



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

Victor Silva de Freitas

**Estimação Robusta de Estados em Sistemas Elétricos de Potência Baseada em  
Algoritmo Ortogonal e Modelos de Máxima Correntropia**

Florianópolis  
2020

Victor Silva de Freitas

**Estimação Robusta de Estados em Sistemas Elétricos de Potência Baseada em  
Algoritmo Ortogonal e Modelos de Máxima Correntropia**

Tese submetida ao Programa de Pós-Graduação  
em Engenharia Elétrica da Universidade Federal de  
Santa Catarina para a obtenção do título de doutor  
em Engenharia Elétrica.  
Orientador: Prof. Antonio José Alves Simões Costa,  
Ph.D.

Florianópolis  
2020

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

Freitas, Victor Silva de  
Estimação Robusta de Estados em Sistemas Elétricos de  
Potência Baseada em Algoritmo Ortogonal e Modelos de  
Máxima Correntropia / Victor Silva de Freitas ;  
orientador, Antonio José Alves Simões Costa, 2020.  
152 p.

Tese (doutorado) - Universidade Federal de Santa  
Catarina, Centro Tecnológico, Programa de Pós-Graduação em  
Engenharia Elétrica, Florianópolis, 2020.

Inclui referências.

1. Engenharia Elétrica. 2. Estimação de Estados em  
Sistemas de Potência. 3. Estimação Robusta. 4. Máxima  
Correntropia. 5. Algoritmo Ortogonal. I. Simões Costa,  
Antonio José Alves. II. Universidade Federal de Santa  
Catarina. Programa de Pós-Graduação em Engenharia Elétrica.  
III. Título.

Victor Silva de Freitas

**Estimação Robusta de Estados em Sistemas Elétricos de Potência Baseada em Algoritmo Ortogonal e Modelos de Máxima Correntropia**

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

Prof. Antonio José Alves Simões Costa, Ph.D.  
Universidade Federal de Santa Catarina (UFSC)

Prof. Vladimiro Henrique Barrosa Pinto de Miranda, Ph.D.  
Faculdade de Engenharia da Universidade do Porto (FEUP)

Prof. João Bosco Augusto London Jr., Dr.  
Escola de Engenharia de São Carlos - Universidade de São Paulo (USP)

Profa. Katia Campos de Almeida, Ph.D.  
Universidade Federal de Santa Catarina (UFSC)

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

---

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

---

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

Florianópolis, 2020.

À avó Luiza Gadelha (*in memoriam*).

## **AGRADECIMENTOS**

Agradeço aos meus pais Raimundo Clarivaldo e Lindalva pelo amor, presença, dedicação e empenho incondicional para proporcionar a melhor educação aos seus filhos. À minha madrinha Iraneide, minha segunda mãe, por sempre estar ao meu lado. Aos demais membros da minha família por terem me apoiado nesta jornada.

Agradeço ao meu orientador, professor Antonio Simões Costa, pela amizade, confiança, dedicação e toda a sabedoria empregados para o desenvolvimento deste trabalho e no meu amadurecimento profissional e acadêmico.

Ao professor Vladimiro Miranda, pelas oportunidades concedidas e pelos seus conhecimentos que encorajaram este trabalho, que foram fundamentais para a sua construção.

À Dayse Pastana, pelo amor, carinho, compreensão e apoio em todos momentos desta caminhada.

Aos professores do Grupo de Sistema de Potência, pelos conhecimentos transmitidos durante o curso e por toda disposição aos alunos.

Ao Instituto de Engenharia de Sistemas e Computadores, Tecnologia e Ciência (INESC TEC), no Porto, em especial ao CPES, pela acolhida, ensinamentos, pelo espaço e confiança para demonstrar o meu trabalho.

Aos colegas do Labspot, pela boa convivência e companheirismo.

Aos grandes irmãos que Florianópolis me proporcionou: Nadja, Elio Jr. e Cláudio Claudino. Certamente já somos uma família depois de tantos anos de convivência.

