COSTA, A.; ASCARI, L. B., 2021), mas diferencia-se destes trabalhos pelo fato de que esta pesquisa contempla um estimador de estados híbrido baseado na arquitetura de fusão de estimativas.

1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está organizada da seguinte forma:

- **Capítulo 2:** este capítulo apresenta a origem e aplicações das Unidades de Medição Fasorial (PMUs) em sistemas de potência;
- **Capítulo 3:** este capítulo descreve o processo de obtenção das estimativas das variáveis de estado da rede elétrica, descrevendo os métodos de resolução do problema. A linearidade do modelo proposto é aproveitada pela conversão de coordenadas no módulo de processamento de sincrofasores e pela utilização da versão em blocos das rotações rápidas de Givens para a solução;
- **Capítulo 4:** o capítulo aborda a estimação híbrida de estados da rede elétrica, com duas arquiteturas: APSI e fusão. Ambas incorporam as medidas do sistema de medição fasorial para refinamento dos resultados obtidos pelos estimadores já existentes;
- **Capítulo 5:** o capítulo aborda o processamento de erros grosseiros na estimação de estados. São recapitulados os métodos estatísticos para detectar e identificar medidas espúrias e técnicas para removê-las ou recuperar os estados. É revista a extensão do método de G3M em blocos para processar medidas fasoriais em sua forma cartesiana;
- **Capítulo 6:** o capítulo descreve o particionamento do sistema elétrico em subsistemas menores, para aumentar a precisão e eficiência na detecção de erros grosseiros em sistemas elétricos de grande porte;
- **Capítulo 7:** este capítulo apresenta os principais resultados obtidos por meio de simulações computacionais em sistema-teste IEEE, abordando os métodos definidos nesta dissertação;
- **Capítulo 8:** o capítulo descreve uma síntese das principais conclusões da pesquisa, destacando pontos relevantes e sugestões para trabalhos futuros.

2 SISTEMA DE MEDIÇÃO FASORIAL

2.1 INTRODUÇÃO

A disseminação da utilização de Unidades de Medição Fasorial no sistema elétrico permite a incorporação de dados sincrofasoriais por parte de ferramentas voltadas ao apoio à operação da rede. Pelo fato destas medidas receberem etiquetas temporais e serem sincronizadas por um sinal de GPS, surge a oportunidade de realizar comparações precisas entre medidas geograficamente distantes, ou seja, como os pulsos estão sincronizados, as medidas sincrofasoriais referem-se à mesma referência angular (ZHOU *et al.*, 2006).

O processamento dos sinais obtidos pode ser realizado por meio da Série de Fourier e da Transformada Discreta de Fourier e, uma vez formados os fasores, estes são rotulados temporalmente. No concentrador de dados, os fasores são organizados em relação aos seus rótulos. Para a estimação de estados, não se leva em consideração a velocidade de transmissão entre a subestação e o ponto onde ocorre a comparação dos dados, mas sim a etiqueta de cada dado (ZIVANOVIC; CAIRNS, 1996).

2.2 UNIDADES DE MEDIÇÃO FASORIAL

A partir do *blackout* que ocorreu no nordeste dos Estados Unidos em 1965, concluiu-se que os sistemas de potência precisavam de meios que os deixassem mais seguros e confiáveis. Este evento impulsionou pesquisas e desenvolvimentos na área de monitoramento em tempo real da rede elétrica. A estimação de estados atua de maneira a prover dados do estado atual para que a segurança da próxima contingência possa ser analisada (SCHWEPPE; WILDES, 1970).

Na época a estimativa fornecia um estado quase estacionário da rede, pois a tecnologia não comportava medições com alta taxa de amostragem de dados. Somente em 1988 na Universidade de Virginia Tech desenvolveu-se a primeira Unidade de Medição Fasorial. Essa tecnologia foi impulsionada por avanços nos campos de processamentos de sinais digitais e de GPS (PHADKE, Arun G, 2002).

Estes instrumentos são instalados em subestações, medem o secundário dos transformadores de instrumentos e recebem entradas analógicas das medidas da rede, como tensões das barras e correntes dos ramos. Também é possível receber dados digitais provenientes de *merge units*. Por meio de um sistema de sincronização via GPS, os sinais de um conjunto de PMUs que compõem um sistema de medição fasorial são catalogados seguindo uma taxa de amostragem. Para evitar o efeito de *aliasing*, a taxa de amostragem deve considerar a frequência de Nyquist, ou seja, uma frequência que é metade da frequência de amostragem de um sistema de processamento de sinal discreto (IEEE, 2011).

A possibilidade de serem realizadas altas taxas de amostragens, de até 15kHz (256 pontos por ciclo) aponta para uma vantagem desse tipo de medição. Enquanto o sistema

SCADA apresenta um tempo de varredura de seus medidores em torno de 5 segundos, com as PMUs é possível obter 60, 120, 240 fasores por segundo, permitindo a percepção de dinâmicas do sistema elétrico que não são capturadas por medidores tradicionais da rede. Os dados gerados por estes equipamentos podem promover melhoras na estimação de estados, controle e proteção da rede (IEEE, 2011; PARAMO; BRETAS; MEYN, 2022).

As PMUs podem ser utilizadas nas esferas de:

- Monitoramento;
- Estabilidade;
- Proteção;
- Segurança Cibernética.

Com estas quatro áreas aborda-se estimação de estados, detecção de distúrbios, estabilidade de tensão, estabilidade transitória, frequência, transmissão e distribuição (PARAMO; BRETAS; MEYN, 2022).

2.3 SISTEMA DE MEDIÇÃO FASORIAL SINCRONIZADA

Um sistema de medição fasorial sincronizada (SMFS) é composto pelas seguintes partes:

- Unidade de Medição Fasorial;
- Módulo de Sincronização;
- Concentrador de Dados Fasoriais (PDC, do inglês *Phasor Data Concentrator*).

As PMUs são instaladas em subestações e fornecem sinais de tensão nas barras e correntes nos ramos. O módulo de sincronização realiza a amostragem desses sinais por meio de um sinal de um pulso por segundo e a taxa de amostragem divide internamente este pulso. Conforme a norma IEEE Std C37.118.1-2011, esta divisão pode ser dada por amostra ou por segundo, ou seja (IEEE, 2011):

- Número inteiro de segundos por amostra;
- Número inteiro de vezes por segundo.

O concentrador de dados fasoriais encaminha as medições etiquetadas e sincronizadas em relação à referência temporal comum aos sistemas que utilizam estes dados para o monitoramento em tempo real da rede, além de fornecer informações de perda de sinal, perda de dados, falhas e assincronismos.

A comunicação do sistema fasorial inicia-se entre o GPS e a PMU; posteriormente ocorre a comunicação de todas as unidades de medição fasorial com o módulo de sincronização e o concentrador de dados fasoriais, e por fim os dados são enviados ao Sistema de Supervisão e Controle (SSC).

2.3.1 Representação Fasorial

Fasores são representações de sinais senoidais e são amplamente utilizados na análise de sistemas elétricos de potência. Matematicamente, pode-se definir o sinal com uma amplitude (X_m), uma frequência angular ($\omega = 2\pi f$), onde f é a frequência do sinal dada em Hertz, e um ângulo de fase, este geralmente com referência em $t = 0$. Assim, a onda será descrita por (IEEE, 2011):

$$x(t) = X_m \cos(\omega t + \varphi) \quad (1)$$

Sendo o fasor \mathbf{X} dado como:

$$\mathbf{X} = \left(\frac{X_m}{\sqrt{2}} \right) e^{j\varphi} \quad (2)$$

Separando as partes real (X_r) e imaginária (X_i), a representação na forma cartesiana é:

$$\mathbf{X} = X_r + jX_i \quad (3)$$

Para os ângulos $\varphi = 0^\circ$ e $\varphi = -90^\circ$, o sincrofasor do sinal da Eq.(1), atingirá seu valor máximo e esse será o instante em que o sinal será sincronizado com o sinal do GPS, enviado a cada segundo (1 PPS) (IEEE, 2011).

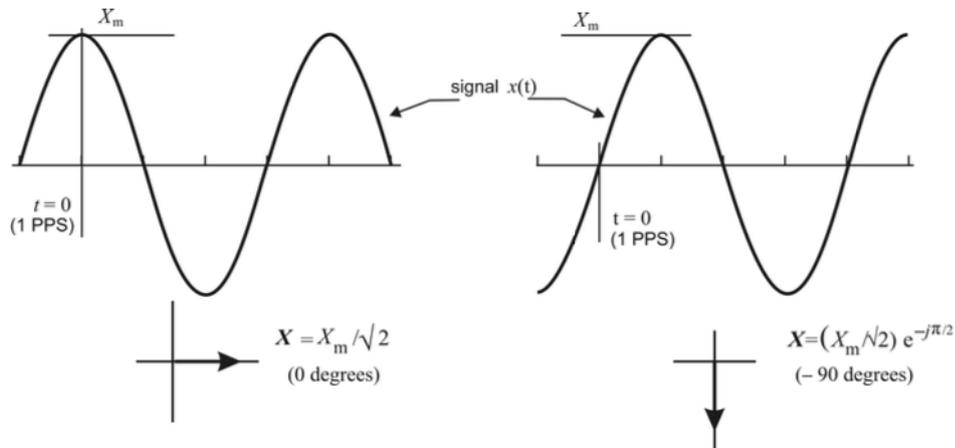


Figura 1 – Representação de sincrofasores a partir de sinais senoidais (IEEE, 2011).

Se o sinal apresentar um desvio δf em relação à frequência nominal do sistema de potência f_0 , os fasores apresentarão magnitude constante, mas os ângulos de fase irão aumentar seguindo o padrão de $2\pi(f - f_0)T_0$, onde $T_0 = 1/f_0$ é o período, Fig. 2. Se esse sinal fosse visto em relação ao tempo, aconteceria um acréscimo até o ângulo de 180° e a partir de então seriam rotacionados e o ângulo aumentaria até -180° , conforme descrito na Fig. 3.

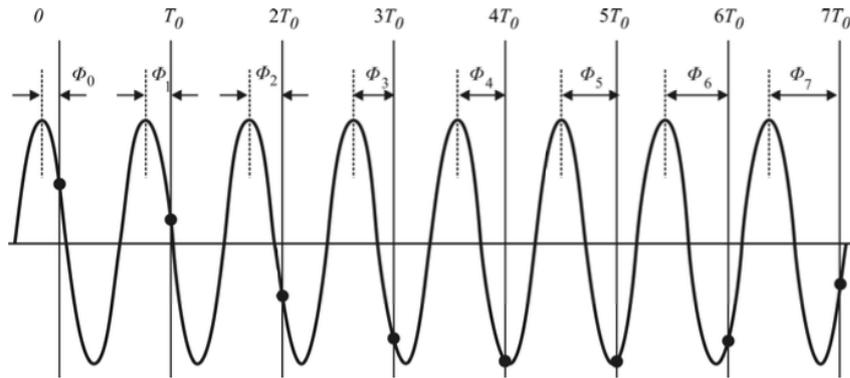


Figura 2 – Senoide com defasagem em relação à frequência nominal f_0 (IEEE, 2011).

Conseqüentemente, para um caso em que a magnitude do fasor é constante, mas o sistema apresentar um desvio em relação à frequência nominal, irão ocorrer rotações a uma taxa de δf entre as amostragens enviadas à PMU (IEEE, 2011).

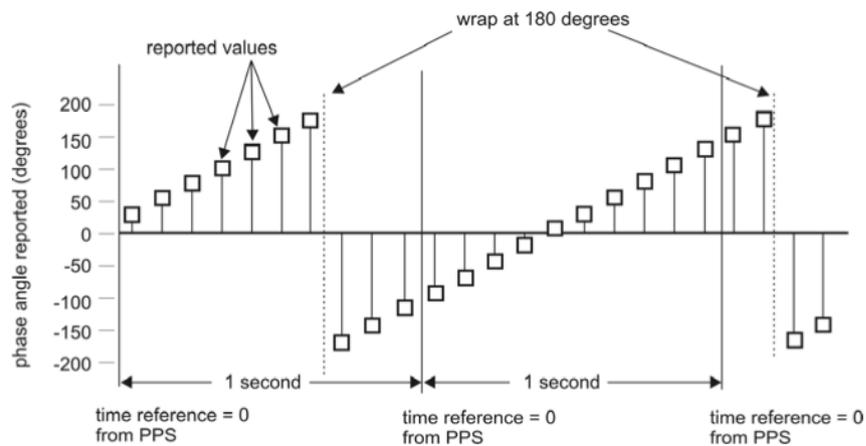


Figura 3 – Amostragem de uma senoide com defasagem (IEEE, 2011).

Uma vantagem do sistema de medição fasorial é a possibilidade de comparação direta entre as medições, fato decorrente de que as medidas são feitas nas mesmas referências de tempo e frequência e ainda que haja diferenças na frequência do sinal e oscilações locais, essas irregularidades são incorporadas à estimação dos ângulos de fase (IEEE, 2011).

2.3.2 Precisão

Durante o processo de obtenção das medições podem ocorrer falhas, ruídos e distorções que acarretam imprecisões e erros que podem aparecer tanto no módulo quanto na fase das estimativas dos sinais. A norma IEEE C37.118.1-2011 estabelece parâmetros para determinar a precisão das medidas das PMUs (IEEE, 2011).

O vetor total de erro (TVE, do inglês *Total Vector Error*), calcula a diferença entre um vetor de ideal (\mathbf{X}) e a estimativa ($\hat{\mathbf{X}}$) obtida pela PMU. Dessa forma, para uma PMU n tem-se:

$$TVE(n) = \sqrt{\frac{(\hat{X}_r(n) - X_r(n))^2 + (\hat{X}_i(n) - X_i(n))^2}{(X_r(n))^2 + (X_i(n))^2}} \quad (4)$$

O TVE resulta em um percentual, exprimindo o máximo erro que uma medida estimada pela PMU pode conter. Por norma, o valor limite de erro que o fasor estimado pode ter é de 1% (IEEE, 2011).

2.4 ESTIMAÇÃO DE ESTADOS EM SISTEMAS DE POTÊNCIA E MEDIÇÕES FASORIAIS

A estimação de estados é um processo crucial para o correto funcionamento do sistema elétrico de potência. Nesse processo, as medidas disponíveis são utilizadas para estimar as variáveis de estado do sistema, como tensões e ângulos de fase das barras. Com o advento dos sistemas de medição fasorial (SMF), um novo conjunto de medidas torna-se disponível para a estimação de estados. As medidas fornecidas pelas PMUs são obtidas a partir da medição de grandezas elétricas instantâneas, como tensões e correntes, com alta resolução temporal, o que proporciona uma visão muito mais detalhada do comportamento do sistema em tempo real (ABUR; EXPOSITO, 2004).

As medidas fornecidas pelas PMUs podem ser classificadas em medidas locais e medidas remotas. As medidas locais são obtidas diretamente na PMU, enquanto que as medidas remotas são obtidas a partir de medições de outras PMUs ou de equipamentos convencionais de medição, como os sistemas SCADA (PHADKE, Arun G; THORP, 2008). As medidas das PMUs locais consistem em medidas de tensão e corrente fasoriais em barras selecionadas, além de medições de frequência e de taxa de variação da frequência. Já as medidas das PMUs remotas consistem em medidas de ângulos de fase de barras não diretamente medidas pela PMU, obtidas a partir de sincronização temporal entre diferentes PMUs (ABUR; EXPOSITO, 2004).

As PMUs são uma importante ferramenta para a modernização e aprimoramento dos sistemas de energia elétrica, permitindo uma operação mais eficiente e segura do sistema (PHADKE, Arun G; THORP, 2008).

2.5 CONCLUSÃO

Neste capítulo apresentou-se a origem histórica das Unidades de Medição Fasorial. Estes instrumentos dispositivos são incorporados às subestações e podem ser utilizados nas áreas de monitoramento, estabilidade, proteção e segurança cibernética da rede. A

partir dessas aplicações surge a oportunidade de se detectar distúrbios, estimar estados e analisar a estabilidade do sistema de potência.

Um conjunto de PMUs incorporados à rede geram um sistema de medição fasorial com medidas sincronizadas em relação a uma mesma referência temporal e de frequência. Estes dispositivos fornecem fasores de tensões nas barras e correntes nos ramos que viabilizam comparações diretas entre medições geograficamente distantes e podem trazer subsídios significativos à Estimação de Estados em Sistema de Potência.

A norma IEEE C37.118.1-2011 apresenta as definições para a medição fasorial sincronizada. Como as fases do processamento dos sinais estão sujeitas a erros, na norma é estabelecido que o máximo TVE que um fasor estimado por uma PMU pode ter é de 1%, sendo este valor dado pela diferença entre que uma medida estimada pela PMU e uma medida de um sinal ideal.

3 ESTIMAÇÃO DE ESTADOS

3.1 INTRODUÇÃO

A Estimação de Estados em Sistemas de Potência (EESP) têm por objetivo determinar as magnitudes e ângulos das tensões nas barras da rede, variáveis denominadas estados do sistema elétrico, uma vez que seu conhecimento permite o cálculo de qualquer outra quantidade de interesse do sistema. A EESP requer o conhecimento da topologia da rede, dos parâmetros elétricos e de medidas adquiridas em tempo real que refletem a condição de operação do sistema de potência (MONTICELLI, 1999).

A topologia da rede elétrica é definida pelas linhas de transmissão, geradores, transformadores e outros componentes, correntemente em operação. Já os parâmetros elétricos advêm de bancos de dados estáticos (KEZUNOVIC, 2006). No presente trabalho, considera-se que a topologia e os parâmetros elétricos representam a rede de maneira correta e livre de erros. As medidas, por sua vez, podem conter inexatidões que serão consideradas na formulação do problema.

A solução convencional da estimação de estados baseia-se no método dos Mínimos Quadrados Ponderados (MQP ou, do inglês, *WLS - Weighted Least Square*), em que a formulação é desenvolvida como um problema de otimização onde busca-se minimizar a Soma Ponderada dos Quadrados dos Resíduos (SPQR) (SCHWEPPE; WILDES, 1970). A solução para o problema é classicamente obtida através da Equação Normal de Gauss. Entretanto, há métodos mais recentes de solução, como os modelos sequenciais ortogonais (SIMOES-COSTA; QUINTANA, 1981).

O objetivo deste capítulo é apresentar as formas clássicas para formulação e solução da estimação de estados bem como o modelo ortogonal de solução.

3.2 MODELO DE MEDIÇÃO

O modelo de medição utilizado na estimação de estados de sistemas de potência relaciona as medidas às variáveis de estado. Nesta seção, o modelo de medição é revisado a fim de introduzir os conceitos apresentados no presente capítulo (MONTICELLI, 1999).

Para uma rede elétrica com N barras e m medidas, a formulação matemática para o modelo é dada por:

$$\mathbf{z} = \mathbf{z}_0 + \boldsymbol{\eta} \quad (5)$$

em que \mathbf{z} é o vetor de medidas com dimensão $m \times 1$, \mathbf{z}_0 representa os valores verdadeiros das grandezas medidas com tamanho $m \times 1$ e $\boldsymbol{\eta}$ de dimensão $m \times 1$ são os erros aleatórios de medição devido às inexatidões dos medidores.

O vetor de valores verdadeiros das medidas \mathbf{z}_0 é dado por um conjunto de funções não-lineares onde são relacionados estados e medidas do sistema. As variáveis de estado

são os os ângulos de fase (em todas as barras menos na barra de referência angular) e as magnitudes das tensões nas barras. Portanto, o vetor de estados \mathbf{x} é composto por $n = 2N - 1$ elementos. Os vetores \mathbf{z}_0 e \mathbf{x} se relacionam como:

$$\mathbf{z}_0 = \mathbf{h}(\mathbf{x}) \quad (6)$$

A dispersão estatística dos erros que contaminam \mathbf{z} é quantificada pela variância dos erros de medição, os quais na ausência de erros grosseiros são considerados com média zero. Define-se \mathbf{R} como a matriz de covariâncias dos erros de medição. Assim, pode-se formular:

$$E(\boldsymbol{\eta}) = \mathbf{0} \quad (7)$$

$$E(\boldsymbol{\eta}\boldsymbol{\eta}^T) = \mathbf{R} \quad (8)$$

onde $E(\cdot)$ é a expectância das variáveis aleatórias. Ainda, supõe-se que os erros de medição são não-correlacionados e seguem a distribuição normal. Dessa forma a matriz \mathbf{R} torna-se diagonal, onde o seu i -ésimo valor corresponde à variância da medida i . De forma que:

$$E(\boldsymbol{\eta}\boldsymbol{\eta}^T) = \mathbf{R} = \text{diag} \{ \sigma_1^2, \dots, \sigma_m^2 \} \quad (9)$$

3.2.1 Observabilidade da Rede

Uma rede elétrica é dita observável se as medidas disponíveis no seu plano de medição são suficientes para a estimação das variáveis de estado. Em caso contrário, diz-se que a rede é não-observável (MONTICELLI, 1999).

Portanto, para o processo de estimação de estados é necessário que a rede seja observável. A observabilidade é obtida quando há um número suficiente de medidas disponíveis e bem distribuídas pela rede. A redundância global de medidas (ρ) é dada por uma relação entre o número de medidas (m) e o número de estados da rede (n) (MONTICELLI, 1999):

$$\rho = \frac{m}{n} = \frac{m}{2N - 1} \quad (10)$$

onde N representa a quantidade de barras do sistema elétrico.

Para ser possível estimar os estados, é necessário que o grau de redundância global do plano de medição seja no mínimo igual a 1, embora na prática ρ tenha que ser significativamente maior do que 1 para permitir o processamento de erros grosseiros (MONTICELLI, 1999).

A fim de contornar a possível falta de observabilidade, por conta da indisponibilidade de medidas, foram desenvolvidas técnicas de complementação do plano de medição

por meio da adição de pseudomedidas. Informações *a priori* derivadas de resultados anteriores da estimação de estados podem também ser utilizadas, embora com variâncias associadas maiores do que as das medidas adquiridas em tempo real (SIMÕES-COSTA; ALBUQUERQUE, 2011).

3.3 MÉTODO DOS MÍNIMOS QUADRADOS PONDERADOS

Tipicamente a estimação de estados é um problema com mais equações do que incógnitas, e para solucionar esta questão utilizam-se conceitos de otimização, objetivando minimizar a soma ponderada dos quadrados dos resíduos (J) (SCHWEPPE; WILDES, 1970).

Define-se o resíduo de estimação da medida i como a diferença entre o valor efetivamente medido (z_i) e o valor obtido em função do estado estimado ($h_i(\hat{\mathbf{x}})$):

$$r_i = z_i - h_i(\hat{\mathbf{x}}) \quad (11)$$

Sendo σ_i a variância da medida i , a função objetivo da estimação de estados é então definida como:

$$\min J(\hat{\mathbf{x}}) = \sum_{i=1}^m \frac{r_i^2}{\sigma_i^2} = \sum_{i=1}^m \frac{(z_i - h_i(\hat{\mathbf{x}}))^2}{\sigma_i^2} \quad (12)$$

Reescrevendo a Eq.(12) em sua forma matricial tem-se:

$$\min J(\hat{\mathbf{x}}) = [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})] \quad (13)$$

3.3.1 Equação Normal de Gauss

Aplicando a condição de otimalidade de primeira ordem à Eq.(13), obtemos o gradiente de $J(\hat{\mathbf{x}})$:

$$\mathbf{g}(\hat{\mathbf{x}}) = \frac{\partial J(\hat{\mathbf{x}})}{\partial \mathbf{x}} = -\mathbf{H}^T(\hat{\mathbf{x}}) \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})] = \mathbf{0} \quad (14)$$

onde a matriz Jacobiana $\mathbf{H}(\hat{\mathbf{x}})$, de dimensão $m \times n$, contém as primeiras derivadas da função \mathbf{h} com respeito aos estados estimados $\hat{\mathbf{x}}$.

Devido à não-linearidade do problema é necessário um método iterativo para determinar a solução, que neste caso é o método de Newton.

Sua aplicação requer o cálculo da segunda derivada da função objetivo em relação a \mathbf{x}^k (ou seja, a matriz Hessiana), que é calculada como:

$$\frac{\partial \mathbf{g}(\hat{\mathbf{x}}^k)}{\partial \mathbf{x}} = \frac{\partial^2 J(\hat{\mathbf{x}}^k)}{\partial \mathbf{x}^2} = \mathbf{H}^T(\hat{\mathbf{x}}^k) \mathbf{R}^{-1} \mathbf{H}(\hat{\mathbf{x}}^k) - \left[\frac{\partial^2 \mathbf{h}(\hat{\mathbf{x}}^k)}{\partial \mathbf{x}^2} \right]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}}^k)] \quad (15)$$

Negligenciando o termo dependente da segunda derivada obtém-se a *matriz de ganho* ou *matriz de informação* $\mathbf{G}(\hat{\mathbf{x}}^k)$:

$$\mathbf{G}(\hat{\mathbf{x}}^k) \approx \mathbf{H}^T(\hat{\mathbf{x}}^k) \mathbf{R}^{-1} \mathbf{H}(\hat{\mathbf{x}}^k) \quad (16)$$

A Eq.(16) é obtida considerando-se que para a região do termo \mathbf{x}^k a matriz Jacobiana sofre poucas variações. Aplicando o método de Newton para a solução iterativa de equações não lineares e a aproximação acima para a Hessiana, temos (MONTICELLI, 1999):

$$\mathbf{G}(\hat{\mathbf{x}}^k) \Delta \mathbf{x} = -\mathbf{g}(\hat{\mathbf{x}}^k) \quad (17)$$

onde $\Delta \mathbf{x} = \hat{\mathbf{x}} - \hat{\mathbf{x}}^k$. Usando as Eqs.(16) e (14):

$$\mathbf{H}^T(\hat{\mathbf{x}}^k) \mathbf{R}^{-1} \mathbf{H} \Delta \mathbf{x} = \mathbf{H}^T(\hat{\mathbf{x}}) \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})] \quad (18)$$

Definindo:

$$\Delta \mathbf{z} = \mathbf{z} - \mathbf{h}(\hat{\mathbf{x}}) \quad (19)$$

Chega-se finalmente à *Equação Normal de Gauss*, é dada por:

$$\left[\mathbf{H}^T(\hat{\mathbf{x}}^k) \mathbf{R}^{-1} \mathbf{H}(\hat{\mathbf{x}}^k) \right] \Delta \mathbf{x} = \mathbf{H}^T(\hat{\mathbf{x}}) \mathbf{R}^{-1} \Delta \mathbf{z} \quad (20)$$

Pelo Método de Gauss-Newton, a Eq.(20) representa o problema a ser solucionado a cada iteração do processo. Partindo de uma estimativa $\hat{\mathbf{x}}^0$, é computado o vetor de incrementos $\Delta \mathbf{x}$ que atualiza o vetor \mathbf{x} . Este processo é repetido até que seja satisfeito o critério de parada do algoritmo.

O critério de parada do algoritmo é estabelecido para determinar quando a solução iterativa atingiu a convergência desejada. Geralmente, o critério de parada está relacionado à magnitude dos incrementos no vetor $\Delta \mathbf{x}$ e é definido por um valor de tolerância pré-estabelecido.

Uma abordagem comum para o critério de parada é verificar se a norma do vetor de incrementos $\Delta \mathbf{x}$ está abaixo de um determinado limite. Isso pode ser expresso como:

$$\|\Delta \mathbf{x}\| \leq \varepsilon \quad (21)$$

onde ε é a tolerância estabelecida. Quando a norma do vetor de incrementos é menor ou igual à tolerância, considera-se que a solução convergiu e o algoritmo é interrompido.

É importante ressaltar que o critério de parada pode variar de acordo com as características do problema e os requisitos específicos de convergência. Em alguns casos, pode ser necessário considerar critérios adicionais, como o número máximo de iterações ou a variação do valor da função objetivo.

Matematicamente, para que se possa atingir um resultado, é necessário que a matriz Jacobiana seja não singular, isto é, tenha posto igual a n . Neste caso a matriz de ganho é simétrica e definida positiva (MONTICELLI, 1999).

3.3.2 Método Sequencial Ortogonal

Para contornar o mau condicionamento que a matriz $\mathbf{H}(\mathbf{x})$ pode sofrer, métodos de resolução baseados em transformações ortogonais vêm sendo desenvolvidos. Essas técnicas apresentam maior robustez numérica e benefícios computacionais agregados que auxiliam na resolução do problema de Estimação de Estados (SIMOES-COSTA; SALGADO, 1983).