Aos amigos inesquecíveis do “além-mar”: Clarissa, Igor, João, Manoela, Shabnam, e tantos outros que tornaram a vivência em Portugal ainda mais doce.

Agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro durante a pesquisa e à Fundação para a Ciência e a Tecnologia (FCT) de Portugal pelo fomento no projeto de pesquisa no INESC TEC.

E por fim, agradeço a todos aqueles que de alguma forma me apoiaram e me incentivaram para o desenvolvimento e conclusão desse projeto.

*“Pessoas se tornaram educáveis na medida em que se reconheceram inacabadas. Não foi a educação que fez as pessoas educáveis, mas a consciência de sua inconclusão é que gerou sua educabilidade. É também na inconclusão de que nos tornamos conscientes e que nos insere no movimento permanente de procura que se alicerça a esperança.”*  
*(Paulo Freire)*

## RESUMO

A solução clássica da Estimação de Estados em Sistema de Potência (EESP) baseia-se no método dos Mínimos Quadrados Ponderados (MQP), que retorna estimativas próximas ao ponto ótimo do problema na hipótese de que as medidas a serem processadas pelo estimador estão isentas de erros grosseiros e sob a hipótese que os erros associados às medidas sejam gaussianos. Entretanto, a presença de qualquer medida espúria irá contaminar de forma severa os resultados da estimação de estados. Desta forma, é crucial que os estimadores clássicos sejam dotados da capacidade de processar medidas portadoras de erros grosseiros. A possível detecção de erros grosseiros deflagra a execução de um conjunto de rotinas de identificação e recuperação/eliminação de medidas, implicando em que todo o processo seja refeito para se obter estimativas isentas da influência dos erros. No intuito de aprimorar a eficiência global do procedimento descrito, este trabalho propõe a adoção de um algoritmo ortogonal para a estimação robusta de estados formulada com base no Critério de Máxima Correntropia (MCC), como parte do contexto da análise em tempo real de sistemas elétricos de potência. Este método é fundamentado na aplicação das propriedades inerentes à Teoria da Informação, e em particular no conceito de Correntropia como novo critério para a estimação de estados. Este conceito empresta propriedades de robustez e de resiliência resultantes da aplicação de janelas de observação que são ajustadas iterativamente, de modo a expurgar automaticamente os erros grosseiros presentes nas medidas processadas pelo estimador de estados. A solução do problema de estimação de estados MCC pode ser obtida através de uma equação matricial semelhante à equação normal, e que deve incluir uma estratégia de reponderação de medidas no curso da estimação a fim de aplicar as propriedades da Correntropia. Entretanto, este procedimento tende a aumentar riscos de instabilidade numérica no processo de solução devido à grande diferença entre os pesos relacionados às medidas. A proposta desta tese de doutorado é a utilização de um método de solução numérica do problema de estimação de estados MCC mediante rotações ortogonais rápidas de Givens, o que permite associar robustez numérica à resiliência face à presença de erros grosseiros da função de correntropia. Adicionalmente, a aplicação do método ortogonal para resolver o problema de estimação de estados facilita a remoção de erros grosseiros e de seus efeitos assim que são identificados pelo algoritmo do estimador, o que evita a necessidade de pós-processamento para o tratamento de medidas espúrias.

Outra contribuição deste trabalho é a proposição de um estimador híbrido de estados baseado no algoritmo MCC, capaz de processar medidas convencionais e fasoriais sincronizadas. A metodologia consiste em dois estágios de processamento: um estimador de estados MQP convencional, que processa medidas do sistema SCADA, cujo vetor de estimativas é tratado como informação *a priori* por um segundo módulo de estimação, sendo este baseado no critério MCC. Este segundo estimador processa medidas fasoriais conjuntamente com as informações *a priori*, e sua concepção com base no critério MCC o habilita a rejeitar medidas fasoriais e também informações *a priori* inconsistentes com os demais dados disponíveis para processamento. Isto garante um procedimento unificado para a depuração dos dados na estimação híbrida de estados e portanto a produção de estimativas confiáveis a partir de dois conjuntos diferentes de medidas. Adicionalmente, o método proposto permite a identificação das



medidas convencionais que não tenham sido devidamente eliminadas no primeiro estágio de estimação. A verificação e a validação das metodologias propostas nesta tese são realizadas a partir de um grande número de estudos de caso utilizando quatro sistemas-teste do IEEE.

**Palavras-chave:** Modelagem em Tempo Real de Sistemas de Potência. Estimação Robusta de Estados em Sistemas de Potência. Estimação Híbrida de Estados em Sistemas de Potência. Critério de Máxima Correntropia. Algoritmos Ortogonais.

## ABSTRACT

The classic solution for Power System State Estimation is based on the Weighted Least Squares (WLS) method, which provides estimates close to the optimum of the problem as long as the measurements processed by the estimator are free of gross errors and under the hypothesis that the measurement errors are Gaussian distributed. However, the presence of any bad data will severely contaminate the state estimation results. As a consequence of the bad data processing stage, the state estimation process must be redone to obtain error-free estimates. To improve the overall efficiency of that procedure, this thesis proposes an orthogonal robust state estimation algorithm based on the Maximum Correntropy Criterion (MCC) applied to power system real-time modeling. The proposed method takes advantage of intrinsic characteristics of Information Theory principles in order to reject outliers; among them, the Correntropy concept plays a central role. This criterion provides robustness and resilience properties that are due to the application of iteratively adjusted observation windows in order to automatically suppress gross errors processed by the state estimator. The implementation of the MCC algorithm necessarily implies that measurement weights change as a function of iteratively adjusted observation window widths. Since widely distinct measurement weights are a well known source of numerical ill-conditioning, the proposed orthogonal implementation is beneficial to impart numerical robustness to the MCC solution. Furthermore, the row-processing nature of the proposed solver greatly facilitates bad data removal as soon as outliers are identified by the MCC algorithm. Another desirable feature of the orthogonal MCC estimator is that it avoids the need of post-processing stages for bad data treatment.

Another issue addressed in this thesis is the proposition of an MCC-based hybrid state estimator capable to process conventional and synchronous phasor measurements. It consists of two estimation stages: the first one is a conventional SCADA-based state estimator, whereas the second stage treats the resulting estimates as *a priori* state information in order to improve their quality by cumulatively processing available phasor measurements. Robustness is enforced through the use of a MCC-based state estimation algorithm in the second stage. This allows the automatic rejection of outliers possibly present in both PMU measurements and state *a priori* information produced by contaminated SCADA measurements. Taking advantage of the resulting error-free final estimates, a methodology for identifying the gross SCADA measurements that contaminate the *a priori* state information is also proposed. The approach relies on the state *a priori* data rejected by the MCC-based state estimator, which enables the selection of suspect SCADA measurements. Bad data identification is then accomplished by comparing error-free MCC state estimates and conventional measurement residuals. The performance of the proposed schemes is assessed through exhaustive case studies conducted on different IEEE test systems.

**Keywords:** Real-Time Modeling Power System State Estimation. Power System Robust State Estimation. Power System Hybrid State Estimation. Maximum Correntropy Criterion. Orthogonal Algorithms.