Apresentando a Equação Normal para sua k -ésima iteração tem-se:

$$\min_{\Delta \mathbf{x}^k} J(\Delta \mathbf{x}^k) = [\Delta \mathbf{z}^k - \mathbf{H}(\mathbf{x}^k)\Delta \mathbf{x}^k]^T \mathbf{R}^{-1} [\Delta \mathbf{z}^k - \mathbf{H}(\mathbf{x}^k)\Delta \mathbf{x}^k] \quad (22)$$

Pela definição da matriz de covariância de erros das medidas apresentada na Eq.(9) percebe-se que \mathbf{R} é definida positiva, pois para todo o conjunto de medidas $\sigma^2 > 0$. Assim, utilizando a fatoração de Cholesky:

$$\mathbf{R} = \mathbf{R}^{1/2} \mathbf{R}^{T/2} \quad (23)$$

Aplicando a inversa:

$$\mathbf{R}^{-1} = \mathbf{R}^{-T/2} \mathbf{R}^{-1/2} \quad (24)$$

Ainda, definindo para a matriz Jacobiana e para o vetor de delta das medidas:

$$\tilde{\mathbf{H}}(\mathbf{x}^k) = \mathbf{R}^{-\frac{1}{2}} \mathbf{H}(\mathbf{x}^k) \quad (25)$$

$$\Delta \tilde{\mathbf{z}}^k = \mathbf{R}^{-\frac{1}{2}} \Delta \mathbf{z}^k \quad (26)$$

De forma que a Eq.(22) passa a ser escrita da seguinte maneira:

$$\min_{\Delta \mathbf{x}^k} J(\Delta \mathbf{x}^k) = [\Delta \tilde{\mathbf{z}}^k - \tilde{\mathbf{H}}(\mathbf{x}^k)\Delta \mathbf{x}^k]^T [\Delta \tilde{\mathbf{z}}^k - \tilde{\mathbf{H}}(\mathbf{x}^k)\Delta \mathbf{x}^k] \quad (27)$$

Para transformações ortogonais a norma Euclidiana é constante e isto possibilita esta aplicação para a solução do problema de Estimação de Estados no presente caso (SIMOES-COSTA; QUINTANA, 1981). Portanto a Eq. (27) passa a ser representada por:

$$\min_{\Delta \mathbf{x}^k} J(\Delta \mathbf{x}^k) = \left\| \Delta \tilde{\mathbf{z}}^k - \tilde{\mathbf{H}}(\mathbf{x}^k)\Delta \mathbf{x}^k \right\|^2 \quad (28)$$

Deste modo, pode-se triangularizar a matriz $\tilde{\mathbf{H}}$ por meio de rotações ortogonais de Givens (SIMOES-COSTA; SALGADO, 1983). Considerando a forma tradicional das rotações de Givens, a seguinte rotação ortogonal de dimensão 2×2 é dada:

$$\mathbf{Q} = \begin{bmatrix} c & s \\ -s & c \end{bmatrix} \quad (29)$$

Considerando as seguintes linhas da matriz $\tilde{\mathbf{H}}$:

$$\begin{bmatrix} \tilde{\mathbf{j}} \\ \tilde{\mathbf{k}} \end{bmatrix} = \begin{bmatrix} 0 & 0 & \cdots & \tilde{j}_i & \tilde{j}_{i+1} & \cdots & \tilde{j}_n \\ 0 & 0 & \cdots & \tilde{k}_i & \tilde{k}_{i+1} & \cdots & \tilde{k}_n \end{bmatrix} \quad (30)$$

Para que um elemento \tilde{k}_i seja zerado, realiza-se então a rotação elementar \mathbf{Q} com o objetivo de zerar o elemento \tilde{k}_i :

$$\mathbf{Q} \begin{bmatrix} \tilde{\mathbf{j}} \\ \tilde{\mathbf{k}} \end{bmatrix} = \begin{bmatrix} \tilde{\mathbf{j}}' \\ \tilde{\mathbf{k}}' \end{bmatrix} \quad (31)$$

Ao realizar a rotação elementar \mathbf{Q} , os elementos \tilde{j}_i e \tilde{k}_i da matriz são transformados em zero, resultando na nova configuração $\tilde{\mathbf{j}}'$ e $\tilde{\mathbf{k}}'$. A matriz resultante terá a seguinte forma:

$$\begin{bmatrix} \tilde{\mathbf{j}}' \\ \tilde{\mathbf{k}}' \end{bmatrix} = \begin{bmatrix} 0 & 0 & \cdots & \tilde{j}'_i & \tilde{j}'_{i+1} & \cdots & \tilde{j}'_n \\ 0 & 0 & \cdots & 0 & \tilde{k}'_{i+1} & \cdots & \tilde{k}'_n \end{bmatrix} \quad (32)$$

O objetivo de zerar o elemento \tilde{k}_i por meio da rotação elementar \mathbf{Q} é parte de um processo conhecido como triangularização da matriz Jacobiana. A aplicação repetitiva dessa operação permite transformar a matriz Jacobiana em uma forma triangular superior, o que facilita o processo de resolução de sistemas de equações lineares, que finalmente gera as estimativas ótimas.

Para que o elemento \tilde{k}'_i seja zerado, é necessário calcular os coeficientes c e s da rotação elementar com base nos valores dos elementos \tilde{j}_i e \tilde{k}_i . Esses coeficientes são obtidos da seguinte forma:

$$c = \frac{\tilde{j}_i}{\sqrt{\tilde{j}_i^2 + \tilde{k}_i^2}} \quad (33)$$

$$s = \frac{\tilde{k}_i}{\sqrt{\tilde{j}_i^2 + \tilde{k}_i^2}} \quad (34)$$

Essa operação de rotação elementar é repetida para cada elemento \tilde{k}_i a ser zerado, até que a matriz Jacobiana esteja completamente triangularizada.

3.3.3 Versão rápida das rotações de Givens

Para evitar o cálculo direto das raízes quadradas e diminuir o esforço computacional das decomposições ortogonais, propõe-se a seguinte formulação em que são considerados pesos δ e ω para as linhas da matriz $\tilde{\mathbf{H}}$ (GENTLEMAN, 1973):

$$\begin{bmatrix} \tilde{\mathbf{j}} \\ \tilde{\mathbf{k}} \end{bmatrix} = \begin{bmatrix} 0 & 0 & \cdots & \sqrt{\delta}j_i & \sqrt{\delta}j_{i+1} & \cdots & \sqrt{\delta}j_n \\ 0 & 0 & \cdots & \sqrt{\omega}k_i & \sqrt{\omega}k_{i+1} & \cdots & \sqrt{\omega}k_n \end{bmatrix} \quad (35)$$

Em que \mathbf{j}_i e \mathbf{k}_i são linhas para uma matriz \mathbf{H} . Define-se:

$$\mathbf{w}^{1/2} = \begin{bmatrix} \sqrt{\delta} & 0 \\ 0 & \sqrt{\omega} \end{bmatrix} \quad (36)$$

$$\mathbf{H} = \begin{bmatrix} \mathbf{j} \\ \mathbf{k} \end{bmatrix} \quad (37)$$

ou seja,

$$\tilde{\mathbf{H}} = \mathbf{w}^{1/2}\mathbf{H} \quad (38)$$

Aplicando as rotações de Givens para as linhas a fim de zerar o elemento k_i :

$$\begin{bmatrix} \tilde{\mathbf{j}}' \\ \tilde{\mathbf{k}}' \end{bmatrix} = \begin{bmatrix} \sqrt{\delta'} & 0 \\ 0 & \sqrt{\omega'} \end{bmatrix} \begin{bmatrix} 0 & 0 & \cdots & j'_i & j'_{i+1} & \cdots & j'_n \\ 0 & 0 & \cdots & 0 & k'_{i+1} & \cdots & k'_n \end{bmatrix} \quad (39)$$

O sistema de equações formado implica em:

$$c^2 = \frac{\delta}{\delta + \omega \left(\frac{k_i}{j_i}\right)^2} \quad (40)$$

$$s^2 = \frac{\omega}{\omega + \delta \left(\frac{j_i}{k_i}\right)^2} \quad (41)$$

Para a versão rápida das Rotações de Givens há uma matriz de transformação ortogonal \mathbf{P} definida da seguinte forma:

$$\mathbf{PH} = \tilde{\mathbf{H}}' \quad (42)$$

Expandindo:

$$\begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix} \begin{bmatrix} \mathbf{j} \\ \mathbf{k} \end{bmatrix} = \begin{bmatrix} \sqrt{\delta'} & 0 \\ 0 & \sqrt{\omega'} \end{bmatrix}^{-1} \begin{bmatrix} c & s \\ -s & c \end{bmatrix} \begin{bmatrix} \sqrt{\delta} & 0 \\ 0 & \sqrt{\omega} \end{bmatrix} \begin{bmatrix} \mathbf{j} \\ \mathbf{k} \end{bmatrix} \quad (43)$$

A partir da Eq. (43) são formados quatro equacionamentos onde objetiva-se descobrir seis incógnitas. Para a resolução desta questão (GENTLEMAN, 1973) realiza as seguintes considerações para os equacionamentos tal que o termo $P_{22} = 1$, o elemento j'_i , dessa forma, $P_{11}j_i + P_{12}k_i = 1$ e como j_i é inicializado por 1 a descrição passa a ser $P_{11} + P_{12}k_i = 1$. Com estas definições evita-se o cálculo das raízes o que reduz o custo computacional do método e diminui as operações em ponto flutuante (SIMOES-COSTA;

QUINTANA, 1981). Os parâmetros e variáveis individuais da Eq. (43) são atualizados conforme segue (QUINTANA; SIMOES-COSTA; MIER, 1982), (BEZ, D. M. *et al.*, 2020), (ZANLORENSI; ASCARI; SIMÕES-COSTA, 2020):

$$\begin{aligned}
 \delta' &= \delta + \omega k_i^2 \\
 P_{11} &= \frac{\delta}{\delta'} \\
 P_{12} &= \omega P_{11} \\
 \omega' &= \omega P_{11} \\
 P_{21} &= -k_i \\
 P_{22} &= 1
 \end{aligned} \tag{44}$$

3.3.4 EESP via Rotações de Givens

Se uma nova medida é processada na k -ésima iteração:

$$\Delta z_i^k = z_i - \mathbf{h}_i(\mathbf{x}^k) \tag{45}$$

A função objetivo apresentada na Eq.(28)do prolema torna-se:

$$\min_{\Delta \mathbf{x}^k} J(\Delta \mathbf{x}^k) = \left\| \begin{bmatrix} \Delta \tilde{\mathbf{z}}^k \\ \Delta \tilde{z}_i^k \end{bmatrix} - \begin{bmatrix} \tilde{\mathbf{H}}(\mathbf{x}^k) \\ \tilde{\mathbf{h}}_i(\mathbf{x}^k) \end{bmatrix} \Delta \mathbf{x}^k \right\|^2 \tag{46}$$

Aplicando a rotação ortogonal tradicional \mathbf{Q} , em que sua condição de ortogonalidade implica que sua inversa seja igual a sua transposta, na norma quadrática tem-se:

$$\mathbf{Q} \begin{bmatrix} \tilde{\mathbf{H}}(\mathbf{x}^k) \\ \tilde{\mathbf{h}}_i(\mathbf{x}^k) \end{bmatrix} = \begin{bmatrix} \mathbf{U} \\ \mathbf{0} \end{bmatrix} \tag{47}$$

$$\mathbf{Q} \begin{bmatrix} \Delta \tilde{\mathbf{z}}^k \\ \Delta \tilde{z}_i^k \end{bmatrix} = \begin{bmatrix} \mathbf{W} \\ \tilde{e}_i \end{bmatrix} \tag{48}$$

em que \mathbf{U} é triangular superior de dimensão $n \times n$ e $\mathbf{0}$ é um vetor nulo $1 \times n$ e \tilde{e}_i é um escalar.

A estimação é obtida com o seguinte sistema linear que representa as $m + 1$ medidas:

$$\mathbf{U}\tilde{\mathbf{x}} = \mathbf{W} \tag{49}$$

A contribuição da medida z_i^k para a soma ponderada dos quadrados dos resíduos é dada por \tilde{e}_i^2 e a cada triangularização este valor é armazenado para gerar, ao final do processo, a SPQR do problema total.

3.3.5 Rotações rápidas de Givens em blocos

Em várias situações a serem descritas em outras seções deste documento, será enfatizada a importância de representar a correlação entre pares de medidas a serem processadas pelas rotações de Givens. Isto serve de motivação para estender as rotações rápidas de Givens de modo a aplica-las simultaneamente a pares de medidas. Esta versão das rotações rápidas de Givens será referida como G3M em Blocos, e será descrita a seguir.

A inicialização do método é dada por:

$$\begin{aligned}\bar{\mathbf{U}} &= \mathbf{I} \\ \mathbf{D} &= \mathbf{0} \\ \bar{\mathbf{c}} &= \mathbf{0}\end{aligned}\tag{50}$$

onde $\bar{\mathbf{U}}$ é triangular superior com elementos unitários e de dimensão $n \times n$, \mathbf{D} possui dimensão $n \times n$ e o vetor coluna $\bar{\mathbf{c}}$ possui n linhas.

Diferentemente do método tradicional, as matrizes serão divididas em blocos com dimensão 2×2 e os blocos diagonais da matriz $\mathbf{D}^{1/2}$ irão ponderar as linhas da matriz $\bar{\mathbf{U}}$.

Seja \mathbf{H} a bloco-matriz aumentada com o vetor de medidas \mathbf{z} dada por:

$$\mathbf{H} = \left[\begin{array}{cccc|c} \mathbf{H}_1 & \mathbf{H}_2 & \dots & \mathbf{H}_n & \mathbf{z} \end{array} \right]\tag{51}$$

Para que os blocos sejam zerados, cada uma das submatrizes $\mathbf{H}_1, \dots, \mathbf{H}_n$ será rotacionada com as linhas da matriz $\bar{\mathbf{U}}$ e ponderadas por um bloco 2×2 de pesos \mathbf{W} extraídos da matriz \mathbf{R}' . A rotação do método de Givens rápido em blocos é dada por:

$$\begin{bmatrix} \bar{\mathbf{u}} \\ \bar{\mathbf{h}} \end{bmatrix} = \begin{bmatrix} \mathbf{P}_{11} & \mathbf{P}_{12} \\ \mathbf{P}_{21} & \mathbf{P}_{22} \end{bmatrix} \begin{bmatrix} \mathbf{u} \\ \mathbf{h} \end{bmatrix}\tag{52}$$

Para o processamento de uma medida k o algoritmo atualiza a matriz \mathbf{P} e os pesos de forma que:

$$\begin{aligned}\bar{\mathbf{D}} &= \mathbf{D} + \mathbf{H}_k^T \mathbf{W}_k \mathbf{H}_k \\ \mathbf{P}_{11} &= \bar{\mathbf{D}}^{-1} \bar{\mathbf{D}} \\ \mathbf{P}_{12} &= \bar{\mathbf{D}}^{-1} \mathbf{H}_k^T \mathbf{W}_k \\ \mathbf{P}_{21} &= -\mathbf{H}_k \\ \mathbf{P}_{22} &= \mathbf{I}_2 \\ \bar{\mathbf{W}}_k &= \mathbf{W}_k (\mathbf{I}_2 - \mathbf{H}_k \mathbf{P}_{12})\end{aligned}\tag{53}$$

Onde \mathbf{I}_2 é a matriz identidade de dimensão 2×2 e a inicialização da matriz \mathbf{W}_k é realizada por meio dos pesos obtidos da matriz de covariância dos erros de medição:

$$\mathbf{W}_k = \begin{bmatrix} \sigma_{x,k}^2 & \sigma_{xy,k}^2 \\ \sigma_{yx,k}^2 & \sigma_{y,k}^2 \end{bmatrix}^{-1} \quad (54)$$

Para um conjunto com m medidas, a resolução do problema é análoga à mostrada na 3.3.4 e após o processamento de todas as medidas, pode ser obtida por meio do sistema linear bloco triangular superior:

$$\bar{\mathbf{U}}\hat{\mathbf{x}} = \bar{\mathbf{c}} \quad (55)$$

Similarmente ao método tradicional, apresentado na Seção 3.3.4, ao final das rotações, a soma ponderada do quadrado dos resíduos também é obtida e está contida no elemento (1,1) da matriz \mathbf{D}_{n+1} .

3.3.6 Conversão de Coordenadas

As medições dos sensores de um sistema elétrico geralmente são realizadas em coordenadas polares. Devido à linearidade do modelo proposta, convém realizar uma transformação de coordenadas.

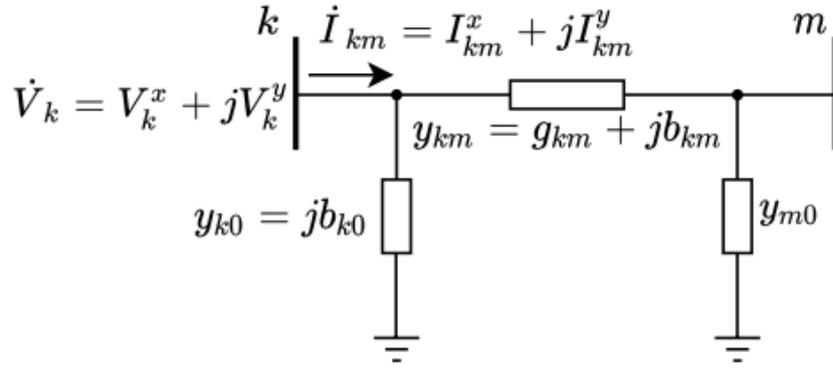
A conversão de coordenadas consiste em transformar as medidas nas coordenadas polares para as coordenadas retangulares. Isso é feito utilizando equações trigonométricas que levam em conta os ângulos e as magnitudes das grandezas medidas. Em seguida, as medidas convertidas são utilizadas como entradas em algoritmos de estimação de estados.

A seguinte formulação do modelo de medição será baseada no exposto na Seção 3.2. Conforme a Eq. (5), os valores verdadeiros da magnitude (z_{r_0}) e da fase (z_{θ_0}) possuem inexatidões (η) inerentes à medição e o vetor de medidas \mathbf{z} em coordenadas polares é dado como:

$$\mathbf{z} = \mathbf{z}_{r_0} \angle \mathbf{z}_{\theta_0} + \boldsymbol{\eta} \quad (56)$$

onde \mathbf{z}_{r_0} e \mathbf{z}_{θ_0} são os vetores de valores verdadeiros. Para um conjunto de m medidas o vetor possuirá dimensão $2m \times 1$:

$$\mathbf{z} = \begin{bmatrix} z_{r,1} \\ z_{\theta,1} \\ z_{r,2} \\ z_{\theta,2} \\ z_{r,3} \\ z_{\theta,3} \\ \vdots \\ z_{r,m} \\ z_{\theta,m} \end{bmatrix} = \begin{bmatrix} z_{r_0,1} \\ z_{\theta_0,1} \\ z_{r_0,2} \\ z_{\theta_0,2} \\ z_{r_0,3} \\ z_{\theta_0,3} \\ \vdots \\ z_{r_0,m} \\ z_{\theta_0,m} \end{bmatrix} + \begin{bmatrix} \eta_{r,1} \\ \eta_{\theta,1} \\ \eta_{r,2} \\ \eta_{\theta,2} \\ \eta_{r,3} \\ \eta_{\theta,3} \\ \vdots \\ \eta_{r,m} \\ \eta_{\theta,m} \end{bmatrix} \quad (57)$$

Figura 4 – Modelo π da rede.

para estes fasores está mostrado na Eq.(71). Os sobrescritos, x e y respectivamente fazem referência às componentes real e imaginária.

$$\begin{bmatrix} V_k^x \\ V_k^y \\ I_{km}^x \\ I_{km}^y \end{bmatrix} = \begin{bmatrix} 1 & & & \\ & 1 & & \\ \hline & g_{km} & (-b_{km} - b_{k0}) & -g_{km} \quad b_{km} \\ (b_{km} + b_{k0}) & g_{km} & -b_{km} & g_{km} \end{bmatrix} \begin{bmatrix} x_k^x \\ x_k^y \\ x_m^x \\ x_m^y \end{bmatrix} + \begin{bmatrix} \eta_{x,k} \\ \eta_{y,k} \\ \eta_{x,m} \\ \eta_{y,m} \end{bmatrix} \quad (71)$$

A matriz central da Eq.(71) é a matriz de observação ou Jacobiana das medidas na forma cartesiana (\mathbf{H}'), o vetor \mathbf{x} representa os estados a serem estimados, reescrevendo o modelo:

$$\mathbf{z}' = \mathbf{H}' \mathbf{x} + \boldsymbol{\eta}' \quad (72)$$

Percebe-se que o modelo de medição apresentado em coordenadas cartesianas é linear e que a matriz de observação é montada a partir dos parâmetros da rede elétrica, o que permite a utilização de métodos não iterativos para a sua solução. Como as matrizes formadas possuem blocos 2×2 , há correlações não desprezíveis entre pares de medidas e os algoritmos de baseados em ponderações escalares, como as rotações de Givens não pode ser utilizado. Em (BEZ, D. M. *et al.*, 2020) estendeu-se o estimador baseado nas rotações de Givens para que os blocos sejam absorvidos pelo algoritmo, proporcionando o processamento simultâneo das partes reais e imaginárias das medidas em coordenadas retangulares.

3.4 CONCLUSÃO

Este capítulo apresentou o processo de obtenção das estimativas para as variáveis de estado da rede. Para tanto, foi exposto o modelo de medidas para o problema de EESP

e o conceito de observabilidade da rede. Após abordou-se o desenvolvimento do problema por meio do método dos Mínimos Quadrados Ponderados.

Para resolução da questão apresentou-se o método clássico de solução dado via Equação Normal de Gauss, bem como o método sequencial Ortogonal baseado em rotações de Givens, o qual mostra-se estatisticamente mais robusto quando comparado ao método tradicional. Contudo, ambos conduzem para estimativas satisfatórias desde que os erros entre as medidas e os valores reais respeitem uma distribuição normal de média zero.

Inicialmente o modelo foi proposto de maneira escalar em coordenadas polares, contudo, para aproveitar a linearidade do modelo, abordou-se a conversão de coordenadas para o sistema e para sua solução utilizou-se a versão em blocos das rotações rápidas de Givens.

4 ESTIMAÇÃO DE ESTADOS HÍBRIDA

4.1 INTRODUÇÃO

Os sistemas elétricos ao redor do mundo são, em geral, monitorados através de medidas assíncronas disponibilizadas por sistemas SCADA. Devido à sua robustez e a significativos investimentos feitos por empresas e operadores ao longo do tempo, a utilização das medidas provenientes desses sistemas na estimação de estados tornou-se um padrão mundial para a monitoração em tempo real de redes elétricas. Entretanto, o avanço tecnológico representado pelos sistemas de medição fasorial e a crescente penetração de PMUs nos sistemas de potência gera o desafio de agregar dados sincrofasoriais para monitoramento em tempo real desses sistemas.

A proposta desse capítulo visa manter integrais os estimadores já utilizados e incorporar as medidas sincrofasoriais à estimação de estados. Para tal, são apresentadas arquiteturas de estimação baseadas nos conceitos de informação *a priori* e Fusão de Dados com Múltiplos Sensores (FDMS) aplicados ao processo de estimação de estados em sistemas de potência.

4.2 ESTIMADOR DE ESTADOS APSI

O estimador de estados APSI (do inglês *A Priori State Information*) possui dois estágios principais, em que a primeira etapa subsidia com dados a segunda etapa. No primeiro estágio, há o processamento convencional das medidas do sistema SCADA (\mathbf{z}_S), para então se iniciar a próxima fase, na qual os resultados preliminarmente obtidos são incorporados ao processo como informações *a priori* dos estados da rede.

Portanto, ao final do processamento do primeiro estágio tornam-se disponíveis o vetor de estados estimados ($\hat{\mathbf{x}}_S$) e a respectiva matriz de covariância de erros (\mathbf{P}_S), usualmente densa, que quantifica as imprecisões das estimativas geradas e é dada como o inverso da matriz ganho (SIMÕES-COSTA; ALBUQUERQUE, 2011):

$$\mathbf{P}_S = (\mathbf{G}_S)^{-1} = (\mathbf{H}_S^T \mathbf{R}_S^{-1} \mathbf{H}_S)^{-1} \quad (73)$$

Em contraponto, a segunda etapa recebe os resultados do primeiro estágio, sob forma de informações *a priori*, as quais são ponderadas pelo inverso das respectivas covariâncias dos erros de estimação (\mathbf{P}_S) ao serem processadas conjuntamente com as medidas do sistema fasorial (\mathbf{z}_F) (ZHOU *et al.*, 2006). Em certas situações, é comum assumir que as informações *a priori* não estão correlacionadas, resultando em uma matriz \mathbf{P}_S diagonal, ou seja, $\mathbf{P}_S = \text{diag}\{\sigma_1^2, \dots, \sigma_n^2\}$. Como este estimador deve ter a capacidade de processar estes dois tipos de dados, algoritmos de estimação baseados na versão rápida das Rotações de Givens mostram-se particularmente eficientes (SIMÕES-COSTA; ALBUQUERQUE,

2011). Pela figura 5 é possível observar a arquitetura e as etapas do estimador de estados APSI.

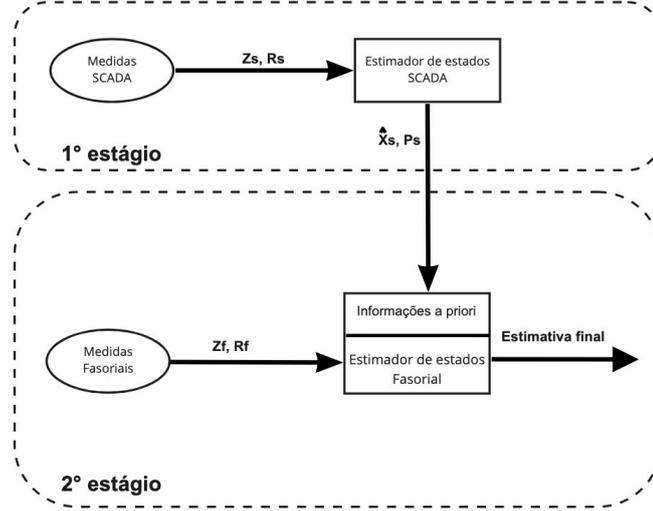


Figura 5 – Arquitetura estimador híbrido APSI.

Assim, para que as informações *a priori* sejam consideradas no processo de estimação do segundo estágio, as matrizes do método de Givens são inicializadas a partir das informações previamente adquiridas, conforme mostram as Eqs. (74), (75) e (76):

$$\bar{\mathbf{c}} = \hat{\mathbf{x}}_S \quad (74)$$

$$\bar{\mathbf{U}} = \mathbf{I}_n \quad (75)$$

$$\mathbf{D} = \mathbf{P}_S \quad (76)$$

Portanto, a função objetivo do problema APSI passa a ser denotada por (ALBUQUERQUE, A. N. C. d., 2011):

$$\min_{\hat{\mathbf{x}}} J(\hat{\mathbf{x}}) = [\mathbf{z}_F - \mathbf{H}_F \hat{\mathbf{x}}]^T \mathbf{R}^{-1} [\mathbf{z}_F - \mathbf{H}_F \hat{\mathbf{x}}] + [\hat{\mathbf{x}}_S - \hat{\mathbf{x}}]^T \mathbf{P}_S^{-1} [\hat{\mathbf{x}}_S - \hat{\mathbf{x}}] \quad (77)$$

Para a formulação da Eq.(77) utiliza-se a matriz de observação fasorial (\mathbf{H}_F), a matriz de covariância dos erros de estimação fasorial (\mathbf{R}_F), a matriz de covariância dos erros de estimação do primeiro estágio (\mathbf{P}_S), o vetor de medidas fasoriais (\mathbf{z}_F), o vetor dos estados estimados no primeiro estágio, bem como o vetor de estados a serem estimados no segundo estágio ($\hat{\mathbf{x}}$).

Seguindo as condições de otimalidade para o problema descrito pela Eq. (77), chega-se a uma versão generalizada da Equação Normal em que são incluídas as informações do primeiro estágio:

$$[\mathbf{H}_F^T \mathbf{R}_F^{-1} \mathbf{H}_F + \mathbf{P}_S^{-1}] \mathbf{x}^* = \mathbf{H}_F^T \mathbf{R}_F^{-1} \mathbf{z}_F + \mathbf{P}_S^{-1} \hat{\mathbf{x}}_S \quad (78)$$

4.3 FUSÃO DE ESTIMATIVAS

A fusão de dados manifesta-se de forma comum em diversas aplicações de Teoria da Informação, seja em sistemas biométricos de identificação que combinam impressão digital, identificação de voz e face, como para monitoramento de aviões em radares e sensores de imagens, com o objetivo de obter uma saída ótima desejada, combinando informações dos diversos sensores disponíveis (MITCHELL, 2007).

Os dispositivos que captam as informações do meio são os sensores e o local onde as informações são combinadas é chamado de célula ou centro de fusão. A partir da coleta de dados, a fusão pode assumir diferentes formas, como fusão centralizada, descentralizada ou híbrida. Estas três disposições possíveis para a fusão de dados encontram-se representadas pelas figuras 6, 7 e 8.

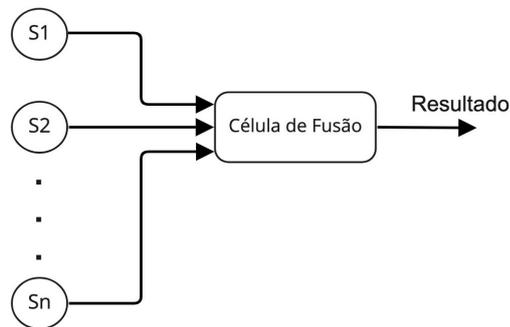


Figura 6 – Fusão de dados centralizada.

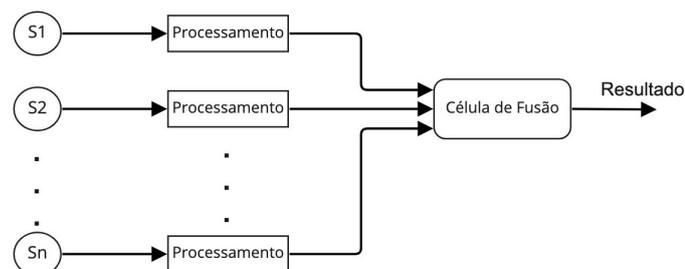


Figura 7 – Fusão de dados descentralizada.

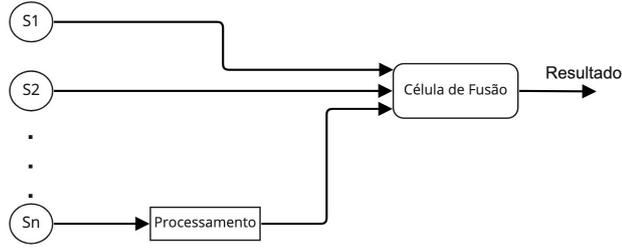


Figura 8 – Fusão de dados híbrida.

No arranjo centralizado os dados são coletados e enviados à célula de fusão, sem sofrer processamento, podendo entretanto passar por alguma etapa de filtragem. Por outro lado, quando as informações são processadas e somente então encaminhadas para a célula de fusão, diz-se que esta é uma arquitetura de fusão descentralizada. A rede híbrida, por sua vez, é uma combinação das redes centralizada e descentralizada, de modo que alguns dados são pré-processados antes e outros apenas na própria célula de fusão.

Conforme descrito anteriormente, a tipologia da fusão pode variar e a escolha da arquitetura mais apropriada depende do problema a ser abordado. Nos algoritmos de estimação híbrida de estados utiliza-se a rede de fusão descentralizada.

Portanto, considerando-se um conjunto com N_s estimativas para um vetor de estados $\hat{\mathbf{x}}$, tal que:

$$\hat{\mathbf{x}} = \hat{\mathbf{x}}_1, \dots, \hat{\mathbf{x}}_{N_s} \quad (79)$$

e os seus erros de estimação podem ser definidos como:

$$\tilde{\mathbf{x}}_i = \hat{\mathbf{x}}_i - \mathbf{x} \quad (80)$$

A matriz de covariância cruzada para os erros das estimações, $\tilde{\mathbf{x}}_1, \dots, \tilde{\mathbf{x}}_{N_s}$, será dada como (ASCARI, L. B. *et al.*, 2022):

$$\mathbf{P} = \begin{bmatrix} \mathbf{P}_{11} & \cdots & \mathbf{P}_{1N_s} \\ \vdots & \ddots & \vdots \\ \mathbf{P}_{N_s1} & \cdots & \mathbf{P}_{N_sN_s} \end{bmatrix} \quad (81)$$

Em que a submatriz \mathbf{P}_{ij} é escrita da seguinte maneira para os N_s erros das estimativas:

$$\mathbf{P}_{ij} = cov\{\tilde{\mathbf{x}}_i, \tilde{\mathbf{x}}_j\} = E[(\hat{\mathbf{x}}_i - \mathbf{x})(\hat{\mathbf{x}}_j - \mathbf{x})^T], \quad i, j = 1, \dots, N_s \quad (82)$$

A fusão das estimativas, $\hat{\mathbf{x}}_1, \dots, \hat{\mathbf{x}}_{N_s}$, é formulada segundo uma combinação linear em que são ponderadas as estimações previamente obtidas (ZHU, YM; LI, 1999), (LI *et al.*, 2003):

$$\hat{\mathbf{x}}^* = \mathbf{W}_1^T \hat{\mathbf{x}}_1 + \cdots + \mathbf{W}_{N_s}^T \hat{\mathbf{x}}_{N_s} \quad (83)$$

onde $\mathbf{W}_1, \dots, \mathbf{W}_{N_s}$ são matrizes de ponderação. Assim, reescrevendo a Eq.(83) na forma sua matricial obtém-se:

$$\mathbf{x}^* = \mathbf{W}^T \hat{\mathbf{x}} \quad (84)$$

O objetivo do problema reside em encontrar as matrizes $\mathbf{W}_1, \dots, \mathbf{W}_{N_s}$ que resultem na melhor estimativa \mathbf{x}^* . Para tanto, seja \mathbf{I} a matriz identidade, formula-se o seguinte problema de otimização a fim de minimizar o espalhamento do erro da estimativa final em relação à média (SIMÕES-COSTA; ALBUQUERQUE; BEZ, 2013), (ZHU, Yunmin, 2012):

$$\begin{aligned} \min_{\mathbf{W}} E[(\mathbf{W}^T \hat{\mathbf{x}}_i - \mathbf{x})(\mathbf{W}^T \hat{\mathbf{x}}_i - \mathbf{x})^T] \\ s.a. : \sum_{i=1}^{N_s} \mathbf{W}_i = \mathbf{I} \end{aligned} \quad (85)$$

Sendo as matrizes \mathbf{P}_{ij} não-singular, o problema de otimização apresentado na Eq.(85) passa a ter somente uma solução em \mathbf{W} (ZHU, YM; LI, 1999), (ZHU, Yunmin, 2012):

$$\mathbf{W}_i = \left(\sum_{k=1}^{N_s} \mathbf{P}_{ik}^{-1} \right) \left(\sum_{j,k=1}^{N_s} \mathbf{P}_{jk}^{-1} \right)^{-1}, \quad i = 1, \dots, N_s \quad (86)$$

4.3.1 Aplicação à EESP

Para a estimação híbrida de estados, utiliza-se o arranjo descentralizado da fusão onde os sistemas SCADA e fasorial são consideradas classes distintas de sensores da rede elétrica. A arquitetura do estimador híbrido é mostrada na Fig. 9. Os dados são obtidos via sistemas SCADA de medição e sincrofasorial, e as medidas e as suas covariâncias são enviadas para os respectivos estimadores de estados. Após serem computadas as estimativas dos estados, estas são transferidas à célula de fusão (juntamente com as respectivas matrizes ganho, ver Eq. (73) com o objetivo de se obter a solução ótima para a estimação híbrida dos estados.

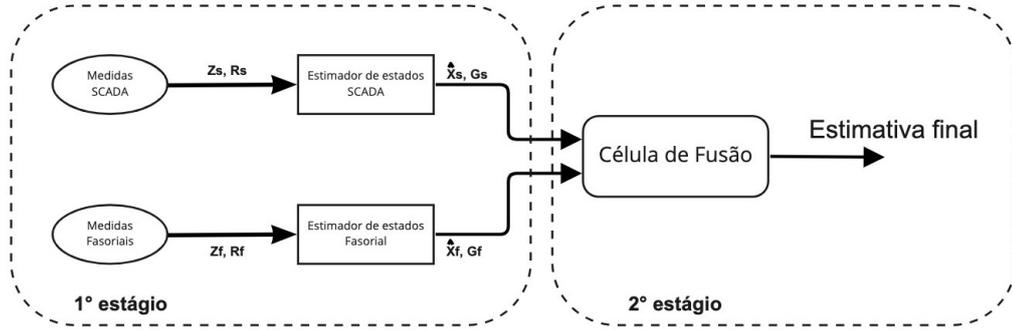


Figura 9 – Arquitetura do estimador híbrido de fusão.

No caso particular onde há dois sensores ($N_s = 2$) a solução (83) reduz-se à fórmula de fusão de Bar-Shalom-Campo (BAR-SHALOM; CAMPO, 1986):

$$\begin{aligned} \mathbf{x}^* &= (\mathbf{P}_{22} - \mathbf{P}_{21})(\mathbf{P}_{11} + \mathbf{P}_{22} - \mathbf{P}_{12} - \mathbf{P}_{21})^{-1}\hat{\mathbf{x}}_1 + \\ &+ (\mathbf{P}_{11} - \mathbf{P}_{12})(\mathbf{P}_{11} + \mathbf{P}_{22} - \mathbf{P}_{12} - \mathbf{P}_{21})^{-1}\hat{\mathbf{x}}_2 \end{aligned} \quad (87)$$

Considerando que as estimativas $\hat{\mathbf{x}}_1$ e $\hat{\mathbf{x}}_2$ são não-relacionadas, ou seja:

$$\mathbf{P}_{ij} = \mathbf{P}_{ji} = \mathbf{0} \quad (88)$$

a solução ótima da estimação híbrida passa a ser:

$$\mathbf{x}^* = \mathbf{P}_{22}(\mathbf{P}_{11} + \mathbf{P}_{22})^{-1}\hat{\mathbf{x}}_1 + \mathbf{P}_{11}(\mathbf{P}_{11} + \mathbf{P}_{22})^{-1}\hat{\mathbf{x}}_2 \quad (89)$$

Assim, considerando os subscritos S para o sistema SCADA e F para as grandezas fasoriais, tem-se:

$$\mathbf{x}^* = \mathbf{P}_F(\mathbf{P}_S + \mathbf{P}_F)^{-1}\hat{\mathbf{x}}_S + \mathbf{P}_S(\mathbf{P}_S + \mathbf{P}_F)^{-1}\hat{\mathbf{x}}_F \quad (90)$$

Conforme apresentado em (73), as matrizes de covariância dos erros de estimação \mathbf{P}_S e \mathbf{P}_F são iguais às inversas das matrizes de ganho \mathbf{G}_S e \mathbf{G}_F (SCHWEPPE; WILDES, 1970). Assim reescrevendo a Eq. (90):

$$\mathbf{x}^* = \mathbf{G}_F^{-1}(\mathbf{G}_S^{-1} + \mathbf{G}_F^{-1})^{-1}\hat{\mathbf{x}}_S + \mathbf{G}_S^{-1}(\mathbf{G}_S^{-1} + \mathbf{G}_F^{-1})^{-1}\hat{\mathbf{x}}_F \quad (91)$$

Devido ao alto custo computacional necessário para o cálculo da inversão das matrizes, propõe-se a seguinte formulação equivalente à Eq. (91) (SIMÕES-COSTA; ALBUQUERQUE; BEZ, 2013):

$$\mathbf{x}^* = (\mathbf{G}_S + \mathbf{G}_F)^{-1} \mathbf{G}_S \hat{\mathbf{x}}_S + (\mathbf{G}_S + \mathbf{G}_F)^{-1} \mathbf{G}_F \hat{\mathbf{x}}_F \quad (92)$$

Rearranjando a Eq. (92) de maneira a representar a fusão como um sistema linear ($Ax = b$):

$$(\mathbf{G}_S + \mathbf{G}_F) \mathbf{x}^* = \mathbf{G}_S \hat{\mathbf{x}}_S + \mathbf{G}_F \hat{\mathbf{x}}_F \quad (93)$$

A equação (93) representa a fórmula fundamental da estimação de estados híbrida em sistemas de potência baseada na fusão de estimativas. Essa equação é uma alternativa preferível em relação à equação (92), pois evita a necessidade de inversões de matrizes e permite a utilização de técnicas de esparsidade em relação às matrizes ganho. Isso traz benefícios significativos para o desempenho computacional do processo de estimação. Além disso, a solução obtida por meio da equação (93) é vantajosa, uma vez que as matrizes ganho já estão disponíveis a partir das soluções do primeiro estágio de estimação. Essa abordagem simplifica o processo de fusão de estimativas, tornando-o mais eficiente e facilitando sua implementação prática (SIMÕES-COSTA; ALBUQUERQUE; BEZ, 2013).

Por conta da linearidade do modelo proposto, é vantajoso realizar uma transformação de coordenadas. Dessa forma, neste trabalho, optou-se por realizar a fusão de estimativas em coordenadas retangulares.

4.4 CONCLUSÃO

O presente Capítulo apresenta a estimação híbrida para os estados da rede elétrica. Em ambas as arquiteturas de estimação abordadas, APSI e fusão, são mantidos íntegros os estimadores já existentes, e a partir deles são incorporadas as medições provenientes do sistema de medição fasorial visando o refinamento dos resultados obtidos.

A arquitetura APSI consiste de duas etapas, em que as estimações das medidas do sistema SCADA são computadas no primeiro estágio. Estes resultados apresentam-se como informações *a priori* para a estimação de estados do segundo estágio, onde são inseridas as medidas provenientes das unidades de medição fasorial. O estimador híbrido de fusão também é composto por múltiplos módulos. Primeiramente o estimador convencional, que processa medições do sistema SCADA, e o estimador que processa medidas sincrofasoriais geram estimativas independentes. Posteriormente estes resultados são encaminhados para a célula de fusão. Nesta etapa, a partir da teoria de fusão de dados, as estimativas são então combinadas, desta forma gerando a estimativa de estados ótima final.

Em termos computacionais, para que os modelos tornem-se lineares é válido utilizar as medidas fasoriais em coordenadas retangulares. Em consequência dessa transformação surgem correlações entre as partes reais e imaginárias das componentes convertidas. O método baseado em rotações de Givens, como mostrado no capítulo em blocos garante

robustez numérica e possibilita que estas correlações sejam respeitadas e levadas em consideração para os cálculos das estimações de estados.

5 PROCESSAMENTO DE ERROS GROSSEIROS

5.1 INTRODUÇÃO

Falhas em transdutores, imprecisões de equipamentos, erros humanos, erros de transmissão de dados ou inexatidão na topologia da rede podem ocasionar medidas espúrias que não devem compor o conjunto de medições utilizadas, sob pena de contaminar os valores das estimativas para os estados (MONTICELLI, 1999). É preciso garantir que o processo de estimação de estados forneça valores precisos e corretos. Por isso é necessário que funções ligadas ao estimador de estados consigam verificar a presença dos chamados erros grosseiros (EGs) ou *outliers*, que são medidas que violam a hipótese de normalidade de sua distribuição estatística, ou seja, cuja magnitude de erro supera uma tolerância definida em termos do desvio padrão da medida (ABUR; EXPOSITO, 2004).

Após a estimação dos estados, as etapas convencionais do processamento de erros no processo são:

1. Detecção;
2. Identificação;
3. Remoção ou recuperação.

Neste capítulo serão abordadas as etapas do processamento clássico de erros grosseiros. No presente trabalho são considerados erros grosseiros de medição, de maneira que se supõe que a topologia bem como os parâmetros elétricos da rede não contêm erros.

5.2 DETECÇÃO

Nesta dissertação, é adotada a hipótese clássica de que os erros aleatórios das medidas seguem a distribuição normal com média zero e variância fixa. Portanto, em condições normais os seus resíduos não possuem altos valores. Um erro grosseiro pode ser detectado mediante análise dos resíduos de medição (ou de uma função destes), pois o valor do resíduo de uma medida contaminada por erro grosseiro estará acima do esperado para as condições normais. Para a i -ésima medida, o resíduo de medição ponderado pode ser calculado da seguinte forma

$$r_{w,i} = \frac{z_i - \hat{z}_i}{\sigma_i} = \frac{z_i - h_i(\hat{\mathbf{x}})}{\sigma_i} \quad (94)$$

em que z_i e \hat{z}_i são o valor e a estimativa da medida i , respectivamente, e σ_i é o desvio padrão.

Para um conjunto com m medidas, é computada a Soma Ponderada dos Quadrados dos Resíduos (SPQR):

$$J(\hat{\mathbf{x}}) = \sum_{i=1}^m \frac{[z_i - h_i(\hat{\mathbf{x}})]^2}{\sigma_i^2} = \sum_{i=1}^m r_{w,i}^2 \quad (95)$$

e caso esse conjunto possua erros grosseiros o valor da SPQR também tende a ser elevado.

A detecção de erros grosseiros por meio do valor de $J(\hat{\mathbf{x}})$ é realizada com base em testes estatísticos de hipóteses. Para um dado plano de medição, como as variáveis são supostas não-correlacionadas, possuem média zero e variância fixa determinada pelo próprio instrumento medidor, em uma situação livre de erros espúrios esta função segue a distribuição do χ^2 com $m - n$ graus de liberdade, em que m é o número de medidas e n é o número de variáveis de estado. A função densidade de probabilidade da distribuição do χ^2 com ν graus de liberdade é representada pela Eq. (96) (HANDSCHIN *et al.*, 1975; MONTICELLI, A.; GARCIA, 1983):

$$f(t) = \frac{t^{\frac{\nu}{2}-1} e^{-\frac{t}{2}}}{2^{\frac{\nu}{2}} \Gamma(\frac{\nu}{2})} \quad (96)$$

Nesse problema, há duas hipóteses consideradas, a hipótese básica (H_0) e a hipótese complementar (H_1). A primeira hipótese supõe que o valor de $J(\hat{\mathbf{x}})$ segue a distribuição do χ^2 com $m - n$ graus de liberdade. Já a hipótese complementar supõe a hipótese H_0 como falsa.

No procedimento de testes de hipóteses, podem ocorrer dois tipos de erros: erro do tipo I, onde se rejeita Hipótese H_0 quando ela é verdadeira, ou seja, presume-se que há um erro grosseiro no conjunto de medidas, mas na realidade não há. Esta situação caracteriza o chamado falso alarme E. Já no erro do tipo II a hipótese básica é dada como verdadeira, mas é, na verdade, falsa. O erro do tipo II é um erro de não detecção, pois há medida espúria no conjunto m e o teste não o capturou (MONTICELLI, A.; GARCIA, 1983).

No teste- $J(\hat{\mathbf{x}})$ ou teste- χ^2 , as seguintes inferências são realizadas:

- Se $J(\hat{\mathbf{x}}) > K$: H_0 é falsa, há erro grosseiro no plano de medição;
- Se $J(\hat{\mathbf{x}}) \leq K$: H_0 é verdadeira, não há erro grosseiro no plano de medição.

O limiar K é definido com base na probabilidade de falso alarme α , a qual é um valor pré-determinado e fixado, geralmente em torno de percentuais de 1% a 5%, e no número de medidas e variáveis de estado do problema. Mostra-se que (HANDSCHIN *et al.*, 1975)(MONTICELLI, A.; GARCIA, 1983)(ABUR; EXPOSITO, 2004):

$$K = \chi_{m-n, 1-\alpha}^2 \quad (97)$$

Portanto se $J(\hat{\mathbf{x}}) > K$ rejeita-se, com uma probabilidade de falso alarme α , a hipótese de que $J(\hat{\mathbf{x}})$ segue a distribuição do χ^2 , enquanto que se $J(\hat{\mathbf{x}}) \leq K$ assume-se que $J(\hat{\mathbf{x}})$ segue a distribuição do χ^2 .

5.3 IDENTIFICAÇÃO

Após ter sido detectado, o erro grosseiro deve ser identificado. O método de identificação utilizado nesta etapa é o Teste do Máximo Resíduo Normalizado. Quando há a situação em que no conjunto de medidas há a presença de uma medida espúria e supondo que a redundância do plano de medição é suficientemente alta, aquela medida com o maior resíduo normalizado é então considerada como a portadora do erro (HANDSCHIN *et al.*, 1975).

Os resíduos são computados da seguinte forma:

$$\mathbf{r} = \mathbf{z} - \mathbf{h}(\hat{\mathbf{x}}) \quad (98)$$

Conforme já mencionado, os resíduos devem ser normalizados antes que suas magnitudes sejam comparadas. A normalização é feita com base na variância associada a este resíduo. Como um erro grosseiro pode afetar resíduos de medidas corretas, este processo ameniza este e outros efeitos que podem afetar a inspeção da medida errônea (HANDSCHIN *et al.*, 1975; MONTICELLI, A.; GARCIA, 1983; MONTICELLI, 1999).

Para uma medida i o seu resíduo é normalizado com base no i -ésimo termo diagonal da matriz de covariância dos resíduos \mathbf{W} . Esta matriz é dada a partir de (MONTICELLI, A.; GARCIA, 1983):

$$\mathbf{W} = \mathbf{R} - \mathbf{H}\mathbf{G}^{-1}\mathbf{H}^T \quad (99)$$

Portanto, o resíduo normalizado r_N para uma medida i será:

$$r_{N,i} = \frac{r_i}{\sqrt{W_{ii}}} \quad (100)$$

5.4 REMOÇÃO E RECUPERAÇÃO

Ao ser identificada, a medida portadora de erro grosseiro deve passar pela etapa de remoção ou, alternativamente, de recuperação e então uma nova estimativa livre de erros pode ser obtida. Ambos os métodos, para a maioria dos casos, conduzem a resultados satisfatórios e similares (ABUR; EXPOSITO, 2004).

O processo de remoção afeta estruturalmente a nova estimação, pois retira das matrizes e dos vetores utilizados na estimação de estados, as linhas e colunas referentes à medida errônea.

O método de recuperação não altera a estrutura das matrizes e vetores para a estimação de estados. Remove-se da medida espúria o valor estimado para o de erro e então os estados serão re-estimados considerando este valor ajustado da medida recuperada (ABUR; EXPOSITO, 2004).

Para uma medida i portadora de EG, a sua descrição pode ser dada a partir de seu valor verdadeiro (z_{i_0}) acrescentado do erro grosseiro (ζ_i):

$$z_i = z_{i_0} + \zeta_i \quad (101)$$

O erro é aproximado a partir do resíduo da medida i em conjunto com a razão entre a covariância da medida com a covariância do erro de medição (ABUR; EXPOSITO, 2004):

$$\zeta_i \approx \frac{R_{ii}}{W_{ii}} r_i \quad (102)$$

Como a medida espúria é recuperada a partir de seu resíduo, verifica-se após este processo que a medida ajustada terá resíduo nulo (SIMOES-COSTA; SALGADO, 1983). Substituindo a Eq. (102) na Eq. (101) a medida recuperada é calculada por:

$$z_{i,rec} = z_i - \frac{R_{ii}}{W_{ii}} r_i \quad (103)$$

5.5 PROCESSAMENTO DE ERROS E G3M

5.5.1 Detecção

O processo de detecção em conjunto com o método de Givens pode ser realizado a cada vez que o processamento de uma medida (juntamente com a linha da matriz Jacobiana correspondente) é concluído. Caso esta medida seja redundante com outras já processadas, o valor da SPQR sofre um acréscimo que depende do resíduo de estimação resultante para a medida. Considerando um plano de medição para uma rede com n variáveis de estado, se k medidas em um conjunto de m medidas foram previamente processadas e o valor da SPQR para a medida k é superior ao valor de SPQR da medida $k - 1$, o teste $J(\hat{\mathbf{x}})$ deve ser aplicado. Neste caso, o número de graus de liberdade \mathbf{v} para o cálculo do limiar K do teste de detecção torna-se variável, sendo incrementado sempre que a medida k mostrar-se redundante com as medidas anteriormente processadas (QUINTANA; SIMOES-COSTA; MIER, 1982).

Se, ao concluir o processamento da medida k , a SPQR torna-se maior que o limiar variável, isto não necessariamente significa que esta medida é a errônea, mas sim que alguma dentre as medidas redundantes com a medida k já processadas é portadora de erro grosseiro. Portanto, a informação a ser registrada é que há uma medida errônea no subconjunto formado pelas k primeiras medidas já sofreram processamento pelo estimador G3M (QUINTANA; SIMOES-COSTA; MIER, 1982).

5.5.2 Identificação

Pelo processo de triangularização da matriz Jacobiana pode-se reescrever a matriz ganho \mathbf{G} em função das matrizes \mathbf{U} e \mathbf{D} , obtidas por meio das rotações de Givens, aprimorando computacionalmente o cálculo da matriz de covariância dos resíduos. É possível mostrar que (QUINTANA; SIMOES-COSTA; MIER, 1982):

$$\mathbf{G} = \bar{\mathbf{U}}^T \mathbf{D} \bar{\mathbf{U}} \quad (104)$$

Substituindo \mathbf{G} no cálculo da matriz de covariância dos resíduos:

$$\mathbf{W} = \mathbf{R} - \mathbf{H} \left(\bar{\mathbf{U}}^T \mathbf{D} \bar{\mathbf{U}} \right)^{-1} \mathbf{H}^T \quad (105)$$

$$\mathbf{W} = \mathbf{R} - \mathbf{Y} \mathbf{D}^{-1} \mathbf{Y}^T \quad (106)$$

onde $\mathbf{Y} = \mathbf{H} \bar{\mathbf{U}}^{-1}$.

Para o processo de normalização são utilizados somente os elementos diagonais da matriz \mathbf{W} . A representação do i -ésimo elemento dessa matriz é:

$$W_{ii} = R_{ii} - \sum_{\ell=1}^n \left(\frac{Y_{i\ell}^2}{D_{\ell\ell}} \right) \quad (107)$$

5.5.3 Remoção

O método das rotações de Givens permite que após a identificação da medida espúria, seus efeitos sobre as matrizes $\bar{\mathbf{U}}$ e \mathbf{D} sejam removidos, reprocessando-se a medida identificada com um peso igual em valor absoluto ao peso original da medida errônea, mas agora com o sinal negativo. Este procedimento não pode ser utilizado quando a estimação é realizada por meio do método da equação normal, pois esta estratégia deriva da ortogonalidade das rotações de Givens (AMARAL, 1987).

5.5.4 Recuperação

A estratégia de recuperação, conforme delineada pelo equacionamento apresentado em (103), constitui uma ferramenta significativa no contexto do tratamento de medidas errôneas. Esta técnica permite reintegrar medidas previamente identificadas como inadequadas, após a aplicação de correções adequadas. É fundamental destacar que essa abordagem pode ser efetivamente combinada com o método da equação normal. Tal compatibilidade deve-se ao fato de que a estratégia de recuperação não provém da ortogonalidade das rotações de Givens. Portanto, a aplicação conjunta desses métodos pode potencializar a eficiência e a precisão no tratamento de dados e na detecção e correção de erros.

5.6 PROCESSAMENTO DE ERROS E G3M EM BLOCOS

Com o método de G3M em blocos, as linhas da matriz de observação são processadas em coordenadas retangulares e aos pares, sendo um par formado pela parte real e parte imaginária de cada medida sincrofásorial de tensão ou corrente. Conseqüentemente, os elementos das matrizes $\bar{\mathbf{U}}$ e \mathbf{D} deixam de ser escalares e passam a ser blocos 2×2 . Nesse caso como as matrizes de covariância continuam positivas definidas, na ausência de erros grosseiros a soma ponderada dos quadrados dos resíduos segue apresentando a distribuição do χ^2 (CARO; CONEJO; MINGUEZ, 2009). Conseqüentemente, os procedimentos para processamento de erros grosseiros anteriores podem ainda ser aplicados, com algumas adaptações, conforme discutido a seguir.

5.6.1 Detecção

Como as medidas estão representadas em sua forma cartesiana, ao ser processada uma medida devem ser contabilizadas ambas as suas partes componentes, real e imaginária, no método de detecção, que é aplicado somente após o processamento completo do par formado por estas componentes. Nesse caso o número de graus de liberdade deve ser atualizado como:

$$\mathbf{v} = \mathbf{v} + 2 \quad (108)$$

5.6.2 Identificação

Devem ser levadas em consideração a correlação existente entre as partes reais e imaginárias das medidas. Cada bloco 2×2 da matriz de covariância pode ser representado por:

$$\mathbf{W} = \begin{bmatrix} W_{xx} & W_{xy} \\ W_{yx} & W_{yy} \end{bmatrix} \quad (109)$$

Estendendo a formulação apresentada na Eq.(110) para um *i-ésimo* bloco da matriz \mathbf{W} . Utilizando os blocos das matrizes \mathbf{R} , \mathbf{D} e \mathbf{V} , onde n equivale ao número de estados:

$$\mathbf{W}_{ii} = \mathbf{R}_{ii} - \sum_{\ell=1}^n \mathbf{Y}_{i\ell} \mathbf{D}_{\ell\ell}^{-1} \mathbf{Y}_{i\ell}^T \quad (110)$$

5.6.3 Remoção

A remoção via G3M em blocos utiliza uma extensão da propriedade de reprocessamento apresentada na versão escalar do método. São removidas as partes real e imaginária da medida espúria utilizando-se um bloco de ponderação 2×2 igual ao negativo do bloco de ponderação originalmente utilizado para a medida errônea. Evita-se assim que o para

implementar a correção o processamento seja feito desde o início (ZANLORENSI, E., 2021).