## LISTA DE FIGURAS

Figura 1.1 – Estudos que contribuem para a estimação robusta de estados em SEP	21
Figura 3.1 – Estimação da fdp de um conjunto de dados para um <i>kernel</i> gaussiano de largura $\sigma = 0,1$ .	42
Figura 3.2 – Estimação da fdp de um conjunto de dados para um <i>kernel</i> gaussiano de largura $\sigma = 0,05$ .	42
Figura 3.3 – Visualização tridimensional da correntropia	44
Figura 3.4 – Visualização tridimensional da correntropia em superfície	45
Figura 3.5 – Representação da Função $CIM(X,0)$	47
Figura 4.1 – Sistema-teste de 3 barras	64
Figura 4.2 – Resíduos das medidas para o método Mínimos Quadrados Ponderados (MQP) e Critério da Máxima Correntropia (MCC)	67
Figura 4.3 – Evolução da Função Densidade de Probabilidade (fdp) dos erros	68
Figura 4.4 – Erro absoluto do estados com diferentes larguras do <i>kernel</i> Gaussiano	69
Figura 5.1 – Arquitetura para o Estimador MCC/APSI	80
Figura 6.1 – Sistema-teste do IEEE de 14 barras e plano de medição.	96
Figura 6.2 – Pesos das medidas nas interações G3M	98
Figura 6.3 – Erros ponderados para erros grosseiros interativos	100
Figura 6.4 – Valores de tempo médio de processamento para os estimadores	106
Figura 6.5 – Erros absolutos - <i>Caso base, condição A</i>	109
Figura 6.6 – Erros absolutos - <i>EG-SCADA, condição A</i>	111
Figura 6.7 – Pesos de ângulos para PMUs e APSI (caso <i>EG-SCADA - Condição A</i> )	111
Figura 6.8 – Pesos de magnitudes de tensão para PMUs e APSI (caso <i>EG-SCADA - Condição A</i> )	112
Figura 6.9 – Erros absolutos - <i>Caso base, condição B</i>	113
Figura 6.10 – Erros absolutos - <i>EG-SCADA, condição B</i>	114
Figura 6.11 – Pesos de ângulos para PMUs e APSI (caso <i>EG-SCADA - Condição B</i> )	115
Figura 6.12 – Pesos de magnitudes de tensão para PMUs e APSI (caso <i>EG-SCADA - Condição B</i> )	115
Figura 6.13 – Pesos de ângulos para PMUs e APSI (caso <i>EG-SCADA&amp;PMU - Condição A</i> )	116
Figura 6.14 – Pesos de magnitudes de tensão para PMUs e APSI (caso <i>EG-SCADA&amp;PMU - Condição B</i> )	117

## LISTA DE TABELAS

Tabela 4.1 – Medidas estimadas e resíduos obtidos pelos Estimadores MQP e MCC+G3M . . . . .	65
Tabela 4.2 – Estados estimados obtidos através dos Estimadores MQP e MCC+G3M	65
Tabela 4.3 – Medidas estimadas e resíduos obtidos pelos Estimadores MQP e MCC+G3M . . . . .	71
Tabela 4.4 – Estados estimados ao final de cada iteração do Estimador MCC+G3M	71
Tabela 4.5 – Valores da norma infinita do vetor de incrementos dos estados ao longo das interações das rotações rápidas de Givens . . . . .	72
Tabela 4.6 – Valores das Janelas de Parzen, resíduos de cada medida e valor de $\hat{b}_i$ no processo iterativo . . . . .	72
Tabela 4.7 – Número de condicionamento para $\rho = 1$ . . . . .	75
Tabela 4.8 – Número de condicionamento para $\rho = 3, 12$ . . . . .	76
Tabela 4.9 – Número de condicionamento com processamento de medida com erro grosseiro . . . . .	76
Tabela 6.1 – Número de medidas para cada sistema-teste do IEEE. . . . .	95
Tabela 6.2 – Resultados da estimação de estados para o sistema-teste do IEEE de 14 barras. . . . .	97
Tabela 6.3 – Resultados específico para dois estimadores . . . . .	102
Tabela 6.4 – Eficiência dos estimadores com erros grosseiros . . . . .	103
Tabela 6.5 – Desempenho em estudo de caso com falha . . . . .	105
Tabela 6.6 – Valores médios para número de iterações . . . . .	107
Tabela 6.7 – Planos de Medição do sistema de 14 barras do IEEE . . . . .	108
Tabela 6.8 – IEEE 14-bus performance indices . . . . .	118
Tabela 6.9 – Identificação de erros grosseiros em medidas SCADA através dos resultados do estimador MCC/APSI . . . . .	120
Tabela 6.10 – Número de medidas SCADA e PMU para os sistemas-teste do IEEE de 57 e 118 barras . . . . .	121
Tabela 6.11 – Índices de Desempenho para os sistemas-teste do IEEE de 57 e 118 barras . . . . .	123
Tabela 6.12 – Eficiência do processamento de erros grosseiros para o estimador híbrido MCC/APSI de estados e rastreamento de medidas espúrias no sistema SCADA . . . . .	124
Tabela 6.13 – Tempos médios de processamento em segundos para os sistemas-teste do IEEE de 57 e 118 barras . . . . .	125
Tabela 6.14 – Número de medidas SCADA e PMU para os sistemas-teste do IEEE de 14, 30, 57 e 118 barras . . . . .	126