5.6.4 Recuperação

A técnica de recuperação em blocos, baseada no G3M, se beneficia de uma extensão da propriedade de reprocessamento encontrada na implementação escalar original do método. Neste cenário, tanto a componente real quanto a imaginária da medida espúria são recuperadas ao aplicar a expansão em blocos da equação (103). Este método apresenta a vantagem significativa de evitar a necessidade de reinicializar o processamento desde o início para efetuar a correção, resultando em otimização do tempo de processamento e melhor utilização dos recursos computacionais, proporcionando uma correção de erros mais ágil e eficiente (ZANLORENSI, E., 2021).

5.7 CONCLUSÃO

Este capítulo aborda o processamento de erros grosseiros na estimação de estados, apresentando cada uma das fases (detecção, identificação e remoção/recuperação).

É apresentado o teste estatístico de hipóteses baseado na distribuição do χ^2 aplicado à SPQR para a detecção de erros grosseiros. Para identificar a medida espúria é aplicado o Teste do Máximo Resíduo Normalizado, onde a medida errônea será aquela que apresentar o maior valor computado. A remoção utiliza a propriedade de reprocessamento da técnica G3M, com um peso igual ao negativo do peso originalmente associado à medida errônea. Já a recuperação evita alterações na estrutura das matrizes e vetores que implementam o método dos mínimos quadrados ponderados, ao gerar uma pseudomedida que remove a magnitude estimada do erro da medida grosseira.

Pelo fato de que as medidas sincrofasoriais devem ser representadas em sua forma cartesiana, apresenta também a extensão do método de processamento de EGs para a técnica de G3M em que os elementos das matrizes envolvidas deixam de ser escalares e passam a ser blocos 2×2 . Isto se deve ao processamento simultâneo das partes real e imaginária das medidas, cujo objetivo é levar em consideração a correlação existente entre elas.

6 PROCESSAMENTO DE ERROS GROSSEIROS EM SISTEMAS DE GRANDE PORTE: DEFICIÊNCIAS E ESTRATÉGIAS CORRETIVAS

6.1 INTRODUÇÃO

Como mostrado na Seção 5.2, a aplicação do teste- $J(\hat{\mathbf{x}})$ envolve a definição de um limiar baseado no número de graus de liberdade da distribuição do χ^2 . A magnitude do erro e a redundância local afetam diretamente as variações da SPQR, resultantes da ocorrência do erro grosseiro. Porém, verifica-se, na prática, uma tendência, à medida que aumenta o porte do sistema elétrico, de perceptível queda de sensibilidade na detecção de erros grosseiros baseada no teste- $J(\hat{\mathbf{x}})$ convencional. Isto é uma consequência do fato de que medidas eletricamente distantes do ponto onde ocorre a medida espúria contribuem pouco para o aumento no valor de $J(\hat{\mathbf{x}})$, pois seus resíduos tendem a ser pouco afetados pelo erro grosseiro. Por outro lado, essas medidas são ainda assim contabilizadas no cálculo do número de graus de liberdade da distribuição do χ^2 , contribuindo portanto para o aumento no limiar e degradando a precisão do teste. Esta deficiência ocorre mesmo que a rede apresente um nível de redundância elevado (MONTICELLI, A.; GARCIA, 1983).

Uma forma viável e eficiente de contornar esta deficiência do teste- $J(\hat{\mathbf{x}})$ consiste em realizar o particionamento do conjunto de medidas disponíveis ao estimador em subconjuntos disjuntos. Estes, por sua vez, induzem a partição da rede em agrupamentos, ou *clusters*. Isto viabiliza a aplicação de testes- $J(\hat{\mathbf{x}})$ individuais a cada um desses *clusters*. Por limitar a região de espalhamento de erros grosseiros a resíduos de medidas na mesma partição da rede — as quais estão portanto eletricamente mais próximas da medida espúria — esta estratégia tem potencial para promover melhorias significativas no desempenho do método de detecção (ZANLORENSI, E., 2021).

Na sequência do capítulo, será primeiramente abordada a degradação no desempenho do teste- $J(\hat{\mathbf{x}})$ para redes de grande porte. Em seguida será introduzida a técnica de particionamento da rede elétrica em função do plano de medição existente, e por fim será descrita a aplicação da técnica para o processamento de erros grosseiros.

6.2 DEGRADAÇÃO NO DESEMPENHO DO TESTE- $J(\hat{x})$ PARA REDES DE GRANDE PORTE

Na aplicação do teste- $J(\hat{\mathbf{x}})$ para detecção de medidas espúrias, espera-se que o incremento causado na SPQR pela ocorrência de um erro grosseiro faça com que o limiar definido pela distribuição do χ^2 do teste- $J(\hat{\mathbf{x}})$ seja superado, desde que haja suficiente redundância local e que a magnitude do EG seja significativa. Porém observa-se que o número $k = m - n$ de graus de liberdade, da distribuição do χ^2 é outro fator que afeta diretamente o desempenho do teste, já que dele depende a definição do limiar de detecção. Adicionalmente, k é fortemente influenciado pela dimensão da rede elétrica,

de tal forma que quanto maior a rede, maior o limiar. Isto não seria um problema se a grande maioria dos resíduos das medidas fossem afetados pela ocorrência de um erro grosseiro na rede. Entretanto, em sistemas de grande porte verifica-se que os resíduos de medidas eletricamente distantes da localização da medida espúria sofrem muito pouca influência do erro. Conseqüentemente tendem a não contribuir significativamente para a SPQR. Criam-se assim situações, em redes de grande porte, em que o limiar do teste eleva-se a ponto de não capturar erros grosseiros cujas magnitudes são menores do que um dado valor (MONTICELLI, A.; GARCIA, 1983).

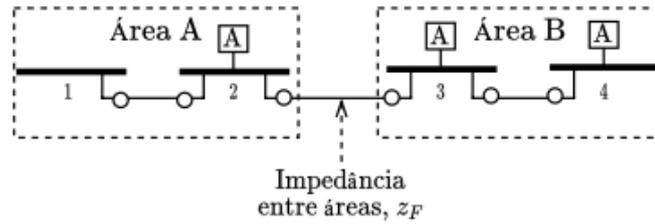


Figura 10 – Impedância entre duas áreas (ZANLORENSI, E., 2021).

Para ilustrar a situação acima descrita, seja o sistema de potência formado pelas áreas A e B da figura 10, interligadas pelo ramo 2-3, cuja impedância é z_F . Tomando como referência a barra 1, são medidos os ângulos dos barramentos 2, 3 e 4 e os fluxos entre os barramentos, conforme indicado na figura 10. As medidas de fronteira são os fluxos entre as barras 2 e 3, fluxo 2-3 e 3-2. A relação entre os resíduos das medidas e os erros de medição é dada por (ABUR; EXPOSITO, 2004):

$$\mathbf{r} = \mathbf{S}\boldsymbol{\eta} \quad (111)$$

onde $\mathbf{S} = \mathbf{WR}^{-1}$ é a matriz de sensibilidade dos resíduos e $\boldsymbol{\eta}$ é o vetor de erros de medição. Definindo o vetor de medidas para cada uma das áreas A e B e da fronteira (F) da Fig.10 por:

$$\mathbf{z} = \begin{bmatrix} z_A \\ z_F \\ z_B \end{bmatrix}, \quad (112)$$

a matriz de sensibilidade pode ser particionada da seguinte forma:

$$\mathbf{S} = \begin{bmatrix} \mathbf{S}_{AA} & \mathbf{S}_{AF} & \mathbf{S}_{AB} \\ \mathbf{S}_{FA} & \mathbf{S}_{FF} & \mathbf{S}_{FB} \\ \mathbf{S}_{BA} & \mathbf{S}_{BF} & \mathbf{S}_{BB} \end{bmatrix} \quad (113)$$

Logo, de (111):

$$\begin{aligned} \mathbf{r}_A &= \mathbf{S}_{AA}\boldsymbol{\eta}_A + \mathbf{S}_{AF}\boldsymbol{\eta}_F + \mathbf{S}_{AB}\boldsymbol{\eta}_B \\ \mathbf{r}_B &= \mathbf{S}_{BA}\boldsymbol{\eta}_A + \mathbf{S}_{BF}\boldsymbol{\eta}_F + \mathbf{S}_{BB}\boldsymbol{\eta}_B \end{aligned} \quad (114)$$

A distância elétrica entre as áreas afeta diretamente a impedância que há entre elas: quanto maior a distância elétrica, maior a impedância z_F . O aumento da distância elétrica entre as áreas causa uma queda nos elementos das submatrizes \mathbf{S}_{AB} e \mathbf{S}_{BA} . Considerando que as variâncias dos medidores são unitárias, a matriz \mathbf{S} torna-se simétrica, o que implica que $S_{BA} = S_{AB}^T$. Desta forma, o aumento progressivo na impedância do ramo de fronteira provoca a redução gradativa da norma $\|\mathbf{S}_{AB}\|$. No limite, isto é, para valores altos de Z_F , conclui-se de (114) que a sensibilidade dos resíduos da área A em relação aos erros da área B tende a zero, e vice-versa (ZANLORENSI, E., 2021).

6.3 PARTICIONAMENTO DO PLANO DE MEDIÇÃO

6.3.1 O conceito de agrupamentos de medidas

Nesta dissertação, aborda-se o tema da estimação híbrida de estados por meio do método de fusão de estimativas. O tema central desta discussão é a estratégia de particionamento da rede, a qual é definida em termos do plano de medição e desempenha um papel crítico para um processamento eficiente e efetivo na estimação de estados.

O objetivo é para aplicar a estratégia de particionamento do plano de medição ao módulo de estimação que processa medidas sincrofasoriais na arquitetura híbrida baseada na fusão de estimativas.

É fundamental ressaltar que assume-se a existência de um estimador SCADA operante, que fornece as entradas necessárias para a estimação híbrida. Este Sistema de Supervisão e Aquisição de Dados é uma estrutura robusta e consolidada, utilizada para o monitoramento e controle de processos à distância. Assim, supõe-se que os procedimentos de processamento de erros grosseiros deste sistema já estão em plena operação e que não estão sujeitos a modificações.

Neste contexto, o foco do trabalho recai sobre o aprimoramento da estimação híbrida de estados, mais especificamente através aplicação da estratégia de particionamento da rede. Este procedimento de partição é, portanto, definido em função do plano de medição, considerando as medidas sincrofasoriais de tensão e de corrente.

Dessa forma, o plano de medição será particionado em agrupamentos de medidas internas e de fronteira a estes agrupamentos. Considerando um sistema com um conjunto de barras S_b com n_c agrupamentos definido como (ZANLORENSI, E., 2021):

$$S_b = \{\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_{n_c}\} \mid \mathbf{b}_i \cap \mathbf{b}_j = \emptyset \quad \forall i \neq j \quad (115)$$

Com esta estrutura pode-se aplicar as rotações de Givens para cada um dos blocos dos subconjuntos de maneira independente, e cada incremento na SPQR resultante do processamento de medidas internas a um dado agrupamento é associado somente a este grupo de medidas. Portanto, pode-se utilizar um teste- $J(\hat{\mathbf{x}})$ para cada agrupamento de medidas internas durante a fatoração ortogonal. Para as medidas de fronteira dos agrupamentos, aplica-se um teste- $J(\hat{\mathbf{x}})$ tradicional, pois a fronteira, por definição, envolve estados de dois ou mais agrupamentos (ZANLORENSI, E., 2021).

Como o agrupamento das medidas de fronteira segue suscetível à perda de sensibilidade do teste- $J(\hat{\mathbf{x}})$, devem ser buscados particionamentos que reduzam o tamanho deste agrupamento.

6.3.2 Grafo de medição fasorial

Na aplicação da teoria de grafos para descrever as partições da rede no contexto da estimação híbrida de estados, um conceito chave é o grafo de medição fasorial. Neste grafo, os vértices são representados pelas barras do sistema de potência que contêm PMU.

Por outro lado, as arestas do grafo são definidas pelas medidas sincrofasoriais de corrente. Para cada medida de corrente existente entre duas barras com, cria-se uma aresta não direcionada, ligando os vértices correspondentes a essas barras. A Figura 11 exemplifica o grafo de medição fasorial, destacado em azul. Os vértices azuis representam os barramentos com PMU, os vértices cinzas circulado em azul não possuem PMU, mas possuem uma pelo menos uma linha em comum com um barramento que possui PMU, ou seja, a corrente está sendo diretamente monitorada nesse ramo, enquanto os vértices cinzas não possuem nem PMU, nem ramo com medição direta de corrente. As arestas azuis constituem, por definição, o grafo de medição fasorial, pois nelas há medidas sincrofasoriais de corrente em pelo menos um vão de linha. No entanto, as arestas tracejadas, pertencem e interconectam os barramentos da rede, mas não são representadas no grafo de medição fasorial, pois não ocorre a medição direta de corrente nestas linhas.

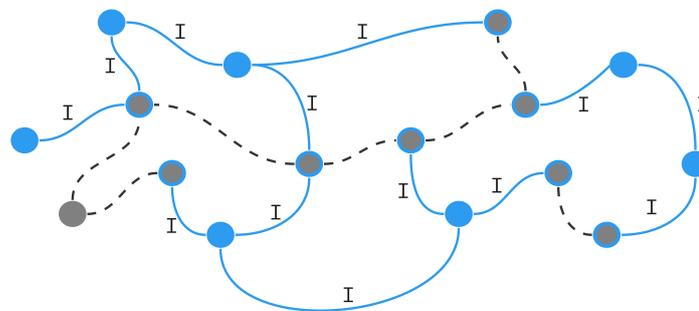


Figura 11 – Grafo de medição fasorial.

O conceito de grafo de medição fasorial desempenha um papel fundamental na

concepção do algoritmo de particionamento. Ao aplicar a teoria dos grafos para descrever as partições do plano de medição fasorial no contexto da estimação híbrida de estados, o grafo de medição se torna um elemento essencial. O algoritmo de particionamento, que é detalhado na Subseção 6.3.4, utilizará esse conceito para dividir adequadamente a rede em *clusters*, permitindo uma melhor abordagem no contexto da estimação híbrida de estados do sistema elétrico.

6.3.3 Critérios de clusterização

O objetivo do método de clusterização da rede é minimizar o número de interligações entre os agrupamentos do sistema. Para isso, a definição dos *clusters* se baseia em critérios específicos, que podem ser detalhados da seguinte forma:

- Minimizar o número de medidas de fronteira entre os agrupamentos;
- Agrupamentos devem apresentar dimensões semelhantes (Critério de Equilíbrio);

O particionamento do plano de medição deve satisfazer ambos os critérios. Para tanto, aplica-se a técnica de Corte Normalizado para processamento de imagens descrita em (SHI; MALIK, 2000).

6.3.4 Cortes Normalizados no Particionamento do Plano de Medição Fasorial

Os cortes normalizados têm por objetivo estabelecer grupos de barras, de forma a assegurar que os critérios de clusterização sejam seguidos. A compreensão dos objetivos do algoritmo de particionamento do grafo de medição segundo cortes normalizados é importante para se ter uma visão clara de como seus resultados se aplicam ao problema em questão. Inicialmente, é necessário compreender as variáveis empregadas na rotina de corte.

Seja o grafo de medição fasorial G cujo conjunto de n vértices é definido como $V = \{v_1, v_2, \dots, v_n\}$. Conforme já mencionado, cada vértice representa uma barra da rede elétrica. O grafo G é ponderado, sendo os pesos dos ramos definidos de acordo com a aplicação em questão. No presente caso, o esquema de ponderação será discutido mais adiante.

A descrição do algoritmo requer a definição de algumas matrizes associadas ao grafo G (DEO, 2017):

- A : matriz de adjacências $n \times n$ de G , onde o elemento a_{ij} corresponde ao peso do ramo que conecta os vértices i e j ;
- δ : matriz de graus (ou valências) dos vértices, é uma matriz diagonal onde o elemento δ_{ii} é a soma dos pesos de todos os ramos que saem do vértice i . Assim, $\delta_{ii} = \sum_{j=1}^n a_{ij}$;
- L : matriz Laplaciana do grafo G . Definida como $L = \delta - A$.

Considere a definição de nc subconjuntos $U_j, j = 1, \dots, nc$, de V tal que:

$$U_1 \cup U_2 \cup \dots \cup U_{nc} = V$$

Cada vértice do grafo G deve pertencer a um e apenas um desses subconjuntos (DEO, 2017), portanto:

$$U_i \cap U_j = \emptyset, \forall i \neq j$$

Finalmente, define-se uma função de corte \mathcal{W} , que informa o quão conectados são os agrupamentos (ZANLORENSI, E., 2021):

$$\mathcal{W}(U_A, U_B) = \sum_{\substack{v_i \in U_A \\ v_j \in U_B}} a_{i,j} \quad (120)$$

A função \mathcal{W} recebe como entrada dois agrupamentos U_A e $U_B \in V$, e fornece como saída a soma dos pesos do conjunto de corte que desconecta ambos (DEO, 2017). Dessa forma, $\mathcal{W}(U_A, U_B)$ é uma medida de interconexão entre esses dois subconjuntos de vértices.

Portanto, para um conjunto com nc agrupamentos a função corte será dada por (ZANLORENSI, E., 2021):

$$corte(U_1, U_2, \dots, U_{nc}) = \frac{1}{2} \sum_{i=1}^k \mathcal{W}(U_i, \bar{U}_i) \quad (121)$$

A função de corte em (121) permite contemplar o primeiro dos critérios estabelecidos na Subseção 6.3.3, porém não considera a necessidade de balancear o tamanho dos agrupamentos entre si. Para isso, emprega-se o conceito de *corte normalizado*. A estratégia de normalização dos cortes leva em conta o tamanho das partições, permitindo a observância do Critério de Equilíbrio da Subseção 6.3.3.

A função de corte normalizada, denominada $cortenorm$, é definida como (SHI; MALIK, 2000), (ZANLORENSI, E., 2021):

$$cortenorm(U_1, U_2, \dots, U_{nc}) = \frac{1}{2} \sum_{i=1}^k \frac{\mathcal{W}(U_i, \bar{U}_i)}{s(U_i)} \quad (122)$$

onde $s(U_i)$ é a soma dos graus de todos os vértices no conjunto U_i .

Finalmente, é preciso descrever o esquema de ponderação das arestas do grafo de medição fasorial. Os pesos das arestas podem ser estabelecidos a partir das magnitudes das admitâncias série. Uma forma de entender a admitância elétrica é enxergá-la como uma forma de medir a proximidade elétrica entre dois pontos. Quando um ramo é monitorado por medidas fasoriais de corrente em ambos os sentidos, é possível utilizar a metade

da magnitude da admitância correspondente como uma ponderação para o cálculo da proximidade elétrica.

- Ramo com medição somente em um ponto:

$$a_{km} = \|y_k m\| \quad (123)$$

- Ramo com medições nos dois pontos:

$$a_{km} = \frac{1}{2} \|y_k m\| \quad (124)$$

Após a definição dos pesos das arestas no grafo de medição fasorial, é possível formular o problema de particionamento do plano de medição de maneira a abranger ambos os critérios discutidos na Subseção 6.3.3. Essa formulação busca encontrar uma solução ótima que minimize a função dos cortes normalizados:

$$\min_{(U_1, U_2, \dots, U_{n_c})} \text{corte}_{norm} \quad (125)$$

Finalmente, é importante ressaltar que a aplicação deste procedimento requer, como dados de entrada, o número médio e máximo de barras por partição. Inicialmente, o número de partições é definido como o menor inteiro não superior a $\frac{N}{N_{medio}}$, onde N representa a quantidade total de barras e N_{medio} a quantidade média de barramentos. Após a definição inicial do número de partições, é aplicada a rotina de agrupamento com base na matriz Laplaciana e a redundância de cada partição é avaliada (ZANLORENSI, E., 2021).

Neste contexto, a redundância de uma partição é definida como o índice de observabilidade que cada barra da partição fornece em relação ao número total de barras da partição. Se alguma partição possuir uma redundância abaixo de um limiar mínimo pré-definido P_{min} , o número de partições é reduzido em uma unidade e o procedimento é refeito (ZANLORENSI, E., 2021).

O procedimento é interrompido quando todas as partições apresentarem redundância acima do limiar P_{min} ou quando uma das partições possui um número de barras superior ao limite máximo N_{max} .

O algoritmo de corte normalizado é uma ferramenta eficaz para determinar a partição otimizada do plano de medição do ponto de vista da detectabilidade de erros grosseiros. É importante ressaltar que a definição das partições considera não apenas o número de vértices do grafo de medição fasorial, mas também a interconexão entre eles, estabelecidas pelas medidas sincrofasoriais de corrente (ZANLORENSI, E., 2021).

6.4 APLICAÇÃO DA TÉCNICA PARA O PROCESSAMENTO DE ERROS GROSSEIROS

Com o particionamento da rede elétrica resultante da aplicação do algoritmo de minimização dos cortes normalizados, são definidas as medidas internas que serão utilizadas para os cálculos de processamento de EGs para os agrupamentos do sistema.

6.4.1 Detecção

A etapa do processamento de erros grosseiros mais fortemente beneficiada pela estratégia de *clusterização* da rede elétrica é a detecção da presença de medidas espúrias. Esta subseção descreve as etapas da aplicação de testes- $J(\hat{\mathbf{x}})$ à rede particionada.

Primeiramente são processadas as medidas internas para cada um dos agrupamentos do sistema elétrico apenas e ao final são processadas as medidas de fronteira do sistema. No processo de detecção, são calculados valores parciais para cada agrupamento i da rede elétrica. Para um agrupamento i define-se:

- J_i : calculada para as medidas e estados internos ao agrupamento i ;
- \mathbf{v}_i : graus de liberdade das medidas internas ao agrupamento i ;
- n_i : quantidade de medidas de z_i ;
- n_f : quantidade de medidas de fronteira, \mathbf{z}_f .

Para uma rede com n_c agrupamentos, este procedimento gerará inicialmente testes caracterizados pela seguinte sequência de pares de SPQRs e respectivos limiares: $(J_1, \mathbf{v}_1), \dots, (J_{n_c}, \mathbf{v}_{n_c})$. Para as medidas de fronteira, que englobam todos os estados do sistema, o cálculo é feito de maneira tradicional, operando sobre o conjunto completo das medidas de fronteira $\mathbf{z}_f(J, \mathbf{v})$.

No início do processamento de medidas, as variáveis SPQR e graus de liberdade são nulas. Ao ser processada uma medida interna a um agrupamento, a atualização da respectiva SPQR é realizada com base em sua variação, ou seja, $J_i = J_i + \Delta J$. Sendo:

$$\Delta J = \bar{\Delta}_{n+1} - \Delta_{n+1} \quad (126)$$

onde Δ_{n+1} representa a SPQR total acumulada da rede. Já a atualização dos graus de liberdade é aplicada quando a medida processada for redundante com as demais anteriormente computadas. Como as medidas sincrofásicas são processadas aos pares, a atualização é dada por $\mathbf{v}_i = \mathbf{v}_i + 2$.

O teste- $J(\hat{\mathbf{x}})$ pode ser nesse momento aplicado, caso seja utilizada a versão sequencial da detecção. Outra forma possível de aplicação do teste, consiste no processamento de todas as medidas do subconjunto, quando $k = n_i$. Se o teste detecta a presença de erros grosseiros no agrupamento i , o vetor de *flags* de detecção (\mathbf{f}) é atualizado, mudando o valor de $f(i)$ de 0 para 1 (ZANLORENSI, E., 2021).

Uma vez que o procedimento de detecção de erros grosseiros tenha sido executado para todos os agrupamentos de medidas, a SPQR total, representada por Δ_{n+1} , é igual ao somatório dos valores de J_i obtidos anteriormente, enquanto o número de graus de liberdade total é dado pela soma dos valores de ν_i . Após esta etapa, são verificadas as medidas de fronteira, aplicando as rotações G3M necessárias. Durante esse processo, tanto a SPQR quanto o número de graus de liberdade são atualizados com base nos valores totais de J e ν .

6.4.2 Etapas de Identificação e Remoção ou Recuperação

O procedimento de identificação e remoção ou recuperação de medidas errôneas, é inicialmente aplicado aos conjuntos de medidas internas. O processo de identificação começa com o cálculo da matriz de covariância dos resíduos, \mathbf{W} , após a estimação dos estados, $\hat{\mathbf{x}}$.

Se os conjuntos \mathbf{z}_i ultrapassam os limites de detecção, ou seja, atendem à condição $f(i) = 1$, calculam-se os resíduos normalizados em blocos. Nestes conjuntos, a medida errônea é indicada pelo valor máximo entre os resíduos normalizados.

Pode-se concluir que o teste de resíduos normalizados é executado de forma independente para cada conjunto de medidas internas cujos testes- $J(\hat{\mathbf{x}})$ correspondentes indicam a presença de erros grosseiros. Se existirem ℓ desses grupos, então ℓ erros grosseiros são identificados simultaneamente em uma única etapa de identificação. Esses podem, então, ser todos removidos em uma única etapa de remoção por meio da técnica de reprocessamento ou recuperados, conforme abordado na Seção 5.6. Esta é uma das principais vantagens do teste- $J(\hat{\mathbf{x}})$ particionado em relação à sua versão tradicional, que permite a identificação e remoção de apenas uma medida errônea de cada vez (ZANLORENSI, E., 2021).

6.5 CONCLUSÃO

A prática corrente de empregar o teste- $J(\hat{\mathbf{x}})$ na detecção de erros grosseiros em redes elétricas enfrenta desafios de desempenho quando aplicada a sistemas de grande escala. Esta problemática surge a partir da influência direta da magnitude do erro e da redundância local na variação da soma ponderada dos quadrados dos resíduos (SPQR), afetando assim o seu valor relativo ao limiar do teste. Para mitigar este desafio, propõe-se o particionamento da rede elétrica, induzido pelo plano de medição da rede, em agrupamentos menores, cada um sendo objeto de aplicação individual do teste- $J(\hat{\mathbf{x}})$. Este procedimento promove a acurácia do método de detecção e potencializa a eficácia na identificação de erros grosseiros em redes elétricas de grandes dimensões.

O particionamento engloba todas as medidas presentes no sistema e consiste unicamente em reorganizá-las de maneira específica. Este método de particionamento fundamenta-se na distância elétrica interáreas, simbolizada pela impedância existente

entre elas. Destaca-se que, diante de elevados níveis de impedância, a sensibilidade dos resíduos de uma determinada área com relação a erros de outra área tende a ser fraca ou quase inexistente. Logo, a subdivisão do sistema em blocos menores, além de aprimorar a acurácia do método de detecção, contribui para minimizar a incidência de perturbações de áreas distantes na identificação de erros numa área específica.

7 RESULTADOS

7.1 INTRODUÇÃO

Este capítulo apresenta as simulações e resultados computacionais que foram realizados para avaliar a abordagem de processamento de erros grosseiros proposta nesta dissertação.

Implementou-se um estimador linear de estados híbrido baseado na arquitetura de fusão de estimativas, aplicando-se os casos com e sem particionamento da rede elétrica para estudar os efeitos dessa técnica no processamento de EGs.

Nas próximas seções são mostrados o ambiente computacional, as condições gerais de simulação, as simulações realizadas e as discussões dos resultados obtidos.

7.2 AMBIENTE COMPUTACIONAL

A seguir, são apresentadas as características do ambiente computacional utilizado e os procedimentos adotados para as simulações:

- Os testes foram desenvolvidos no ambiente computacional Matlab versão R2020a;
- As simulações foram executadas em um computador com processador de 1,8 GHz Intel Core i5 Dual-Core e memória de 8 GB 1600 MHz DDR3.

7.2.1 Condições Gerais de Simulação

- Os sistemas teste de referência utilizados nesta pesquisa são os do *IEEE* de 57, 118 e 300 barras;
- As simulações das medidas, tanto fasoriais quanto SCADA, foram realizadas adicionando erros gaussianos aos valores verdadeiros das medições. Esses valores verdadeiros foram obtidos a partir da solução convergida de um algoritmo de fluxo de potência. A fonte dos dados utilizados nos sistemas simulados é a referência (UNIVERSITY OF WASHINGTON, 1993), garantindo a confiabilidade dos dados utilizados;
- Cada medida simulada é determinada pela equação $z = z_0 + psm \times \sigma$, em que z_0 representa o valor verdadeiro da medida, psm é um valor pseudoaleatório gerado por um algoritmo interno do Matlab, seguindo uma distribuição normal. A variância da medida, σ^2 , é calculada considerando a magnitude da medida verdadeira, representada por $|z_0|$, e um parâmetro de ajuste da acurácia (A). Essa formulação permite a inclusão dos erros gaussianos nas medidas simuladas, levando em conta tanto a magnitude da medida verdadeira como uma influência na variância dos erros. A representação é então dada pela fórmula $\sigma^2 = (A \times |z_0|)^2 + A^2$ (DOPAZO; KLITIN; VANSLYCK, 1972). Dessa forma, as

simulações das medidas foram realizadas considerando a adição de erros gaussianos controlados, o que proporciona uma análise mais realista das incertezas e variações presentes nas medições reais. Essa abordagem permite explorar os efeitos dos erros nas estimativas de estado e avaliar a robustez dos algoritmos utilizados no processamento das medidas;

- Como o foco das simulações deste trabalho são as medições sincrofásoriais, as medidas e estimativas SCADA são consideradas livres de erros grosseiros, ou seja, supõe-se que estas já passaram previamente pelas etapas de processamento de EGs. As medidas SCADA são, portanto, simuladas de forma que nenhum erro exceda o valor de 3 desvios-padrão. Os estados são então estimados pelo método G3M tradicional;
- Adotou-se uma probabilidade de falso alarme (α) de 1%;
- O particionamento é aplicado somente sobre o plano de medição fasorial.
- Considera-se uma acurácia de 1% para todas as medidas SCADA e 0,1% para todas as medidas fasoriais;
- O tamanho do particionamento em cada rede teste é dado de maneira a manter entre 14 a 15 barramentos por *cluster*;
- As estimativas do sistema SCADA, juntamente com sua matriz de covariância, são utilizadas como entradas no algoritmo desenvolvido para a fusão de estimativas. Antes de serem processadas, essas estimativas passam por uma mudança de coordenadas, sendo convertidas de coordenadas polares para coordenadas retangulares. Essa transformação é realizada para garantir uma representação mais adequada das estimativas, facilitando a fusão e a combinação dos valores estimados. Ao realizar a mudança de coordenadas, as estimativas do sistema SCADA são expressas em coordenadas retangulares, permitindo uma integração mais eficiente e uma interpretação mais intuitiva dos dados. Essa etapa é fundamental para o correto funcionamento do algoritmo de fusão, que busca combinar as estimativas de forma coerente e precisa;
- As medidas fasoriais são inicialmente construídas em coordenadas polares. Essa representação em coordenadas polares permite capturar as informações de magnitude e ângulo das grandezas medidas. No entanto, para fins de processamento e análise, essas medidas são convertidas para coordenadas retangulares. Essa conversão é aplicada tanto às medidas fasoriais quanto à matriz de covariância dos erros de medição fasorial;
- Uma unidade de medição fasorial tem a capacidade de medir o fasor de tensão de na barra onde está instalada, bem como os fasores de corrente nos ramos conectados a essa mesma barra;

- O sistema SCADA fornece medidas que incluem o módulo de tensão nas barras, a injeção de potência ativa e/ou reativa nas barras, a corrente nos ramos e o fluxo de potência ativa e/ou reativa nos ramos;
- A alocação das PMUs segue um algoritmo de alocação ótima proposto em (AMARE; CENTENO; PAL, 2015), visando estabelecer uma redundância N-1 no plano de medição fasorial;
- Em todos os sistemas estudados, uma barra contendo PMU é selecionada para estabelecer a referência, em que terá alta precisão na medida de fase;
- A adição de erros grosseiros é restrita às medidas fasoriais, onde os locais e magnitudes dos erros são definidos e fornecidos como entrada para o algoritmo de processamento desses erros. Esse algoritmo é executado em conjunto com o algoritmo de estimação de estados.

7.2.2 Métricas

- Métrica de tensão utilizada para verificar o erro vetorial total dos estados estimados (KEMA, 2006).

$$\varepsilon_{\vec{v}} = \|\vec{\mathbf{V}}_{\text{erro}}\| = \left(\sum_{k=1}^N |\vec{V}_{\text{estimado}}^k - \vec{V}_{\text{verdadeiro}}^k|^2 \right)^{1/2} \quad (127)$$

onde para a k -ésima barra da rede, $\vec{V}_{\text{estimado}}^k$ é o fasor tensão dos valores estimados, $\vec{V}_{\text{verdadeiro}}^k$ é o fasor tensão dos valores verdadeiros e N é o número total de barras do sistema.

- Taxa de sucesso de detecção: métrica utilizada para verificar o percentual de detecção atingido nas simulações.

$$\text{Deteccao}(\%) = 100 \times \frac{\sum_{i=1}^N \text{deteccao}}{N} \quad (128)$$

onde N é o número total de simulações para cada caso.

- Taxa de sucesso de identificação: métrica utilizada para verificar o percentual de identificação atingido nas simulações.

$$\text{Identificacao}(\%) = 100 \times \frac{\sum_{i=1}^N \text{identificacao}}{N} \quad (129)$$

onde N é o número total de simulações para cada caso. Para este estudo, a taxa de identificação será dada em relação à quantidade total de simulações: nessa abordagem, a taxa de identificação é calculada como o número de casos corretamente identificados em relação ao número total de casos simulados.

- Mediana da métrica de tensão: métrica utilizada para verificar o conjunto de dados gerados a partir das N simulações realizadas para cada rede teste.

Na análise estatística, tanto a mediana quanto a média são medidas comumente usadas para resumir conjuntos de dados. No entanto, em certos casos, a mediana pode ser preferida em vez da média devido a algumas propriedades específicas. Uma das principais razões para adotar a mediana em vez da média é a sensibilidade a valores discrepantes ou extremos. A média é afetada pelos valores extremos, pois é calculada somando todos os valores e dividindo pelo número de observações. Assim, se houver valores atípicos ou discrepantes, eles podem distorcer significativamente a média e afetar a interpretação dos resultados.

Por outro lado, a mediana é menos suscetível a valores extremos, pois é determinada pelo valor que divide o conjunto de dados em duas partes iguais: metade dos valores está acima e metade está abaixo. Portanto, mesmo que haja valores extremos presentes, eles não afetam tanto a mediana quanto afetariam a média. Isso torna a mediana uma medida robusta em situações em que existem valores discrepantes ou quando a distribuição dos dados é assimétrica. Ela fornece uma medida mais representativa do valor central dos dados, desconsiderando os valores extremos que podem ser distorcidos.

No contexto da estimação de estados de sistemas de potência, onde podem ocorrer erros grosseiros ou valores discrepantes nos dados, a mediana é uma escolha apropriada. Ela permite uma avaliação mais precisa e confiável das métricas de desempenho, pois não é afetada de forma significativa por esses erros extremos.

7.3 PLANOS DE MEDIÇÃO

Os planos de medição adotados para os sistemas teste abordados nesta dissertação estão expostos abaixo. Na Tabela 1 são indicadas as medições SCADA e na Tabela 2 estão indicadas as medições sincrofasoriais.

Tabela 1 – Número de medidas e índices de redundância SCADA.

Sistema Teste	P/Q	$ V $	t/u	ρ
57 barras	28	57	78	2,36
118 barras	31	108	179	2,24
300 barras	234	90	409	2,29

Tabela 2 – Número de medidas e índices de redundância PMU.

Sistema Teste	\vec{V}	\vec{I}	ρ
57 barras	33	97	2,27
118 barras	69	244	2,6
300 barras	202	538	2,46

7.4 SIMULAÇÕES COMPUTACIONAIS

Nesta seção, realizamos simulações computacionais nas redes teste IEEE de 57, 118 e 300 barras para investigar o impacto do particionamento da rede no processamento de erros grosseiros. O objetivo é avaliar como a abordagem de particionamento influencia o processamento desses erros em diferentes magnitudes. As redes teste IEEE são amplamente utilizadas na área de estimação de estados de sistemas de potência, fornecendo cenários realistas para avaliar diferentes técnicas.

Nas simulações realizadas para obter as taxas de sucesso de detecção e identificação, adota-se um cenário em que um erro grosseiro ocorre no plano de medição fasorial a cada execução do algoritmo. O local desse erro grosseiro é especificado de forma sistemática, abrangendo todas as possibilidades. Essa abordagem permite avaliar de maneira abrangente e equilibrada o desempenho da detecção e identificação de erros grosseiros em diferentes configurações. Ao cobrir todas as possibilidades do local do erro grosseiro, pode-se obter uma visão mais precisa do quanto eficaz o algoritmo é na detecção e identificação desses erros. Dessa forma, garante-se uma análise abrangente e representativa das taxas de sucesso nessas simulações.

Com o objetivo de reduzir efeitos devidos às variações decorrentes dos erros gaussianos, foram realizadas 20 simulações para cada local de alocação de erro grosseiro (EG). Essa abordagem múltipla de simulações nos permite obter uma visão mais robusta e confiável do desempenho do sistema diante das diferentes alocações de EG. Ao executar múltiplas simulações para cada local de EG, conseguimos mitigar os efeitos aleatórios e garantir uma análise mais consistente das taxas de sucesso de detecção e identificação. Essa estratégia nos permite capturar uma visão mais abrangente do comportamento do sistema diante dos erros grosseiros e fornecer informações mais confiáveis sobre sua detecção e identificação.

Por meio dessas simulações, busca-se fornecer uma análise comparativa entre a rede particionada e a não particionada, examinando como a magnitude dos erros grosseiros é tratada em cada configuração. Isso permitirá entender o impacto do particionamento da rede no processamento desses erros e obter informações sobre a eficácia dessa abordagem na estimação de estados de sistemas de potência.

7.4.1 Sistema Teste de 57 Barras

Nesta subseção, apresentamos as simulações computacionais realizadas na rede teste IEEE de 57 barras, focando nos efeitos do particionamento da rede nos casos com variações na magnitude dos erros grosseiros. A escolha da rede de 57 barras como cenário para estas simulações se deve ao fato de que, a partir de uma rede deste tamanho, os efeitos do particionamento começam a ser mais visíveis e relevantes. Para este sistema há 259 locais para ocorrência de EG e, conforme mencionado na Seção 7.4, para garantir a

robustez dos resultados foram realizados $20 \times 259 = 5.180$ experimentos.

Para realizar os testes, a rede de 57 barras foi particionada em 4 *clusters*, levando em consideração a estrutura do sistema e a distribuição dos nós. Em seguida, simulações foram conduzidas tanto para a rede particionada quanto para a não particionada, com variações na magnitude dos erros grosseiros. O objetivo dessas simulações é analisar como o particionamento da rede afeta o processamento desses erros, e comparar o desempenho das duas configurações em termos de detecção e correção de erros grosseiros. Na Figura 12 apresenta-se o particionamento aplicado ao plano de medição fasorial do sistema.

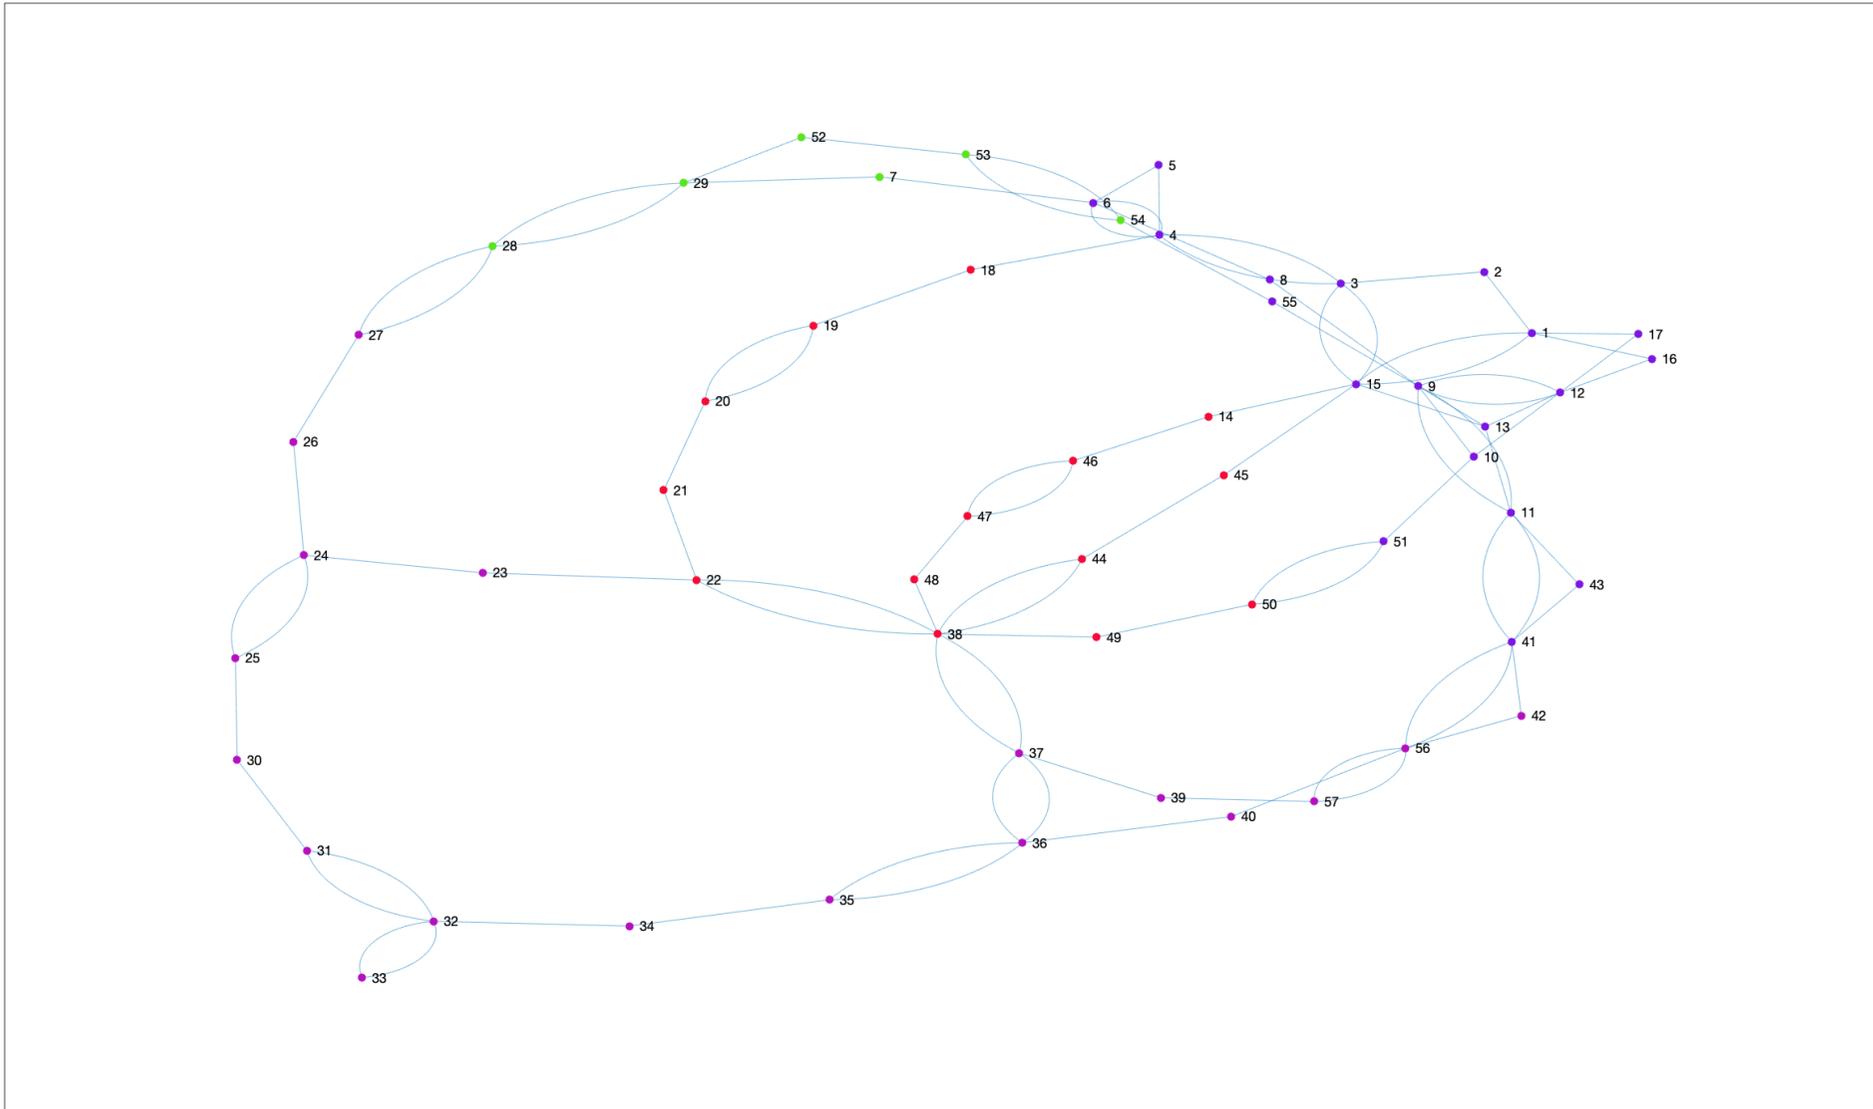


Figura 12 – Rede de 57 barras com particionamento do plano de medição fasorial de 4 *clusters*.

Na Figura 12 do plano de medição particionado em *clusters*, os vértices representam as barras nas quais a medição de tensão está sendo realizada ou barramentos que possuem ramos que possuem medidas sincrofasoriais de corrente. As linhas azuis indicam que existe medição direta de corrente nestes ramos. No entanto, é importante notar que, na figura, apenas os barramentos monitorados por PMUs e aqueles que possuem ramos com medição sincrofasorial de corrente são exibidos, ou seja, apenas o plano de medição sincrofasorial está representado. Como resultado, as linhas que conectam barras que possuem não possuem PMUs e não têm ramos em que ocorre medição sincrofasorial de corrente não estão representados na figura. No entanto, isso não significa que não hajam mais barras e linhas do sistema.

7.4.2 Taxas de sucesso

Nesta subseção, serão conduzidas simulações e análises das taxas de sucesso de detecção e identificação de erros grosseiros na rede teste de 57 barras, considerando os casos com a utilização da rede particionada e não particionada. O objetivo dessas simulações é avaliar o desempenho dessas configurações em relação à detecção e identificação de erros grosseiros, fornecendo uma compreensão mais aprofundada de como o particionamento da rede pode influenciar esses processos.

Através da análise comparativa das taxas de sucesso nessas configurações, espera-se obter resultados significativos sobre a eficácia do particionamento da rede na melhoria da detecção e identificação de erros grosseiros na rede teste de 57 barras. Esses resultados permitirão compreender melhor o impacto do particionamento na precisão e na confiabilidade dos processos de detecção e identificação de erros. Além disso, será possível obter informações relevantes sobre as vantagens e desafios do uso do particionamento da rede nesse contexto específico.

7.4.2.1 Detecção

Nesta análise, examinam-se as taxas de sucesso de detecção de duas configurações de rede: a rede particionada e a rede não particionada. As taxas de sucesso são avaliadas em relação à variação da magnitude do erro, que é expressa em termos de sigma (σ). Os resultados das simulações estão expostos na Tabela 3.

Tabela 3 – Taxas de sucesso de detecção para os casos de rede particionada e não particionada na rede teste de 57 barras.

Magnitude do erro	Rede particionada	Rede não particionada
30σ	90,73 %	90,35 %
25σ	87,64 %	85,71 %
20σ	83,01 %	80,69 %
15σ	77,99 %	75,29 %
10σ	67,95 %	59,85 %

Deve ser lembrado que o parâmetro sigma, nesse contexto, é uma quantidade estatística que representa o desvio padrão dos erros em relação a um valor de referência. Nesse contexto, é usado para quantificar a magnitude do erro grosseiro simulado: quanto maior o valor de sigma, maior é a magnitude do erro grosseiro. A rede particionada envolve a divisão do plano de medição em subconjuntos menores, limitando a contribuição a $J(\hat{x})$ por parte das medidas cujos resíduos são mais sensíveis ao erro grosseiro local. Por outro lado, a rede não particionada considera as contribuições de todas as medidas do plano de medição global. Ao analisar as taxas de sucesso em diferentes magnitudes de erro, pode-se entender como as configurações de rede lidam com erros de diferentes intensidades. Para melhor visualização os dados são também apresentados na Fig. 13.

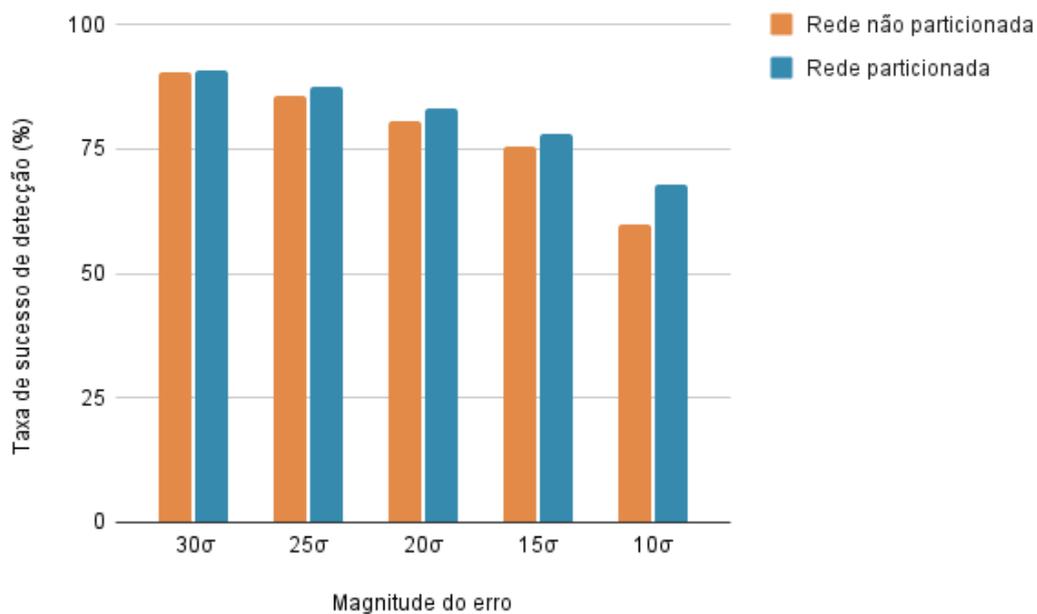


Figura 13 – Taxas de sucesso de detecção para a rede teste de 57 barras.

Para realizar uma análise dos resultados fornecidos, é possível observar as taxas de sucesso de detecção para diferentes magnitudes de erro em duas configurações: rede não particionada e rede particionada.

Em geral, a rede particionada apresenta taxas de sucesso de detecção mais altas em todas as magnitudes de erro em comparação com a rede não particionada. A diferença nas taxas de sucesso entre as duas configurações torna-se mais pronunciada para magnitudes de erro menores (10σ e 15σ), onde a rede particionada supera a rede não particionada significativamente. Para magnitudes de erro maiores (30σ e 25σ), a diferença entre as configurações é menos acentuada, mas a rede particionada ainda tem uma vantagem.

À medida que a magnitude do erro aumenta, as taxas de sucesso de detecção tendem também a aumentar, tanto para a rede não particionada quanto para a rede particionada. Isso confirma o fato de que erros maiores são mais fáceis de serem detectados

em comparação com erros de menor magnitude. A diferença nas taxas de sucesso entre as magnitudes de erro é mais notável na rede não particionada, onde a taxa de sucesso diminui de forma mais acentuada à medida que a magnitude do erro diminui.

A rede não particionada apresenta uma taxa de sucesso de detecção de 59,85% para a magnitude de erro de 10σ , indicando uma dificuldade em detectar erros dessa magnitude. A rede particionada, por outro lado, tem uma taxa de sucesso de 67,95% para a mesma magnitude de erro, demonstrando uma melhora na detecção em comparação com a rede não particionada. Ambas as configurações têm suas maiores taxas de sucesso de detecção para a magnitude de erro de 30σ , sendo 90,73% para a rede particionada e 90,35% para a rede não particionada.

A utilização da rede particionada pode, portanto, fornecer melhores resultados na detecção de erros em comparação com a rede não particionada, especialmente para magnitudes de erro menores. No entanto, a diferença nas taxas de sucesso entre as configurações diminui à medida que a magnitude do erro aumenta, sugerindo que para redes elétricas desses porte ambas podem ser igualmente eficazes para erros maiores.

7.4.2.2 Identificação

São apresentados os resultados e discussões das simulações realizadas para analisar as taxas de sucesso de identificação nos casos de rede particionada e não particionada na rede teste de 57 barras. Os resultados obtidos por meio dessas simulações estão disponíveis na Tabela 4, mostrada abaixo, destacando as taxas de sucesso de identificação para cada configuração. Serão discutidos os principais aspectos e tendências observados nesses resultados, fornecendo informações sobre o desempenho e a eficácia do particionamento da rede na identificação de erros. Essa análise permitirá uma compreensão mais aprofundada do impacto do particionamento da rede nesse processo, auxiliando no desenvolvimento de estratégias mais eficientes para a detecção e correção de erros em sistemas de potência.

Tabela 4 – Taxas de sucesso de identificação para os casos de rede particionada e não particionada na rede teste de 57 barras.

Magnitude do erro	Rede particionada	Rede não particionada
30σ	74,52 %	74,13 %
25σ	77,61 %	72,59 %
20σ	73,75 %	69,50 %
15σ	68,34 %	66,41 %
10σ	60,62 %	53,28 %

Os resultados obtidos nas simulações das taxas de sucesso de identificação para os casos de rede particionada e não particionada na rede teste de 57 barras estão apresentados de forma gráfica na Figura 14. Essa representação gráfica permite uma visualização mais clara e comparativa das taxas de sucesso entre as diferentes configurações e proporciona uma abordagem mais intuitiva e eficaz para avaliar e discutir os resultados das simulações.

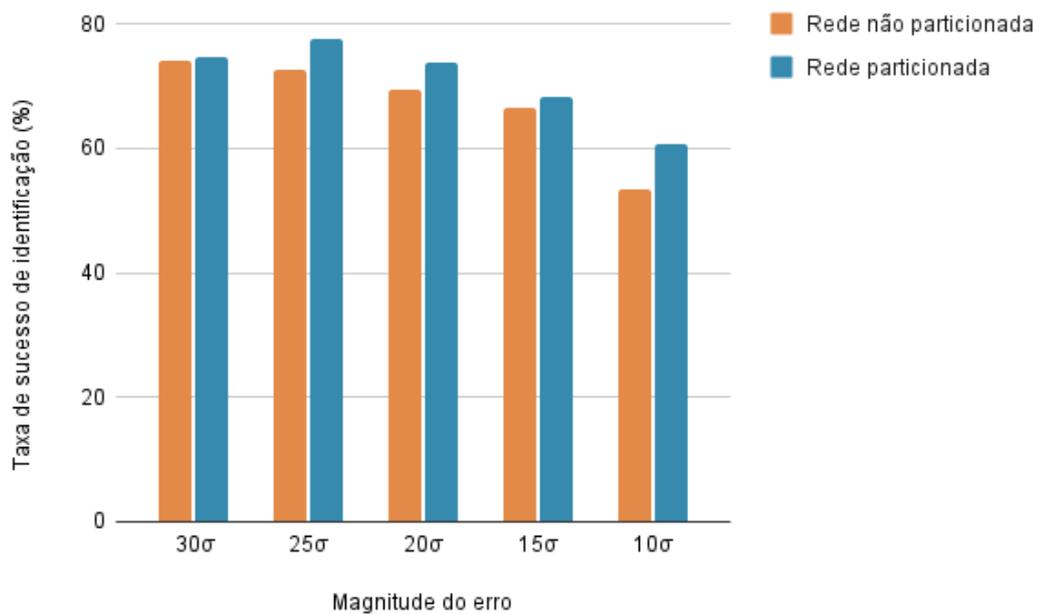


Figura 14 – Taxas de sucesso de identificação para a rede teste de 57 barras.

Ao analisar os dados de identificação de erros grosseiros nas configurações de rede particionada e não particionada, observam-se tendências interessantes.

A medida que a magnitude do erro, expressa em sigma, aumenta, tanto a rede particionada quanto a não particionada apresentam taxas de identificação relativamente altas. Isso indica que erros grosseiros de maior magnitude são detectados e identificados corretamente em ambas as configurações.

No entanto, quando a magnitude do erro diminui, observa-se uma melhora relativa na identificação do erro pela rede particionada em comparação com a rede não particionada. Essa diferença sugere que a abordagem de particionamento dos dados aplicada na rede particionada pode fornecer uma vantagem na detecção e identificação de erros de menor magnitude.