Tabela 6.15–Estados estimados obtidos através dos estimadores MQP-Híbrido e MCC/APSI para o Sistema-teste de 14 barras . . . . .	127
Tabela 6.16–Estados estimados obtidos através dos estimadores MQP-Híbrido e MCC/APSI para o Sistema-teste de 30 barras. . . . .	127
Tabela 6.17–Estados estimados obtidos através dos estimadores MQP-Híbrido e MCC/APSI para o Sistema-teste de 57 barras. . . . .	128
Tabela 6.18–Estados estimados obtidos através dos estimadores MQP-Híbrido e MCC/APSI para o Sistema-teste de 118 barras. . . . .	128
Tabela 6.19–Resultados das métricas de média e variância para os estimadores MQP-Híbrido e MCC/APSI. . . . .	130
Tabela A.1–Dados das Barras do Sistema-Teste de 3 Barras . . . . .	152
Tabela A.2–Dados da Linhas do Sistema-Teste de 3 Barras . . . . .	152

## LISTA DE ABREVIATURAS E SIGLAS

APSI	Informações <i>A Priori</i> de Estados
CIM	Métrica Induzida por Correntropia
EE	Estimador de Estados
EESP	Estimação de Estados em Sistemas de Potência
EQM	Erro Quadrático Médio
fdp	Função Densidade de Probabilidade
KKT	Karush-Kuhn-Tucker
LNRT	Teste do Máximo Resíduo Normalizado
MCC	Critério da Máxima Correntropia
MCC+G3M	Estimador Ortogonal baseado nas Rotações Rápidas de Givens
MCC/APSI	MCC de Estados com capacidade de processar informações <i>a priori</i>
MQP	Mínimos Quadrados Ponderados
PMU	Phasor Measurement Units
SCADA	<i>Supervisory Control and Data Aquisition</i>
SEP	Sistemas Elétricos de Potência
SMFS	Sistema de Medição Fasorial Sincronizada
TI	Teoria da Informação

## LISTA DE SÍMBOLOS

$\mathcal{S}$	Conjunto de índices de medidas suspeitas
$N$	Número Total de Barramentos do sistema
$\mathbf{z}$	Vetor de Medidas
$\mathbf{h}(\mathbf{x})$	Vetor de Funções Não-Lineares das Medidas
$\boldsymbol{\varepsilon}$	Vetor de Erros Aleatórios de Medição
$m$	Número de Medidas
$\mathbf{x}$	Vetor de Estados Verdadeiros
$n$	Número de Estados do Sistema
$\sigma_m$	Desvio Padrão dos Medidores
$E\{\cdot\}$	Operador Expectância
$\mathbf{R}$	Matriz de Covariância das Medias
$\rho$	Redundância Global do Modelo de Medição
$\mathbf{r}$	Vetor dos Resíduos das Medidas
$\hat{\mathbf{x}}$	Vetor de Estados Estimados
$J(\hat{\mathbf{x}})$	Função-Objetivo
$\sum_{i=1}^m$	Somatório de $i$ até $m$
$\mathbf{H}$	Matriz Jacobiana das Medidas do Sistema
$k$	Iteração Corrente
$\Delta$	Operador Incremento
$\mathbf{G}$	Matriz Ganho
$\nabla$	Operador Gradiente
$Cond(\cdot)$	Operador Condicionamento Numérico
$\chi^2$	Qui-Quadrado
$\alpha$	Probabilidade de Falso Alarme
$\ell$	Número de Graus de Liberdade
$K$	Percentil Limiar
$\boldsymbol{\Omega}$	Matriz de Covariância dos Resíduos
$\boldsymbol{\Sigma}$	Matriz de Covariância dos Erros de Estimção
$r^N$	Resíduo Normalizado
$\hat{b}$	Estimativa do erro grosseiro de uma medida em termos de desvios-padrão
$\hat{\beta}$	Estimativa para amplitude do erro grosseiro de uma medida
$\lambda_{\hat{b}}$	Limiar para teste de hipóteses
$p(x)$	Probabilidade do Elemento $x$
$H_2$	Entropia Quadrática de Rényi
$\sigma^2$	Variância do <i>kernel</i> Gaussiano
$G_\sigma$	<i>Kernel</i> Gaussiano
$\sigma$	Largura do <i>kernel</i> Gaussiano
$\mathcal{V}$	Função Correntropia