Ambas as configurações de rede (não particionada e particionada) apresentam taxas de identificação relativamente altas para erros de maior magnitude, com valores acima de 69% em todas as magnitudes de erro mais altas avaliadas. Contudo, à medida que a magnitude do erro diminui, podemos observar uma melhora significativa na taxa de identificação para a rede particionada em comparação com a rede não particionada. Por exemplo, para a magnitude do erro 10σ , a taxa de identificação da rede particionada é de 60,62%, enquanto a taxa de identificação da rede não particionada é de 53,28%.

Esses resultados reforçam a importância do particionamento dos dados na etapa de detecção de erros grosseiros em sistemas de potência. Ao utilizar o particionamento, a rede particionada fornece um desempenho superior na identificação de erros de menor magnitude, contribuindo para a melhoria da qualidade das estimativas dos estados da

rede elétrica.

7.4.3 Medianas das Métricas de Tensão

Nesta subseção, realizam-se análises detalhadas das medianas das métricas de tensão no contexto da estimação de estados em sistemas de potência. As métricas de tensão desempenham um papel crucial na avaliação da qualidade das estimativas, fornecendo informações sobre a precisão e a confiabilidade das estimativas das tensões nas diferentes barras do sistema. Nestas simulações, como informado na Subseção 7.2.1, as medidas e estimativas SCADA são consideradas livres de erros e possuem um processamento de erros grosseiros independente. Para as estimativas obtidas apenas com estas medidas, foi obtida uma mediana da métrica de 0,041918 para todos os casos simulados. Essa mediana representa uma medida confiável e consistente da qualidade das estimativas para este sistema específico. Portanto, para melhor visualização dos resultados para o estimador fasorial e para a fusão das estimativas o valor da métrica para as estimativas SCADA foi suprimido da tabela e do gráfico apresentados abaixo.

Ao analisar as medianas das métricas de tensão, busca-se identificar padrões e tendências que possam influenciar o desempenho da estimação, permitindo uma melhor compreensão dos fatores que impactam a qualidade das estimativas. Os resultados obtidos para as medianas das métricas de tensão para os casos de rede particionada e não particionada na rede teste de 57 barras para as estimativas geradas pelo estimador fasorial e para a fusão das estimativas (SCADA e fasorial) estão apresentados na Tabela 5.

Tabela 5 – Medianas das métricas para os diferentes casos de magnitude do erro na rede teste de 57 barras.

Magnitude do Erro	Rede particionada		Rede não particionada	
	Estimador fasorial	Fusão das estimativas	Estimador fasorial	Fusão das estimativas
30σ	0,002483	0,002445	0,002598	0,002583
25σ	0,002545	0,002470	0,002600	0,002565
20σ	0,002477	0,002419	0,002603	0,002548
15σ	0,002519	0,002467	0,002756	0,002735
10σ	0,002985	0,002914	0,003690	0,003422

Para proporcionar uma melhor visualização e comparação dos resultados, os resultados das medianas das métricas foram representados graficamente. Na Figura 15, apresentamos o gráfico das medianas das métricas para as condições de rede particionada e não particionada, tanto para o estimador fasorial quanto para a fusão das estimativas. Esse gráfico permite uma análise mais intuitiva das tendências e diferenças entre as configurações de rede e as abordagens de estimação. Com a representação gráfica das medianas das métricas, é possível identificar de forma mais clara e visual as variações e os padrões observados nos resultados, auxiliando na interpretação dos dados e no embasamento de conclusões.

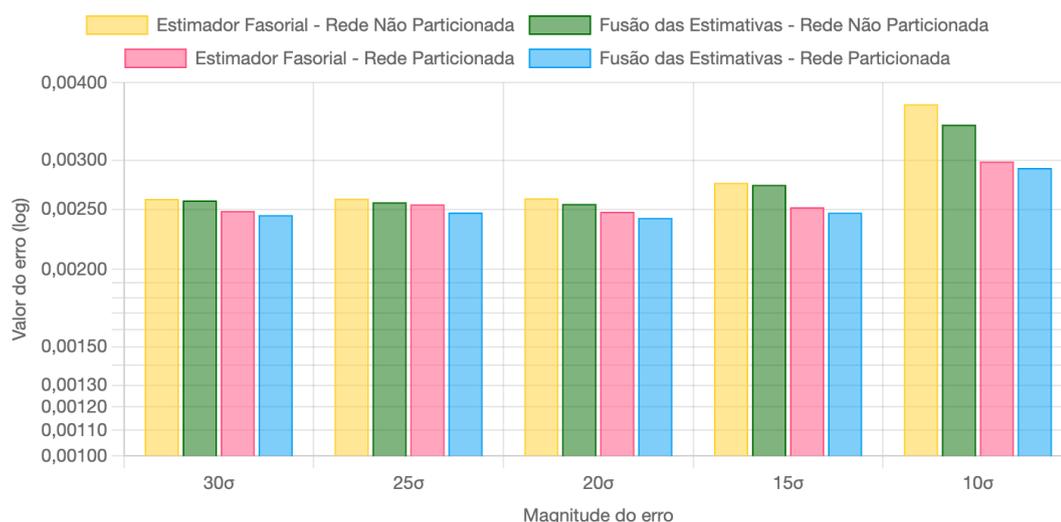


Figura 15 – Medianas das métricas de tensão para a rede teste de 57 barras.

Os resultados mostram as métricas das medianas das tensões estimadas pelo estimador fasorial e pela fusão das estimativas em diferentes magnitudes de erro, para as configurações de rede particionada e não particionada.

Ao analisar as medianas das tensões, observamos que, em ambas as configurações de rede, uma diminuição na mediana da tensão está associada a uma melhor métrica. Isso indica que uma menor mediana das tensões reflete uma estimacão mais precisa dos estados da rede elétrica.

Ao comparar as configurações de rede, podemos observar que, em geral, a rede particionada apresenta medianas das tensões menores tanto para o estimador fasorial quanto para a fusão das estimativas em comparacão com a rede não particionada. Isso sugere que a abordagem de particionamento dos dados utilizada na rede particionada resulta em uma melhor métrica e uma estimacão mais precisa das tensões em relacão à rede não particionada.

É importante destacar que a fusão das estimativas demonstra um desempenho superior em relacão ao estimador fasorial em ambas as configurações de rede. Essa melhoria na métrica indica que a fusão das estimativas, ao combinar informacões de diferentes fontes, oferece resultados mais confiáveis e precisos na estimacão das tensões.

Em resumo, uma diminuicão na mediana da tensão indica uma melhor métrica, refletindo uma estimacão mais precisa dos estados da rede elétrica. A rede particionada apresenta medianas das tensões menores em comparacão com a rede não particionada, indicando um desempenho geralmente melhor na estimacão das tensões. Além disso, a fusão das estimativas se destaca como uma abordagem promissora para melhorar a precisão das estimativas em ambas as configurações de rede.

Realizando uma análise dos maiores e menores valores das medianas das métricas para o estimador fasorial e para a fusão das estimativas, considerando as configurações de

rede particionada e não particionada:

1. Rede particionada:

- Estimador fasorial: o menor valor da mediana das tensões é observado na magnitude de erro de 20σ (0,002477), enquanto o maior valor é registrado na magnitude de erro de 10σ (0,002985);
- Fusão das estimativas: o menor valor da mediana das tensões é registrado na magnitude de erro de 20σ (0,002419), enquanto o maior valor é observado na magnitude de erro de 10σ (0,002914).

2. Rede não particionada:

- Estimador fasorial: o menor valor da mediana das tensões é registrado na magnitude de erro de 30σ (0,002598), enquanto o maior valor é observado na magnitude de erro de 10σ (0,003690);
- Fusão das estimativas: o menor valor da mediana das tensões é observado na magnitude de erro de 30σ (0,002583), enquanto o maior valor é registrado na magnitude de erro de 10σ (0,003422).

Em ambas as configurações de rede, notamos que as medianas das tensões tendem a diminuir à medida que a magnitude do erro aumenta, indicando uma melhoria na precisão das estimativas com erros menores. Esta melhora decorre das melhores taxas de detecção para erros de maior magnitude.

Ao comparar as configurações de rede particionada e não particionada, observamos que a rede particionada apresenta valores menores para as medianas das tensões em ambas as métricas, tanto para o estimador fasorial quanto para a fusão das estimativas. Isso sugere que a rede particionada tende a proporcionar uma melhor precisão na estimação das tensões em relação à rede não particionada. Comparando as configurações de rede, observam-se diferenças nas medianas das tensões, sugerindo um desempenho superior em uma das configurações. Essas conclusões destacam a importância da detecção correta dos erros e da utilização de técnicas como a fusão das estimativas para obter estimativas mais precisas e confiáveis dos estados da rede elétrica.

7.4.4 Sistema Teste de 118 Barras

Esta subseção de simulações apresenta os resultados obtidos a partir de um extenso conjunto de experimentos realizados com a rede teste IEEE de 118 barras. Foram conduzidos um total de 12.500 (20×625) experimentos, nos quais foram aplicadas variações na magnitude do erro grosseiro para as configurações de rede particionada e não particionada. Esses experimentos visam investigar o impacto do particionamento da rede nos resultados de detecção e identificação de erros grosseiros, proporcionando uma análise detalhada e abrangente do desempenho dessas configurações.

A realização dos experimentos em uma rede de 118 barras amplia o escopo da análise, permitindo uma avaliação mais abrangente dos efeitos do particionamento. A variação da magnitude do erro grosseiro foi explorada em duas configurações: rede particionada e rede não particionada, para o plano de medição fatorial da rede teste de 118 barras. Vale ressaltar que, para essa rede, foi realizado um particionamento em 8 *clusters*, a fim de estruturar o sistema de medição e análise de forma mais eficiente. O plano de medição fatorial particionado é mostrado na Figura 16.

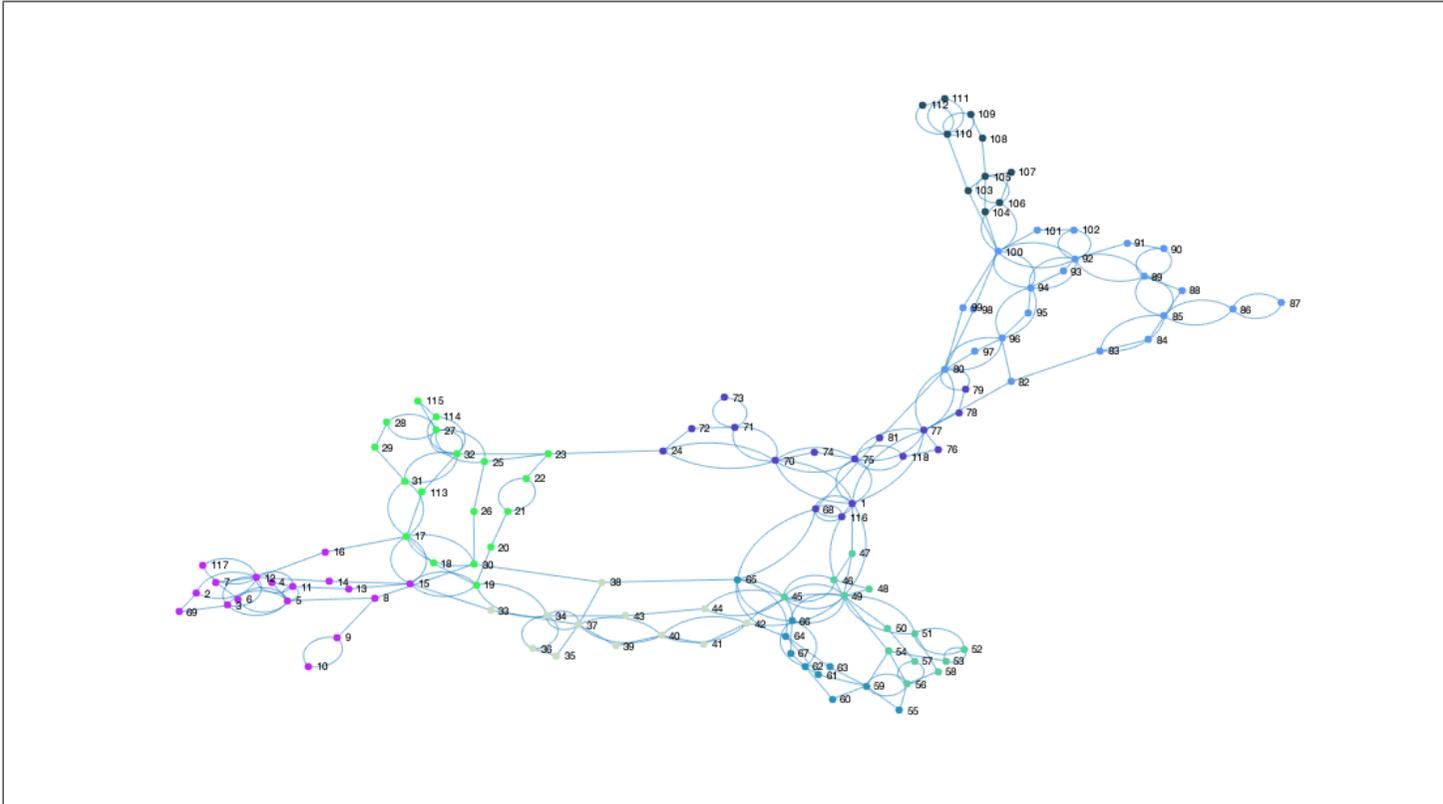


Figura 16 – Rede de 118 barras com particionamento do plano de medição fasorial de 8 *clusters*.

Os experimentos realizados com diferentes magnitudes de erros grosseiros nessas configurações fornecem informações sobre o desempenho do particionamento da rede no processo de detecção e identificação de erros. Essa abordagem permite uma avaliação mais abrangente dos efeitos do particionamento, levando em consideração a complexidade do sistema de medição e sua influência na qualidade das estimativas.

Na Figura 16, o plano de medição é particionado em *clusters* e os vértices representam as barras onde as medições de tensão estão sendo realizadas ou os barramentos que possuem ramos com medidas sincrofasoriais de corrente. As linhas azuis indicam a presença de medições diretas de corrente nesses ramos.

7.4.5 Taxas de sucesso

Nesta subseção, são apresentadas as simulações e resultados das taxas de sucesso de detecção e identificação para a rede teste IEEE de 118 barras. Os resultados obtidos estão expostos em tabelas e gráficos, proporcionando uma melhor visualização e compreensão dos dados. Essa abordagem permite uma análise mais clara e comparativa do desempenho das configurações de rede particionada e não particionada. As tabelas apresentam as taxas de sucesso para diferentes magnitudes de erros grosseiros, enquanto os gráficos fornecem uma representação visual dos resultados. Essa combinação de formatos permite examinar e interpretar de forma mais completa e detalhada o desempenho da detecção e identificação de erros grosseiros nessa configuração de rede particionada e não particionada do sistema de 118 barras.

7.4.5.1 Detecção

As análises dos resultados para a detecção de erros grosseiros no sistema teste de 118 barras são apresentadas abaixo. Os dados obtidos por meio das simulações foram organizados na Tabela 6.

Tabela 6 – Taxas de sucesso de detecção para os casos de rede particionada e não particionada na rede teste de 118 barras.

Magnitude do erro	Rede particionada	Rede não particionada
30σ	94,56 %	90,72 %
25σ	92,96 %	88,48 %
20σ	90,56 %	84,48 %
15σ	86,08 %	75,20 %
10σ	72,32 %	38,24 %

Adicionalmente, visando melhorar a clareza e compreensão dos resultados, foi adotada a representação gráfica dos dados. Os dados estão representados graficamente na Figura 17.

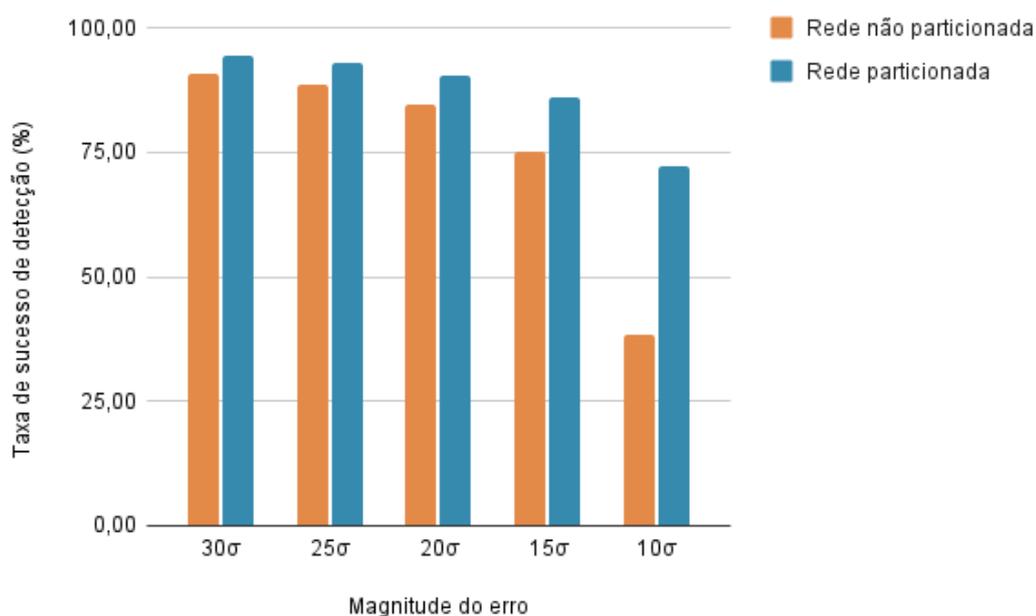


Figura 17 – Taxas de sucesso de detecção para a rede teste de 118 barras.

A análise das taxas de detecção de erros grosseiros para o sistema de 118 barras com 8 partições revela uma tendência consistente em relação à influência do particionamento da rede. Para todas as magnitudes de erro grosseiro testadas, a rede particionada apresentou taxas de detecção mais altas em comparação com a rede não particionada. Por exemplo, para um erro grosseiro de 30σ , a taxa de detecção na rede particionada foi de 94,56%, enquanto na rede não particionada registrou-se 90,72%. Essa diferença se mantém em todas as magnitudes, com a rede particionada superando consistentemente a rede não particionada em termos de detecção de erros grosseiros.

À medida que a magnitude do erro grosseiro diminui, a discrepância entre as taxas de detecção das duas configurações de rede se torna ainda mais evidente. Por exemplo, para um erro de 20σ , a taxa de detecção na rede particionada foi de 90,56%, enquanto na rede não particionada foi de 84,48%. Essa diferença aumenta quando consideramos erros de 15σ e 10σ , com a rede particionada alcançando taxas de detecção de 86,08% e 72,32%, respectivamente, enquanto a rede não particionada apresenta taxas consideravelmente menores, de 75,20% e 38,24%. Essa tendência destaca a capacidade do particionamento da rede em melhorar significativamente a detecção de erros grosseiros, principalmente para magnitudes de erro menores.

Esses resultados reforçam a importância do particionamento da rede de 118 barras na detecção eficiente de erros grosseiros. Independentemente da magnitude do erro grosseiro, a rede particionada apresentou melhores taxas de detecção em comparação com a rede não particionada. Isso ressalta a eficácia do particionamento na detecção de anomalias em sistemas de maior porte, onde as características complexas do sistema e o aumento da

dimensionalidade demandam uma estratégia de particionamento mais robusta. Em conclusão, o particionamento da rede se mostra uma abordagem promissora para melhorar a detecção de erros grosseiros em sistemas de potência, especialmente quando consideramos magnitudes menores de erros, onde a diferença de desempenho entre as configurações de rede se torna ainda mais expressiva.

7.4.5.2 Identificação

Apresentam-se abaixo os resultados das simulações, exibidos na Tabela 7, que fornecem uma análise detalhada das taxas de sucesso de identificação. Os dados foram obtidos para duas configurações: rede particionada e rede não particionada, considerando diferentes magnitudes de erro.

Tabela 7 – Taxas de sucesso de identificação para os casos de rede particionada e não particionada na rede teste de 118 barras.

Magnitude do erro	Rede particionada	Rede não particionada
30σ	81,12 %	80,80 %
25σ	82,56 %	77,92 %
20σ	80,16 %	76,64 %
15σ	74,88 %	68,32 %
10σ	65,76 %	36,80 %

Os resultados obtidos foram representados graficamente, proporcionando uma representação visual das tendências e diferenças nas taxas de sucesso de identificação. Os gráficos oferecem uma maneira mais intuitiva de analisar os dados, permitindo observar claramente as variações nas taxas de sucesso em relação à magnitude do erro.

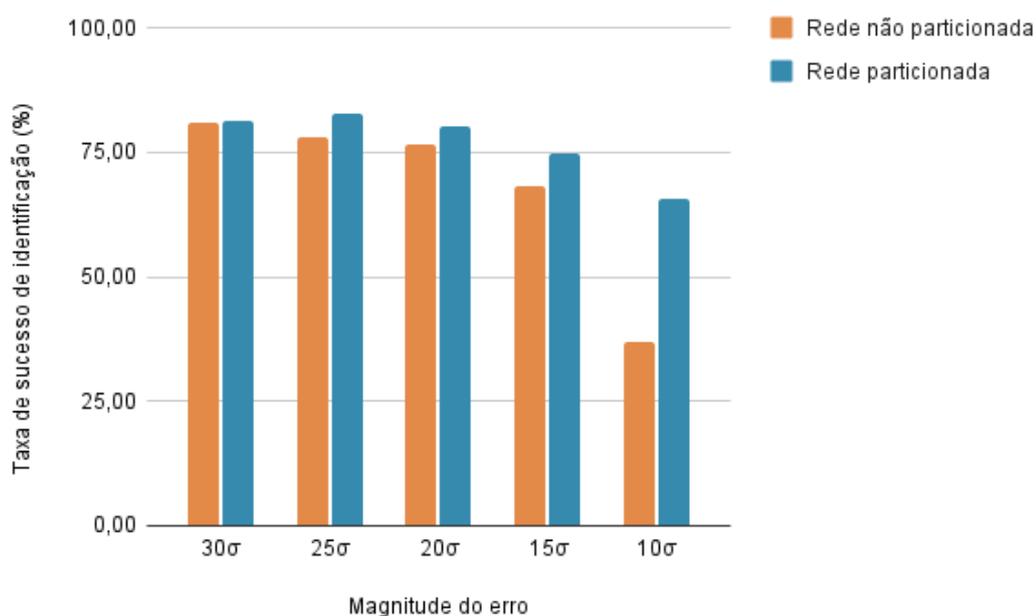


Figura 18 – Taxas de sucesso de identificação para a rede teste de 118 barras.

A análise das taxas de sucesso de identificação revelou algumas tendências interessantes. Os resultados foram obtidos em duas configurações: rede particionada e rede não particionada, considerando diferentes magnitudes de erro.

Ao comparar as configurações de rede particionada e rede não particionada, ficou evidente que a rede particionada apresentou taxas de sucesso de identificação mais altas em todas as magnitudes de erro.

Para a rede particionada, a taxa de sucesso se manteve relativamente estável em todas as magnitudes de erro, variando entre 82,56% e 65,76%. Isso indica que o particionamento da rede ajudou a minimizar o impacto do erro na identificação, garantindo uma taxa consistente de sucesso.

Por outro lado, a taxa de sucesso de identificação da rede não particionada diminuiu à medida que a magnitude do erro diminuiu. Em particular, ao lidar com um erro de 10σ, a taxa de sucesso caiu para 36,80%. Isso indica que a rede não particionada é menos sensível a erros menores, resultando em uma taxa de identificação significativamente menor.

Ao lidar com uma magnitude de erro de 20σ, a rede particionada obteve uma taxa de sucesso de 80,16%, enquanto a rede não particionada alcançou 76,64%. Novamente, a rede particionada apresentou um desempenho melhor.

Para uma magnitude de erro de 15σ, a taxa de sucesso de identificação da rede particionada foi de 74,88%, em comparação com 68,32% da rede não particionada. A diferença entre as configurações aumentou, mostrando a vantagem da rede particionada. Essa diferença reforça a eficácia da abordagem de rede particionada. O particionamento da rede proporcionou uma taxa de sucesso de identificação mais estável em todas as

magnitudes de erro, enquanto a rede não particionada mostrou-se menos capaz de lidar com erros menores. Essa estratégia oferece uma taxa de sucesso de identificação mais consistente e é especialmente benéfica em cenários com erros de magnitude menor.

7.4.6 Medianas das Métricas de Tensão

Os dados das medianas das métricas estão disponíveis na Tabela 8 apresentada abaixo. As medianas das métricas das estimativas fasoriais e da fusão das estimativas para as configurações de rede particionada e rede não particionada foram calculadas e registradas para cada magnitude de erro. As medianas das métricas de tensão para o sistema SCADA foram suprimidas, conforme mencionado anteriormente, devido a estas serem consideradas livre de erros grosseiros. A mediana para o sistema SCADA obtida para todos os casos é de 0,022264. A Tabela 8 fornecerá uma visão completa das medianas das métricas consideradas em cada cenário.

Tabela 8 – Medianas das métricas para os diferentes casos de magnitude do erro na rede teste de 118 barras.

Magnitude do Erro	Rede particionada		Rede não particionada	
	Estimador fasorial	Fusão das estimativas	Estimador fasorial	Fusão das estimativas
30σ	0,002379	0,002311	0,002412	0,002335
25σ	0,002422	0,00235	0,002469	0,002384
20σ	0,002391	0,002338	0,002429	0,002371
15σ	0,002518	0,002478	0,002708	0,002664
10σ	0,002667	0,002583	3,026900	2,90522

Os resultados obtidos foram também visualmente apresentados por meio do gráfico, exposto na Figura 19, permitindo uma compreensão mais clara e intuitiva das medianas das métricas nas diferentes magnitudes de erro para as configurações de rede particionada e rede não particionada. Essa representação gráfica dos dados oferece uma perspectiva visual que complementa a informação tabular, facilitando a identificação de tendências e padrões nos desempenhos das métricas.

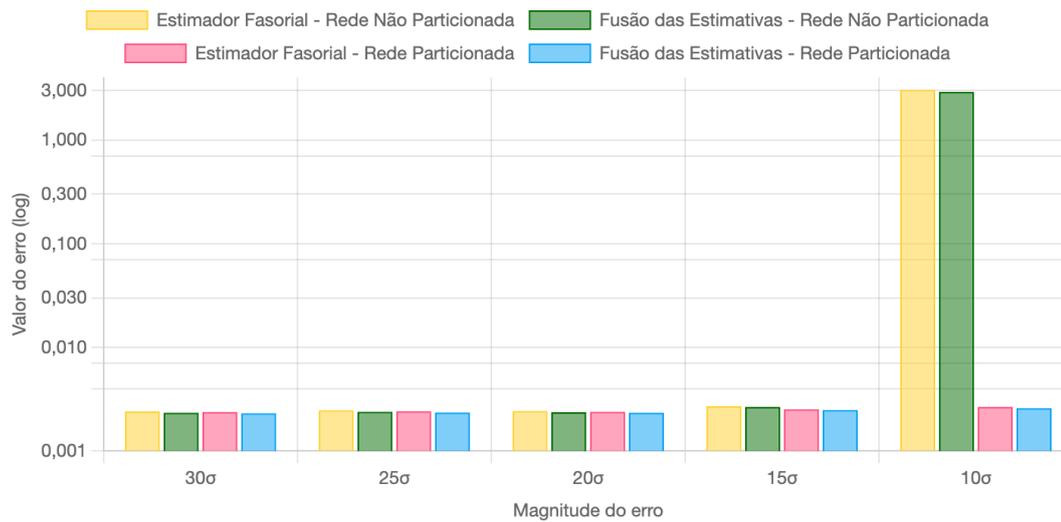


Figura 19 – Medianas das métricas de tensão para a rede teste de 118 barras.

Ao serem analisadas as métricas das estimativas fasoriais na rede particionada, observamos que os valores também se mantêm relativamente estáveis em todas as magnitudes de erro, com variações mínimas. Isso sugere que a rede particionada é capaz de manter um desempenho consistente no processamento de EGs, independentemente da magnitude do erro.

Em relação às métricas da fusão das estimativas na rede particionada, novamente nota-se uma estabilidade nos valores em todas as magnitudes de erro. Essa consistência indica que a abordagem de fusão de dados utilizada na rede particionada contribui para estimativas mais precisas e estáveis, independentemente da magnitude do erro.

No entanto, nas métricas das estimativas fasoriais na rede não particionada, nota-se que os valores aumentam à medida que a magnitude do erro diminui. Isso indica que a precisão das estimativas é comprometida em situações com erros menores.

Por fim, nas métricas da fusão das estimativas na rede não particionada, os valores também aumentam à medida que a magnitude do erro diminui. Isso sugere que a rede não particionada é mais sensível a erros menores, resultando em estimativas menos precisas e estáveis em cenários de menor magnitude de erro.

Ao analisar os dados das medianas métricas e correlacioná-los com as taxas de sucesso de detecção para os casos de erros grosseiros simulados, pode-se observar uma tendência consistente.

Na configuração de rede particionada, onde as taxas de sucesso de detecção são mais altas, as métricas das estimativas fasoriais e de fusão das estimativas apresentam valores mínimos e máximos mais estáveis em todas as magnitudes de erro. Isso sugere uma precisão mais consistente na detecção, conforme evidenciado pelas medianas dessas métricas.

Por outro lado, na configuração de rede não particionada, onde as taxas de su-

cesso de detecção são potencialmente mais baixas, as métricas das estimativas fasoriais e da fusão das estimativas exibem uma maior variabilidade nos valores mínimos e máximos, principalmente na magnitude de erro de 10σ . Essa maior variabilidade pode estar relacionada a uma menor precisão na detecção.

Assim, a correlação entre as taxas de sucesso de detecção e as medianas das métricas sugere que quanto maior a taxa de detecção, mais precisa tende a ser a estimativa. Na rede particionada, onde as taxas de sucesso de detecção são mais altas, observamos menor variabilidade nas medianas das métricas, indicando uma detecção mais precisa e estável.

Por outro lado, na rede não particionada, onde as taxas de sucesso de detecção são potencialmente mais baixas, a maior variabilidade nas medianas das métricas pode indicar uma menor precisão na detecção.

Portanto, os resultados reforçam a importância do particionamento da rede na obtenção de estimativas mais precisas e estáveis, refletindo-se em taxas de detecção mais altas.

7.4.7 Sistema Teste de 300 Barras

Nesta subseção, será apresentada uma análise detalhada dos resultados obtidos por meio das simulações conduzidas no sistema teste IEEE de 300 barras, com o objetivo de verificar a detecção e identificação de erros grosseiros na rede. Foram realizadas um total de 20 conjuntos de 1479 simulações cada, visando reduzir a influência de erros gaussianos nos testes. Os cenários de erro grosseiro foram variados, abrangendo magnitudes de 30σ a 10σ . As simulações foram realizadas tanto para as configurações de rede particionada quanto para as configurações de rede não particionada, permitindo uma comparação abrangente dos resultados. Abaixo, na Figura 20, apresenta-se o particionamento do plano fasorial do sistema teste de 300 barras em 20 *clusters*, fornecendo uma referência visual para o particionamento aplicado no sistema.

Ao longo da análise, são examinados diversos aspectos, como a taxa de detecção e identificação de erros grosseiros, a precisão das estimativas obtidas, bem como o impacto das diferentes magnitudes de erro nos resultados. Os resultados obtidos são de suma importância para compreender a eficácia do particionamento na detecção e identificação desses erros, permitindo aprimorar a etapa de processamento de erros grosseiros. Além disso, esses resultados orientarão possíveis melhorias e otimizações nas configurações de rede particionada e não particionada, impulsionando o desenvolvimento de estratégias mais eficientes no tratamento de erros grosseiros.

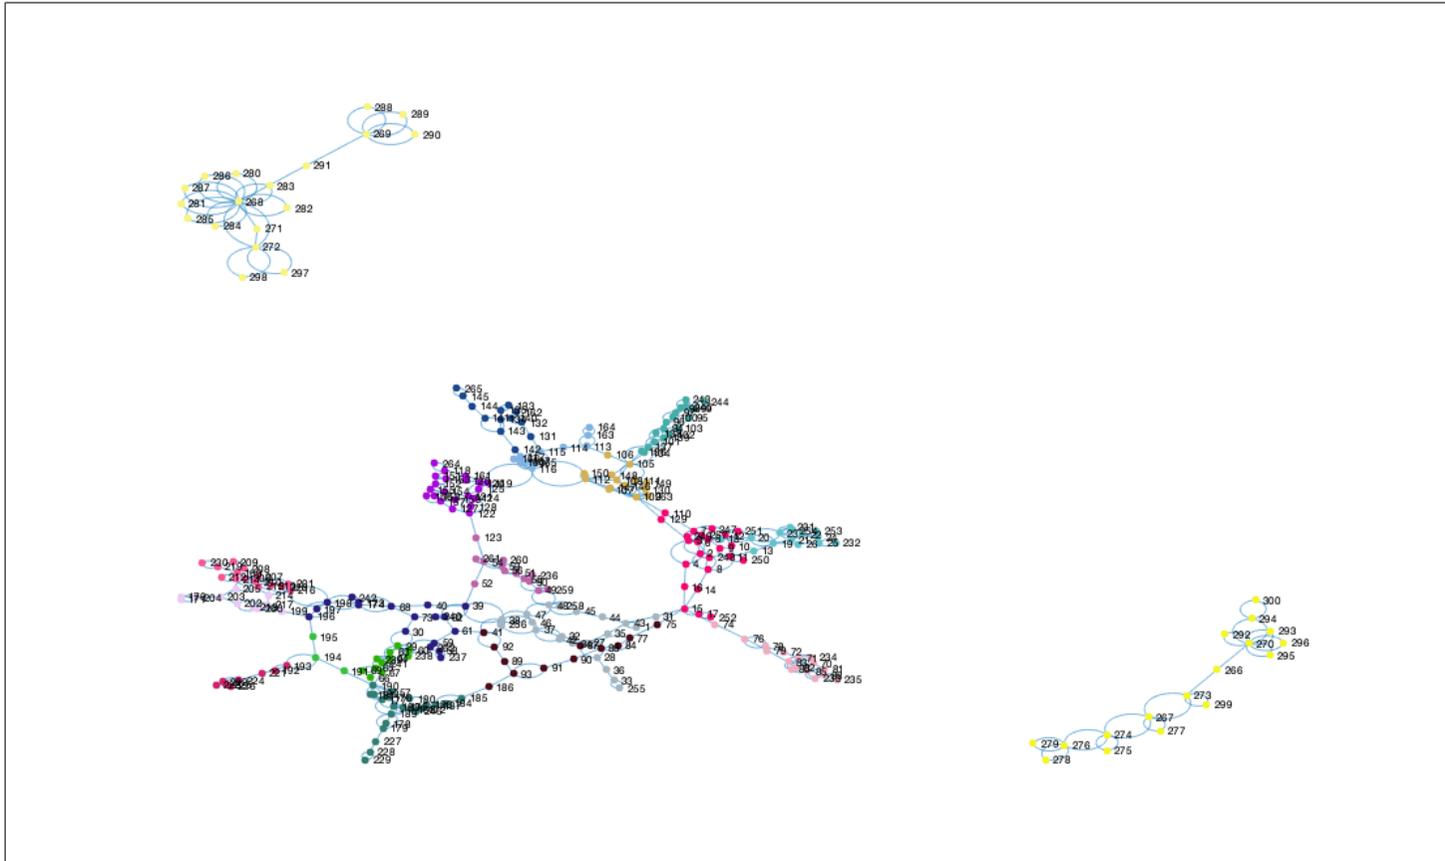


Figura 20 – Rede de 300 barras com particionamento do plano de medição fasorial de 20 *clusters*.

Na Figura 20, o plano de medição é particionado em *clusters* e os vértices representam as barras onde as medições de tensão estão sendo realizadas ou os barramentos que possuem ramos com medidas sincrofasoriais de corrente. As linhas azuis indicam a presença de medições sincrofasoriais de corrente nesses ramos.

É importante observar que, na figura, apenas os barramentos monitorados por PMUs e aqueles com ramos contendo medições sincrofasoriais de corrente são exibidos. Ou seja, somente o plano de medição sincrofasorial está representado. Como consequência, as linhas que conectam barras sem PMUs ou ramos sem medição de corrente sincrofasorial não estão presentes na figura. No entanto, isso não significa que não haja mais barras e linhas no sistema.

Adicionalmente, é necessário ressaltar que a não representação dos demais barramentos e linhas no grafo de medição fasorial não implica que a rede seja desconexa. A Figura 11, exemplificada na Subseção 6.3.2, ilustra esse ponto. Embora apenas as medições sincrofasoriais e os barramentos associados sejam exibidos, a rede elétrica continua sendo conexa.

Portanto, é importante compreender que a representação gráfica das medições sincrofasoriais no grafo de medição fasorial não abrange todos os elementos da rede, mas aqueles que estão sendo monitorados ou possuem medidas diretas associadas. A rede elétrica em si é conectada, independentemente da representação gráfica utilizada para análise e visualização das medições.

7.4.8 Taxas de sucesso

Nesta subseção, serão apresentadas as taxas de sucesso de detecção e de identificação obtidas nas simulações conduzidas no sistema teste IEEE de 300 barras. Essas taxas são medidas fundamentais para avaliar a eficiência do sistema no que diz respeito à detecção e identificação de erros grosseiros.

Os resultados serão apresentados em tabelas, oferecendo uma visão clara sobre o desempenho do sistema em diferentes cenários de erro, abrangendo magnitudes de 30σ a 10σ , tanto para as configurações de rede particionada quanto para as configurações de rede não particionada. Além disso, os dados serão representados de maneira gráfica para uma visualização mais intuitiva e comparativa das taxas de sucesso.

7.4.8.1 Detecção

Será apresentada uma análise das taxas de sucesso obtidas nas simulações conduzidas para avaliar a proposta de particionamento da rede no sistema teste IEEE de 300 barras. O objetivo dessas simulações foi avaliar a efetividade do particionamento da rede na detecção de erros grosseiros em diferentes cenários de magnitude. Os resultados das taxas de sucesso estão disponíveis na Tabela 9 e foram plotados graficamente para uma melhor visualização dos dados, conforme exposto na Figura 21.

Tabela 9 – Taxas de sucesso de detecção para os casos de rede particionada e não particionada na rede teste de 300 barras.

Magnitude do erro	Rede particionada	Rede não particionada
30σ	92,83 %	86,07 %
25σ	91,28 %	80,26 %
20σ	88,64 %	73,97 %
15σ	82,69 %	57,13 %
10σ	72,08 %	12,44 %

Serão examinadas as taxas de sucesso em relação às magnitudes de erro grosseiro, enfatizando as diferenças entre a rede particionada e a rede não particionada. Essa análise proporcionará informações valiosas sobre a eficácia do particionamento da rede na detecção de erros grosseiros, auxiliando no direcionamento de possíveis melhorias e otimizações futuras.

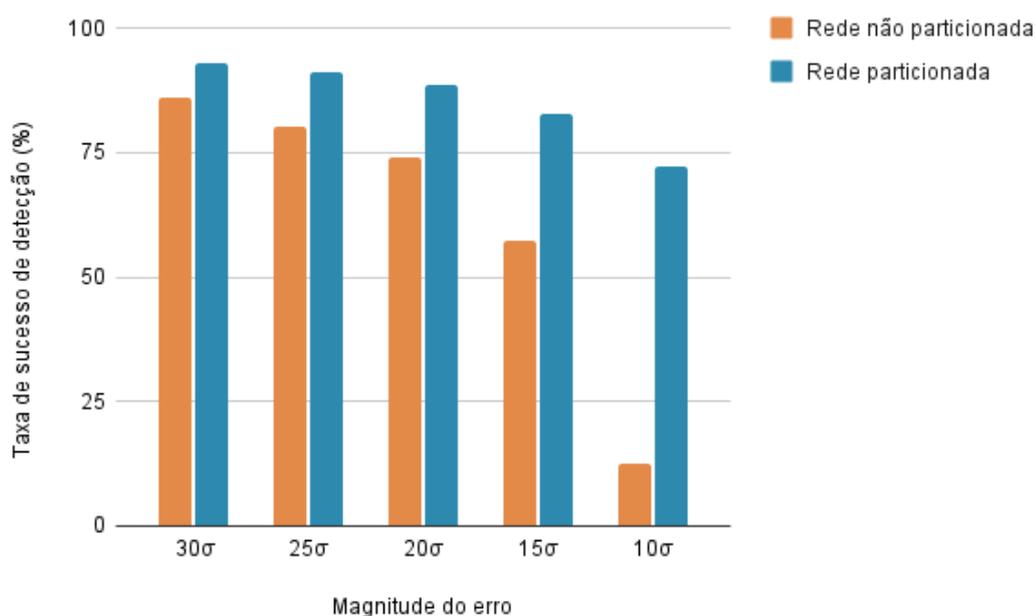


Figura 21 – Taxas de sucesso de detecção para a rede teste de 300 barras.

Ao analisar as taxas de detecção apresentadas, observa-se uma diferença significativa entre a rede particionada e a rede não particionada à medida que as magnitudes do erro grosseiro são diminuídas de 30σ para 10σ . Verifica-se que a rede particionada apresenta valores muito superiores para a detecção desses erros de menor magnitude em comparação com a rede não particionada.

Para uma magnitude de erro grosseiro de 30σ , a taxa de detecção é de 92,83% para a rede particionada, enquanto a rede não particionada apresenta uma taxa de detecção de 86,07%. Essa diferença de 6,76% entre as taxas indica a superioridade da rede particionada na detecção de erros com essa magnitude.

À medida que a magnitude diminui para 25σ , a rede particionada mantém uma alta taxa de detecção de 91,28%, enquanto a taxa de detecção da rede não particionada diminui para 80,26%. A diferença de 11,02% entre as taxas destaca ainda mais a eficácia da rede particionada na detecção de erros de menor magnitude.

No caso de uma magnitude de 20σ , a rede particionada mantém uma taxa de detecção de 88,64%, enquanto a rede não particionada tem uma taxa de detecção de 73,97%. Essa diferença de 14,67% entre as taxas reforça a superioridade da rede particionada na detecção de erros com essa magnitude.

Ao considerar a magnitude de 15σ , a rede particionada apresenta uma taxa de detecção de 82,69%, enquanto a rede não particionada tem uma taxa de detecção de 57,13%. A diferença de 25,56% entre as taxas destaca a considerável superioridade da rede particionada na detecção de erros de menor magnitude.

Por fim, na magnitude de 10σ , a rede particionada continua a se destacar, com uma taxa de detecção de 72,08%, enquanto a rede não particionada apresenta uma taxa de detecção significativamente menor, de apenas 12,44%. A diferença de 59,64% entre as taxas evidencia claramente a eficiência da rede particionada na detecção de erros com essa magnitude.

Essa análise ressalta a importância do particionamento da rede no sistema teste IEEE de 300 barras, demonstrando que a detecção de erros grosseiros é significativamente aprimorada na rede particionada, especialmente em cenários com magnitudes menores.

7.4.8.2 Identificação

As taxas de identificação dos erros grosseiros estão apresentadas na Tabela 10 e foram plotadas graficamente na Figura 22. Ao examinar os dados, é possível notar uma diferença significativa entre a rede particionada e a rede não particionada quando as magnitudes do erro grosseiro são reduzidas de 30σ para 10σ .

Tabela 10 – Taxas de sucesso de identificação para os casos de rede particionada e não particionada na rede teste de 300 barras.

Magnitude do erro	Rede particionada	Rede não particionada
30σ	81,81 %	77,35 %
25σ	79,99 %	72,41 %
20σ	77,82 %	66,06 %
15σ	71,94 %	53,35 %
10σ	62,14 %	11,36 %

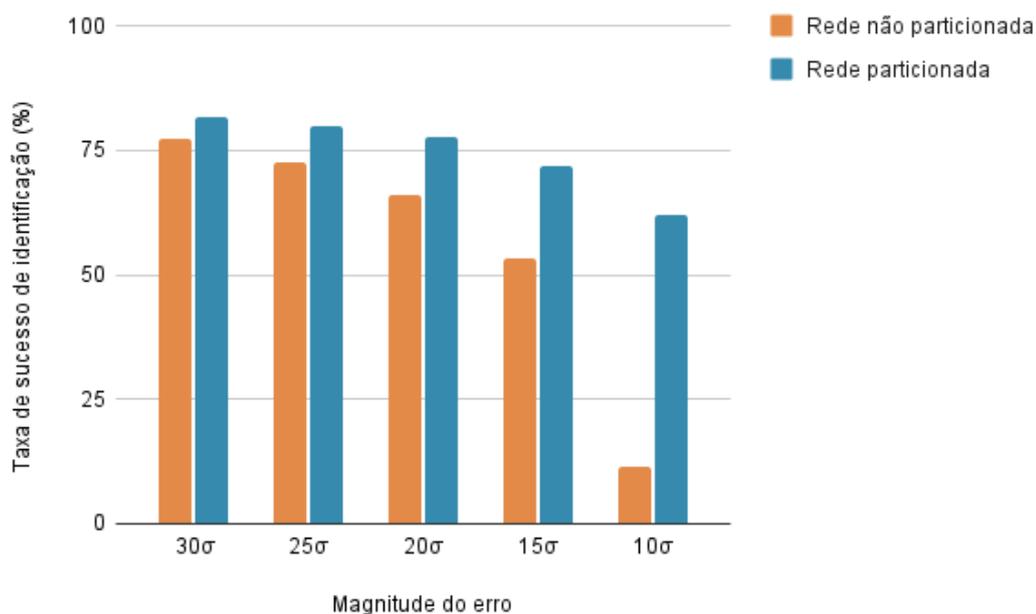


Figura 22 – Taxas de sucesso de detecção para a rede teste de 300 barras.

Para uma magnitude de erro grosseiro de 30σ , a taxa de identificação da rede particionada é de 81,81%, enquanto a da rede não particionada é de 77,35%. Isso representa uma diferença de 4,46% entre as duas taxas, indicando que a rede particionada tem uma vantagem na identificação de erros de menor magnitude.

À medida que a magnitude diminui para 25σ , a taxa de identificação da rede particionada permanece elevada em 79,99%, enquanto a taxa da rede não particionada diminui para 72,41%. A diferença entre as taxas aumenta para 7,58%, destacando ainda mais a superioridade da rede particionada na identificação de erros com magnitudes menores.

No caso de uma magnitude de 20σ , a taxa de identificação da rede particionada é de 77,82%, enquanto a taxa da rede não particionada é de 66,06%. Essa diferença de 11,76% entre as taxas reforça a eficácia da rede particionada na identificação de erros com menor magnitude.

Ao considerar a magnitude de 15σ , observamos que a taxa de identificação da rede particionada é de 71,94%, enquanto a da rede não particionada é de 53,35%. A diferença entre as taxas é de 18,59%, ressaltando a considerável superioridade da rede particionada na identificação de erros de menor magnitude.

Por fim, na magnitude de 10σ , a taxa de identificação da rede particionada ainda é significativamente superior, atingindo 62,14%, enquanto a taxa da rede não particionada é de apenas 11,36%. A diferença de 50,78% entre as taxas destaca claramente a eficiência da rede particionada na identificação de erros com essa magnitude.

Essa análise reforça a importância do particionamento da rede no sistema teste

IEEE de 300 barras, demonstrando que a rede particionada apresenta taxas de identificação significativamente superiores para erros de menor magnitude quando comparada à rede não particionada. Isso evidencia a eficácia da abordagem de particionamento na melhoria da identificação de erros grosseiros.

7.4.9 Medianas das Métricas de Tensão

A análise das métricas medianas de tensão revela diferenças significativas entre a rede particionada e a rede não particionada, considerando as diferentes magnitudes de erro grosseiro. Os dados das simulações realizadas estão apresentados na Tabela 11 e de maneira gráfica na Figura 23. Pela tabela podem ser verificadas as informações das métricas das medianas de tensão para diferentes magnitudes de erro grosseiro nas configurações de rede particionada e rede não particionada.

Tabela 11 – Medianas das métricas para os diferentes casos de magnitude do erro na rede teste de 300 barras.

Magnitude do Erro	Rede particionada		Rede não particionada	
	Estimador fasorial	Fusão das estimativas	Estimador fasorial	Fusão das estimativas
30σ	0,006586	0,006071	0,006632	0,006125
25σ	0,006608	0,006100	0,006708	0,006225
20σ	0,006584	0,006101	0,006875	0,006360
15σ	0,006709	0,006202	0,007584	0,006953
10σ	0,007042	0,006533	5,530829	4,383918

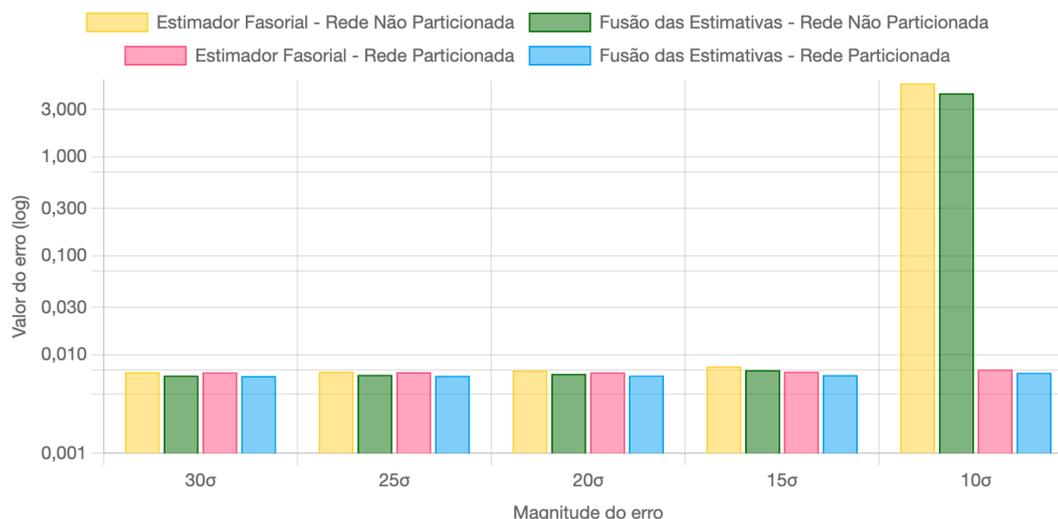


Figura 23 – Medianas das métricas de tensão para a rede teste de 300 barras.

Destaca-se que, dentre as métricas medianas analisadas, os melhores resultados são observados para a fusão das estimativas tanto na rede particionada quanto na rede não particionada. Em todos os casos de magnitude de erro grosseiro, a fusão das estimativas apresenta valores mais baixos, indicando uma maior precisão na estimativa de tensão.

Esses resultados reforçam a importância do uso da fusão de informações provenientes de diferentes estimadores para melhorar a acurácia das estimativas de tensão, independentemente da configuração da rede. A estratégia de fusão das estimativas se mostra promissora e pode ser uma abordagem eficaz para lidar com erros grosseiros e obter resultados mais confiáveis no contexto do processamento de dados de sistemas elétricos.

Ao diminuir as magnitudes do erro grosseiro de 30σ para 10σ , observa-se um aumento acentuado nas métricas medianas tanto para o estimador fasorial quanto para a fusão das estimativas na rede não particionada. Para o estimador fasorial, a mediana aumenta drasticamente de 0,006632 para 5,530829, e para a fusão das estimativas, a mediana aumenta de 0,006125 para 4,383918 no mesmo intervalo. Esses valores destacam a sensibilidade da rede não particionada a erros grosseiros de menor magnitude, resultando em métricas medianas significativamente mais altas e estimativas de tensão menos precisas.

Em contraste, na rede particionada, as métricas medianas para ambos os estimadores permanecem relativamente estáveis e baixas, independentemente da magnitude do erro grosseiro. No caso do estimador fasorial, por exemplo, a mediana na rede particionada varia de 0,006586 para 0,007042, enquanto na rede não particionada, a mediana aumenta de 0,006632 para 5,530829. Já para a fusão das estimativas, a mediana na rede particionada varia de 0,006071 para 0,006533, enquanto na rede não particionada, a mediana aumenta de 0,006125 para 4,383918. Essas diferenças numéricas evidenciam a superioridade da rede particionada em relação à rede não particionada, especialmente em cenários com erros grosseiros de menor magnitude. A rede particionada apresenta métricas medianas mais baixas, isso indica uma maior capacidade da rede particionada em manter estimativas mais precisas de tensão, mesmo em cenários com erros grosseiros de menor magnitude.

Essas diferenças nas métricas medianas refletem o desempenho superior da rede particionada na estimativa de tensão em comparação com a rede não particionada. A menor variação das métricas medianas na rede particionada indica uma maior robustez e estabilidade das estimativas, mesmo quando sujeitas a erros grosseiros de diferentes magnitudes.

É importante ressaltar que as taxas de detecção desempenham um papel crucial nessa análise. A rede particionada geralmente apresenta taxas de detecção mais altas em comparação com a rede não particionada, especialmente quando a magnitude do erro grosseiro é reduzida. Essas taxas de detecção mais altas contribuem para um melhor desempenho geral da rede particionada, permitindo um processamento mais eficiente dos erros grosseiros e, conseqüentemente, influenciando nas métricas medianas de tensão.

Em resumo, os resultados indicam que a rede particionada apresenta um desempenho mais preciso e robusto na estimativa de tensão, mesmo em situações com erros grosseiros de menor magnitude. A menor variação das métricas das medianas, combinada com taxas de detecção mais altas, reforça a eficácia do particionamento da rede como uma estratégia para melhorar a precisão e confiabilidade das estimativas de tensão.

7.5 ANÁLISE COMPARATIVA DE DESEMPENHO DO PARTICIONAMENTO DE REDES

A seção de Análise Comparativa de Desempenho do Particionamento de Redes tem como objetivo examinar e avaliar o desempenho da técnica de particionamento aplicadas em redes elétricas de tamanhos distintos. Nesta seção, são analisadas as redes de 57, 118 e 300 barras, buscando identificar os impactos do particionamento no desempenho geral na etapa de processamento de erros grosseiros dos sistemas estudados.

As Figuras 24 e 25 apresentam os dados das taxas de sucesso de detecção e identificação de erros, respectivamente. Essas representações gráficas fornecem informações valiosas sobre o desempenho do processamento de erros grosseiros para os diferentes sistemas, permitindo uma comparação clara entre redes particionadas e não particionadas. Ao analisar os gráficos, é possível obter uma compreensão abrangente do comportamento das taxas de sucesso em relação às diferentes magnitudes de erro. Essas visualizações oferecem uma perspectiva visual do desempenho relativo das redes, auxiliando na identificação de padrões e tendências relevantes para a detecção e identificação de erros grosseiros.

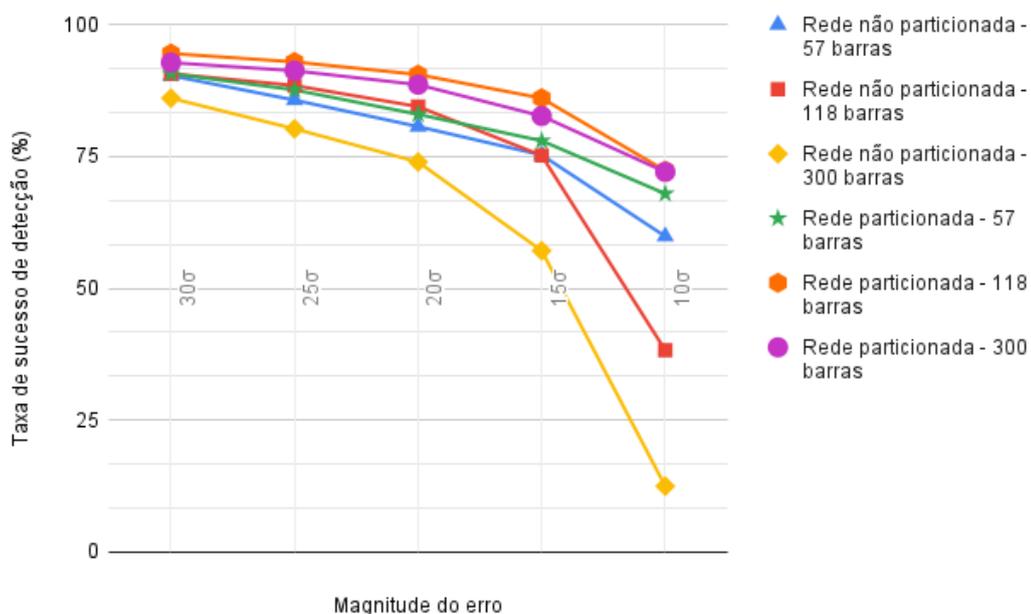


Figura 24 – Taxas de sucesso de detecção em diferentes magnitudes de erro para os sistemas de 57, 118 e 300 barras nas configurações particionadas e não particionadas.

Ao analisar as taxas de sucesso de detecção, pode-se observar uma diferença significativa entre as redes particionadas e não particionadas, especialmente para sistemas de maior porte, como o de 118 e 300 barras. Verifica-se que, nas redes não particionadas, as taxas de sucesso diminuem consideravelmente à medida que a magnitude do erro diminui. Por exemplo, na rede não particionada de 300 barras, a taxa de sucesso é de apenas 12,44%

para um erro de 10σ , enquanto na rede particionada de 300 barras, a taxa de sucesso é de 72,08% para a mesma magnitude de erro.

Observando os resultados em detalhes, nota-se que o particionamento das redes traz benefícios significativos. Na rede particionada de 118 barras, as taxas de sucesso de detecção são consideravelmente mais altas do que na rede não particionada em todas as magnitudes de erro. Para um erro de 10σ , a taxa de sucesso na rede particionada é de 72,32%, enquanto na rede não particionada é de apenas 38,24%.

Além disso, é interessante destacar que, na rede particionada de 57 barras, as taxas de sucesso são relativamente altas tanto para a rede particionada quanto para a não particionada. No entanto, o particionamento ainda apresenta uma pequena vantagem, com taxas de sucesso ligeiramente superiores em todas as magnitudes de erro.

Essa análise comparativa reforça a importância do particionamento de redes em sistemas complexos, pois fornece uma melhora significativa para as taxas de sucesso de detecção em cenários de erros grosseiros de maiores e menores magnitudes. Esses resultados demonstram que o particionamento é especialmente crucial em sistemas de porte realístico, como o de 118 e 300 barras, onde as taxas de sucesso são significativamente mais baixas na ausência do particionamento.

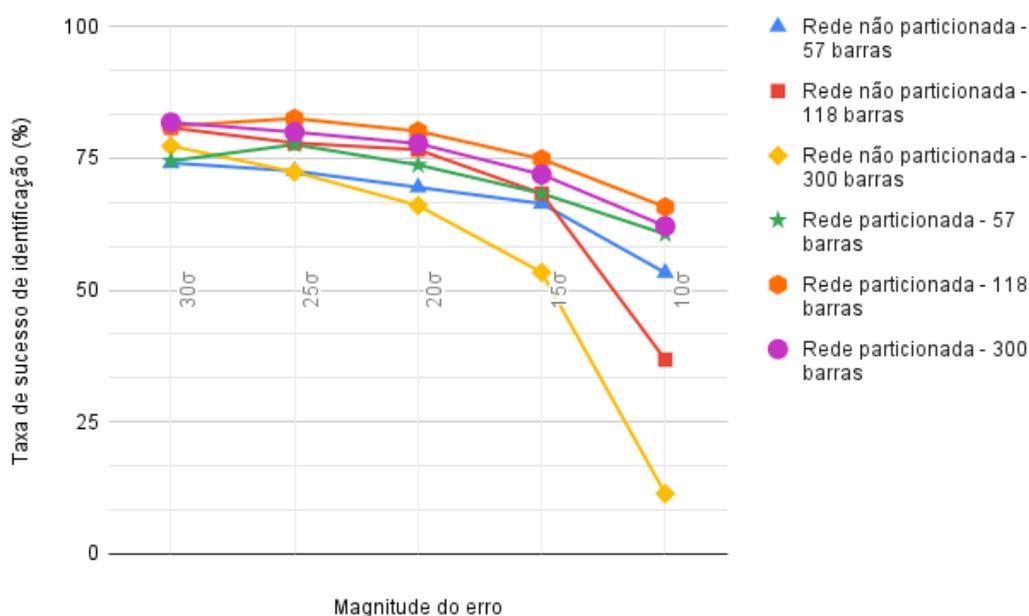


Figura 25 – Taxas de sucesso de identificação em diferentes magnitudes de erro para os sistemas de 57, 118 e 300 barras nas configurações particionadas e não particionadas.

Para as taxas de sucesso de identificação, é igualmente possível notar diferenças marcantes entre as redes particionadas e não particionadas. Os resultados demonstram que o particionamento das redes tem um impacto positivo na taxa de sucesso de identificação,

especialmente em sistemas de maior porte.

Ao considerar a rede não particionada de 300 barras, por exemplo, verifica-se que as taxas de sucesso de identificação são significativamente baixas em todas as magnitudes de erro. Para um erro de 10σ , a taxa de sucesso é de apenas 11,36%. No entanto, na rede particionada de 300 barras, as taxas de sucesso de identificação são consideravelmente mais altas, alcançando 62,14% para a mesma magnitude de erro.

Essa tendência também pode ser observada na rede de 118 barras, onde as taxas de sucesso de identificação são notavelmente melhores na rede particionada em comparação com a não particionada. Por exemplo, para um erro de 15σ , a taxa de sucesso na rede particionada é de 74,88%, enquanto na rede não particionada é de apenas 68,32%.

Na rede de 57 barras, embora as taxas de sucesso de identificação sejam relativamente altas tanto para a rede particionada quanto para a não particionada, o particionamento ainda apresenta vantagens notáveis. Para um erro de 10σ , a taxa de sucesso na rede particionada é de 60,62%, enquanto na rede não particionada é de 53,28%.

Essa análise evidencia os benefícios do particionamento de redes na melhoria das taxas de sucesso de identificação. O particionamento possibilita um desempenho mais eficiente na etapa de identificação de erros grosseiros, mesmo diante de erros de menor magnitude. Em especial, é importante destacar que o particionamento é particularmente relevante em sistemas de porte realístico, como as redes de 118 e 300 barras, onde as taxas de sucesso de identificação são notavelmente mais altas na presença do particionamento.

7.6 DESEMPENHO COMPUTACIONAL

Nesta seção, será discutido o desempenho das técnicas propostas. O computador utilizado possui um processador Intel Core i5 Dual-Core de 1,8 GHz e 8 GB de memória DDR3 com uma frequência de 1600 MHz. As simulações foram conduzidas no *software* Matlab R2020a. Os tempos apresentados são médias dos tempos obtidos para simulações executadas sob condições idênticas.

Tabela 12 – Tempos de processamento computacional em segundos.

Sistema Teste	Tempo de processamento (s)		
	Processamento de EG	Particionamento	Fusão em coordenadas retangulares
57 barras	0,066	0,242	0,009
118 barras	0,307	1,868	0,046
300 barras	0,534	2,329	0,097

Para cada um dos sistemas teste, foram simulados erros grosseiros simples como parte do processo de avaliação. Os tempos de processamento de EG apresentados incluem as etapas de detecção, identificação e remoção dos erros grosseiros. Além disso, o tempo para o particionamento do plano de medição também é relatado. Por fim, o tempo para a

fusão em coordenadas retangulares abrange todo o processo de formulação da fusão e a conversão de coordenadas necessária para o cálculo dos resultados.

Os resultados evidenciam que o tempo de execução do particionamento é primordialmente influenciado pelo tamanho do sistema (e, conseqüentemente, pelo tamanho do plano de medição) e pelo número desejado de partições, sendo observado que o tamanho do sistema possui uma influência mais significativa no esforço computacional. Ademais, os resultados indicam que a técnica de clusterização empregada é adequada para a aplicação em análise, como corroborado pelo baixo esforço computacional necessário. É importante ressaltar que o algoritmo de particionamento deve ser executado *off line*. Atualizações são requeridas somente quando ocorrem alterações na topologia da rede ou no plano de medição.

7.7 CONCLUSÃO

Considerando os resultados apresentados, torna-se evidente o significativo impacto da técnica de particionamento na detecção e identificação de erros, especialmente em redes de maior porte e em situações de erros de menor magnitude. Observa-se que essa técnica melhora não apenas a capacidade de detectar e identificar erros, mas também apresenta maior robustez para lidar com erros de menor magnitude em comparação com a rede não particionada.

Essa vantagem é particularmente acentuada nas redes de teste de maior porte (118 e 300 barras). À medida que a magnitude do erro diminui para 10σ , a diferença na taxa de sucesso entre a rede particionada e a não particionada se torna bastante pronunciada. Para a rede de 300 barras, por exemplo, a taxa de sucesso de detecção para a rede particionada é quase seis vezes maior do que para a rede não particionada (72,08% versus 12,44%, respectivamente). Na identificação de erros, a taxa de sucesso da rede particionada é mais de cinco vezes maior do que a da não particionada para a mesma rede (62,14% versus 11,36%).

Esses resultados sublinham a eficácia superior do método de particionamento no processamento de EGs em redes de porte realístico, melhorando a capacidade de detecção e identificação de erros, principalmente para erros de menor magnitude. Essa robustez acrescida torna a abordagem de particionamento uma escolha promissora para o processamento de erros grosseiros em redes de energia de grande escala.

Do ponto de vista do desempenho computacional (Tabela 12), observa-se que o tempo de processamento para a rede de 57 barras é menor, como seria de se esperar devido ao seu tamanho. À medida que o tamanho da rede aumenta, o tempo de processamento também aumenta, tanto para o processamento de EG, para o particionamento, quanto para a fusão em coordenadas retangulares. Porém é importante ressaltar que o algoritmo de partição deve ser executado em ambiente *off line*, sendo que atualizações só se tornam necessárias em caso de alterações na topologia da rede e/ou do plano de medição

sincrofasorial.

8 CONCLUSÃO

8.1 CONSIDERAÇÕES FINAIS

O uso do sistema de medição fasorial sincronizada possibilitou a obtenção direta de fasores de sequência positiva de tensão e corrente nos sistemas elétricos de potência. Essas medidas são adquiridas em subestações geograficamente distintas por meio das unidades de medição fasorial (PMUs), cuja referência de tempo é fornecida pelo sistema de posicionamento global (GPS).

Com a disponibilidade das PMUs, surge a oportunidade de aprimorar os algoritmos de estimação de estados, incorporando as medidas fasoriais no conjunto de dados processado por essa ferramenta. Embora o sistema de medição fasorial sincronizada não substitua completamente as medidas tradicionais obtidas por meio do sistema SCADA, essas duas formas de medição serão combinadas gradualmente em aplicativos do sistema de potência, permitindo a utilização de diferentes sistemas de medição em diversas ferramentas.

A estimação de estados desempenha um papel crucial nos centros de operação em tempo real, fornecendo informações atualizadas sobre o estado operativo da rede elétrica. É essencial que as estimativas de estados reflitam com precisão as condições de operação da rede. No entanto, a ocorrência de medidas elétricas grosseiras representam um desafio significativo para o desempenho do processo de estimação. O processamento inadequado dessas medidas pode comprometer as estimativas produzidas, resultando em informações inconsistentes em relação ao estado real da rede.

O Controle de Segurança é uma estratégia fundamental nos centros de operação de sistemas elétricos de potência, buscando tomar ações corretivas e preventivas para garantir a continuidade e qualidade do suprimento de energia elétrica aos consumidores. Para isso, é de extrema importância que o Operador possa monitorar a condição operativa do sistema com confiabilidade, permitindo a tomada de ações de controle de forma segura. Nesse contexto, o Estimador de Estados desempenha um papel crucial, fornecendo ao Operador os valores mais prováveis dos estados do sistema em tempo real, considerando as diversas fontes de erro associadas aos sistemas de medição. É essencial equipar essa ferramenta com técnicas de processamento capazes de detectar, identificar e remover dados contaminados com erros grosseiros, garantindo a confiabilidade dos resultados da estimação.

Diversas estruturas foram propostas para incluir medidas fasoriais na estimação de estados, gerando as chamadas arquiteturas híbridas de estimação. As estratégias de fusão de estimativas, compostas por dois estágios, têm se mostrado particularmente atrativas, pois mantêm a infraestrutura existente e apenas adicionam um módulo de processamento de medidas fasoriais. Além disso, essas abordagens possibilitam a utilização de algoritmos lineares não iterativos para processar as medidas fasoriais, convertendo-as em coordenadas retangulares. No entanto, medidas expressas em coordenadas retangulares apresentam correlação estatística não desprezível entre seus componentes cartesianos, que é indevida-

mente desconsiderada por alguns métodos de estimação baseados em fatores de ponderação escalares. Esta aproximação prejudica as propriedades estatísticas da solução, o que por sua vez afeta o desempenho dos métodos de processamento de erros grosseiros.

Para lidar com essa dificuldade, foi desenvolvido um estimador de estados baseado em rotações de Givens em blocos, permitindo o processamento de medidas fasoriais ponderadas por blocos 2×2 , o que permite considerar a correlação entre os componentes retangulares no resultado da estimação de estados. Essa abordagem abre caminho para melhorias significativas na estimação de estados em sistemas elétricos de potência (BEZ, D. M. *et al.*, 2020).

O objetivo principal desta dissertação é contribuir para o aprimoramento do desempenho dos métodos de processamento de erros grosseiros dentro da arquitetura híbrida de fusão de estimativas, em especial para redes de porte realístico. Para alcançar esse objetivo, foi adotada a estratégia de *clustering* da rede por meio do particionamento do plano de medição fasorial. Essa abordagem visa aumentar a sensibilidade na detecção de erros grosseiros, permitindo uma melhor identificação e recuperação desses erros. Ao utilizar o particionamento do plano de medição, é possível obter melhorias significativas de desempenho na etapa de processamento de EGs, resultando em estimativas de estados mais confiáveis e precisas.

A partir dos resultados obtidos com as simulações computacionais realizadas por meio dos sistemas teste IEEE de 57, 118 e 300, pode-se observar o impacto significativo da técnica de particionamento na detecção de erros, especialmente em redes de maior porte e em situações de erros de menor magnitude. Os resultados das taxas de sucesso de detecção e identificação apresentam uma clara diferença entre as redes particionadas e não particionadas.

No sistema de 57 barras, os resultados indicam que tanto a taxa de detecção quanto a taxa de identificação são elevadas para ambos os casos de rede particionada e não particionada, mantendo-se acima de 60% e 50%, respectivamente, mesmo para erros considerados pequenos, de magnitude próxima a 10σ , onde σ é o desvio padrão da medida. No entanto, é notável que a rede particionada apresenta taxas ligeiramente superiores em todos os casos de magnitude do erro, demonstrando sua capacidade de melhoria no processamento de erros grosseiros.

Os resultados obtidos para o sistema de 118 barras destacam a clara vantagem da rede particionada em relação à rede não particionada na detecção e identificação de erros grosseiros. Essa diferença é particularmente acentuada em erros de menor magnitude, como os de 15σ e 10σ . Para erros de 15σ , a taxa de sucesso na detecção na rede particionada é notavelmente maior, alcançando cerca de 86%, enquanto na rede não particionada é de aproximadamente 75%. Da mesma forma, a taxa de identificação na rede particionada é significativamente maior, atingindo aproximadamente 69%, em comparação com a taxa de 66% na rede não particionada. Em erros de 10σ , a diferença na taxa de sucesso entre

as redes é ainda mais expressiva. A rede particionada apresenta uma taxa de detecção de aproximadamente 72%, enquanto a rede não particionada registra apenas 38%. Esses resultados demonstram claramente a eficácia do particionamento do sistema de medição na melhoria da detecção de erros grosseiros, especialmente em situações de menor magnitude, proporcionando uma abordagem robusta e confiável para o processamento desses erros em sistemas de energia de grande escala.

No sistema de 300 barras, os resultados destacam a eficácia do particionamento na detecção e identificação de erros, para todas as magnitudes simuladas. A taxa de sucesso na rede particionada é consideravelmente maior em comparação com a rede não particionada, alcançando valores acima de 90% para a detecção e aproximadamente 80% para a identificação em erros de 30σ . Esta diferença entre as taxas de sucesso se torna ainda mais pronunciada à medida que a magnitude do erro diminui. Em erros de 15σ , a taxa de detecção na rede particionada é superior a 82%, enquanto na rede não particionada é de aproximadamente 57%. Já para erros de 10σ , a taxa de detecção na rede particionada fica acima de 72%, enquanto na rede não particionada não passa de 13%. Esses resultados evidenciam claramente a superioridade da estratégia de particionamento para o processamento de erros grosseiros, especialmente em situações de erros de menor magnitude, proporcionando uma detecção mais confiável e precisa.

Em conclusão, o particionamento demonstrou melhorias significativas na capacidade de processamento de erros grosseiros, principalmente para erros de menor magnitude, aumentando a confiabilidade nos resultados da estimação de estados. Além disso, tanto a abordagem da estimação híbrida da fusão de estimativas em coordenadas retangulares, como a estratégia de particionamento apresentam um desempenho computacional satisfatório, sendo viável para a aplicação em sistemas reais de energia elétrica.

8.2 SUGESTÕES PARA TRABALHOS FUTUROS

As seguintes sugestões de trabalhos futuros visam expandir e aprofundar o conhecimento adquirido nesta dissertação, abrindo novas possibilidades de pesquisa e aprimoramento na aplicação da técnica de particionamento da rede para o processamento de erros grosseiros em estimadores híbridos de fusão de estimativas.

- Extensão para simulações com múltiplos erros grosseiros: desenvolver estratégias e realizar simulações considerando a ocorrência de múltiplos erros grosseiros na rede elétrica. Isso permitirá avaliar o impacto positivo do particionamento da rede na detecção e identificação quando múltiplos erros grosseiros estão simultaneamente presentes no conjunto de medidas a serem processadas por estimadores híbridos de fusão de estimativas;
- Investigação da eficácia do particionamento em redes com diferentes topologias. Realizar simulações em redes elétricas com diferentes topologias, como redes

radiais, malhadas ou mistas, para avaliar a eficácia do particionamento em cada tipo de topologia. Isso permitiria avaliar melhor os desafios e benefícios do particionamento em diferentes configurações de rede;

- Implementação de técnicas de inteligência artificial para a detecção de erros. Explorar o uso de técnicas de aprendizado de máquina, como redes neurais artificiais ou algoritmos de aprendizado supervisionado, para melhorar a detecção e identificação de erros grosseiros. Isso envolveria a criação de modelos de detecção treinados com dados de simulações e a avaliação do desempenho desses modelos em comparação com abordagens convencionais;
- Avaliação do desempenho em condições de operação dinâmica. Simulações em que consideram-se condições de operação dinâmica, como variações rápidas de carga ou eventos de perturbação, para avaliar como o particionamento da rede influencia a detecção e identificação de erros em situações não estacionárias. Isso permitiria entender o comportamento do particionamento em cenários mais desafiadores e dinâmicos.

REFERÊNCIAS

- ABUR, Ali; EXPOSITO, Antonio Gomez. **Power system state estimation: theory and implementation**. [S.l.]: CRC press, 2004.
- ALBUQUERQUE, André Nascimento Cavalcanti de. **Estratégias em dois estágios para incorporar medidas fasoriais sincronizadas na estimação de estados em sistemas de potência**. 2011. Programa de Pós-Graduação em Engenharia Elétrica – Universidade Federal de Santa Catarina, Florianópolis/SC.
- AMARAL, Silas do. Métodos para processamento de erros grosseiros múltiplos em estimadores do estado sequenciais-ortogonais, 1987.
- AMARE, Kunal; CENTENO, Virgilio A; PAL, Anamitra. Unified PMU placement algorithm for power systems. *In: IEEE. 2015 North American power symposium (NAPS)*. [S.l.: s.n.], 2015. P. 1–6.
- ASCARI, Larah Brüning *et al.* Fusão de estimativas resiliente a erros grosseiros baseada no critério de máxima correntropia com aplicação na estimação de estados híbrida em sistemas elétricos de potência, 2022.
- BAR-SHALOM, Yaakov; CAMPO, Leon. The effect of the common process noise on the two-sensor fused-track covariance. **IEEE Transactions on aerospace and electronic systems**, IEEE, n. 6, p. 803–805, 1986.
- BEZ, Daniel; SIMOES-COSTA, A. Enhanced probabilistic modeling of phasor measurement errors in hybrid SCADA-PMU state estimation. *In: PROCEEDINGS of PMAPS*. [S.l.: s.n.], 2012. v. 10, p. 1116.
- BEZ, Daniel Martins; SIMÕES-COSTA, Antonio; ASCARI, Larah Brüning; JUNIOR, Edson Zanlorensi. A Block Version of Orthogonal Rotations for Improving the Accuracy of Hybrid State Estimators. **IEEE Transactions on Power Systems**, IEEE, v. 35, n. 6, p. 4432–4444, 2020.
- BI, TS; QIN, XH; YANG, QX. A novel hybrid state estimator for including synchronized phasor measurements. **Electric Power Systems Research**, Elsevier, v. 78, n. 8, p. 1343–1352, 2008.

BRUNO, C; CANDIA, C; FRANCHI, L; GIANNUZZI, G; POZZI, M; ZAOTTINI, R; ZARAMELLA, M. Possibility of enhancing classical weighted least squares state estimation with linear PMU measurements. *In: IEEE. 2009 IEEE Bucharest PowerTech. [S.l.: s.n.], 2009. P. 1–6.*

CARO, Eduardo; CONEJO, Antonio J; MINGUEZ, Roberto. Power system state estimation considering measurement dependencies. **IEEE Transactions on Power Systems**, IEEE, v. 24, n. 4, p. 1875–1885, 2009.

CHEN, Jian; ABUR, Ali. Placement of PMUs to enable bad data detection in state estimation. **IEEE Transactions on Power Systems**, IEEE, v. 21, n. 4, p. 1608–1615, 2006.

DEO, Narsingh. **Graph theory with applications to engineering and computer science**. [S.l.]: Courier Dover Publications, 2017.

DO COUTTO FILHO, Milton Brown; SOUZA, Julio Cesar Stacchini de; GUIMARAENS, Marcio Andre Ribeiro. Enhanced bad data processing by phasor-aided state estimation. **IEEE Transactions on Power Systems**, IEEE, v. 29, n. 5, p. 2200–2209, 2014.

DOPAZO, JF; KLITIN, OA; VANSLYCK, LS. State calculation of power systems from line flow measurements, part II. **IEEE Transactions on Power Apparatus and Systems**, IEEE, n. 1, p. 145–151, 1972.

DUFF, Iain S; SCOTT, Jennifer A. Stabilized bordered block diagonal forms for parallel sparse solvers. **Parallel Computing**, Elsevier, v. 31, n. 3-4, p. 275–289, 2005.

GENTLEMAN, W Morven. Least squares computations by Givens transformations without square roots. **IMA Journal of Applied Mathematics**, Oxford University Press, v. 12, n. 3, p. 329–336, 1973.

GÖL, Murat; ABUR, Ali. A modified chi-squares test for improved bad data detection. *In: IEEE. 2015 IEEE Eindhoven PowerTech. [S.l.: s.n.], 2015. P. 1–5.*

HANDSCHIN, Edmund; SCHWEPPE, Fred C; KOHLAS, Jurg; FIECHTER, AAFA. Bad data analysis for power system state estimation. **IEEE Transactions on Power Apparatus and Systems**, IEEE, v. 94, n. 2, p. 329–337, 1975.

IEEE. IEEE Standard for Synchrophasor Measurements for Power Systems. **IEEE Std C37.118.1-2011 (Revision of IEEE Std C37.118-2005)**, p. 1–61, 2011.

KEMA. **Metrics for Determining the Impact of Phasor Measurements on Power System State Estimation**. [S.l.]: Eastern Interconnection Phasor Project, 2006.

KEZUNOVIC, Mladen. Monitoring of power system topology in real-time. *In*: IEEE. PROCEEDINGS of the 39th Annual Hawaii International Conference on System Sciences (HICSS'06). [S.l.: s.n.], 2006. v. 10, 244b–244b.

KORRES, GN; CONTAXIS, GC. A reduced model for bad data processing in state estimation. **IEEE Transactions on Power Systems**, IEEE, v. 6, n. 2, p. 550–557, 1991.

LERRO, Don; BAR-SHALOM, Yaakov. Tracking with debiased consistent converted measurements versus EKF. **IEEE transactions on aerospace and electronic systems**, IEEE, v. 29, n. 3, p. 1015–1022, 1993.

LI, X Rong; ZHU, Yunmin; WANG, Jie; HAN, Chongzhao. Optimal linear estimation fusion. I. Unified fusion rules. **IEEE Transactions on Information Theory**, IEEE, v. 49, n. 9, p. 2192–2208, 2003.

MITCHELL, Harvey B. **Multi-sensor data fusion: an introduction**. [S.l.]: Springer Science & Business Media, 2007.

MONTICELLI. **State estimation in electric power systems: a generalized approach**. [S.l.]: Springer Science & Business Media, 1999.

MONTICELLI, A; GARCIA, A. Reliable bad data processing for real-time state estimation. **IEEE transactions on power apparatus and systems**, IEEE, n. 5, p. 1126–1139, 1983.

PARAMO, Gian; BRETAS, Arturo; MEYN, Sean. Research Trends and Applications of PMUs. **Energies**, MDPI, v. 15, n. 15, p. 5329, 2022.

PHADKE, AG; THORP, JS; NUQUI, RF; ZHOU, M. Recent developments in state estimation with phasor measurements. *In*: IEEE. 2009 IEEE/PES Power Systems Conference and Exposition. [S.l.: s.n.], 2009. P. 1–7.

PHADKE, Arun G. Synchronized phasor measurements-a historical overview. *In: IEEE. IEEE/PES transmission and distribution conference and exhibition. [S.l.: s.n.], 2002. v. 1, p. 476–479.*

PHADKE, Arun G; THORP, James S. **Synchronized phasor measurements and their applications.** [S.l.]: Springer, 2008. v. 1.

QUINTANA, VH; SIMOES-COSTA, A; MIER, M. Bad data detection and identification techniques using estimation orthogonal methods. **IEEE Transactions on Power Apparatus and Systems**, IEEE, n. 9, p. 3356–3364, 1982.

SCHWEPPE, Fred C; WILDES, J. Power system static-state estimation, Part I: Exact model. **IEEE Transactions on Power Apparatus and systems**, IEEE, n. 1, p. 120–125, 1970.

SHI, Jianbo; MALIK, Jitendra. Normalized cuts and image segmentation. **IEEE Transactions on pattern analysis and machine intelligence**, Ieee, v. 22, n. 8, p. 888–905, 2000.

SIMOES-COSTA, A; QUINTANA, VH. An orthogonal row processing algorithm for power system sequential state estimation. **IEEE Transactions on Power Apparatus and Systems**, IEEE, n. 8, p. 3791–3800, 1981.

SIMOES-COSTA, A; SALGADO, R. Bad data recovery for orthogonal row processing state estimators. *In: PROC. of the CIGRE-IFAC Symp. on Control Appl. for Power System Security, Florence. [S.l.: s.n.], 1983. P. 101–01.*

SIMÕES-COSTA; ALBUQUERQUE. A two-stage orthogonal estimator to incorporate phasor measurements into power system real-time modeling. *In: SN. POWER Systems Computation Conference (PSCC). [S.l.: s.n.], 2011.*

SIMÕES-COSTA; ALBUQUERQUE; BEZ. An estimation fusion method for including phasor measurements into power system real-time modeling. **IEEE Transactions on Power Systems**, IEEE, v. 28, n. 2, p. 1910–1920, 2013.

SIMÕES-COSTA; MEYER; DECKER. Análise dos benefícios de medições fasoriais sincronizadas quanto ao desempenho da estimação de estados em sistemas de potência. *In: SN. XVII Brazilian Conference on Automatic Control. [S.l.: s.n.], 2008.*

UNIVERSITY OF WASHINGTON. **Power Systems Test Case Archive**. [S.l.: s.n.], 1993. Disponível em <https://labs.ece.uw.edu/pstca/>. Acesso em 16 de março de 2022. [S.l.: s.n.]

ZANLORENSI; ASCARI; SIMÕES-COSTA. Processamento de Erros Grosseiros para Estimadores de Estados Híbridos Ortogonais em Blocos e Medidas Fasoriais em Coordenadas Retangulares. **Anais da Sociedade Brasileira de Automática**, v. 2, n. 1, 2020.

ZANLORENSI, Edson. Processamento de erros grosseiros para estimadores de estados híbridos baseados em rotações de Givens em blocos, 2021.

ZANLORENSI, Edson; SIMÕES-COSTA, Antonio; ASCARI, Larah Brüning. Enhanced Bad Data Processing for Hybrid Block-Orthogonal State Estimators. *In: IEEE. 2021 IEEE Madrid PowerTech*. [S.l.: s.n.], 2021. P. 1–6.

ZHAO, Hongga. A new state estimation model of utilizing PMU measurements. *In: IEEE. 2006 International Conference on Power System Technology*. [S.l.: s.n.], 2006. P. 1–5.

ZHOU, Ming; CENTENO, Virgilio A; THORP, James S; PHADKE, Arun G. An alternative for including phasor measurements in state estimators. **IEEE transactions on power systems**, IEEE, v. 21, n. 4, p. 1930–1937, 2006.

ZHU, YM; LI, X Rong. Best linear unbiased estimation fusion. *In: PROCEEDINGS of the second international information fusion conference*. [S.l.: s.n.], 1999. v. 2, p. 1054–1061.

ZHU, Yunmin. **Multisensor decision and estimation fusion**. [S.l.]: Springer Science & Business Media, 2012. v. 14.

ZIVANOVIC, R; CAIRNS, C. Implementation of PMU technology in state estimation: an overview. *In: IEEE. PROCEEDINGS of IEEE. AFRICON'96*. [S.l.: s.n.], 1996. v. 2, p. 1006–1011.