$p_{X,Y}$	Função Densidade de Probabilidade Conjunta
$\delta$	Delta de Dirac
$\epsilon$	Erro de uma Variável Aleatória
$D$	Matriz Diagonal de Magnitude de Pesos
$G_{MCC}$	Matriz Ganho Modificada
$R_W$	Matriz Diagonal de Resíduos Ponderados
$\Delta x$	Vetor de incrementos sobre as variáveis de estado
$W$	Matriz de Pesos com base no critério de máxima correntropia
$\Delta \tilde{z}$	Vetor de Incrementos Resíduos Ponderados
$\eta$	Limiar de número real e pequeno
$Q$	Matriz Ortogonal
$\bar{U}$	Matriz Triangular Superior
$\bar{c}$	Vetor resultante das rotações de Givens
$T$	Matriz Diagonal de Fatores de Ponderação
$U$	Matriz Triangular Superior Unitária
$c$	Vetor decomposto resultante das rotações de Givens
$\tau$	Parâmetro de Rotação Elementar
$v$	Parâmetro de Rotação Elementar
$\lambda_{\mathcal{S}}$	Número de desvios-padrão das medidas
$\bar{x}$	Vetor de Informação <i>A Priori</i> de Estados Estimados
$\bar{\sigma}$	Largura da Janela de Parzen para Informações <i>A Priori</i>
$V$	Matriz Diagonal de Fatores de Ponderação para Informações <i>A Priori</i> de Estado
$\Delta \tilde{x}$	Vetor de Incrementos de Estados Ponderados
$\Delta \bar{x}$	Vetor de Incrementos entre Estados e Informações de Estado <i>A Priori</i>
$\hat{z}_{SS}$	Vetor de medidas estimadas calculadas com base nas estimativas do Estimador SCADA
$\hat{z}_{SMCC}$	Vetor de medidas estimadas calculadas com base nas estimativas do Estimador MCC/APSI
$r_{SS}$	Vetor de resíduos calculadas com base nas estimativas do Estimador SCADA
$r_{SMCC}$	Vetor de resíduos calculadas com base nas estimativas do Estimador MCC/APSI



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>19</b>
1.1	INTRODUÇÃO	19
1.2	REVISÃO BIBLIOGRÁFICA	20
1.2.1	Estimação de Estados baseada em Métodos Não-Quadráticos	21
1.2.2	Função de Correntropia Aplicada à Estimação de Estados	22
1.2.3	Processamento de Erros Grosseiros em Modelos Híbridos de Estimação	24
1.3	OBJETIVOS E CONTRIBUIÇÕES DA TESE	28
1.4	ORGANIZAÇÃO DA TESE	28
<b>2</b>	<b>ESTIMAÇÃO DE ESTADOS VIA MÉTODOS QUADRÁTICOS</b>	<b>30</b>
2.1	INTRODUÇÃO	30
2.2	MODELO DE MEDIÇÃO	30
2.3	CRITÉRIO DOS MÍNIMOS QUADRADOS PONDERADOS	32
2.4	SOLUÇÃO VIA MÉTODO DA EQUAÇÃO NORMAL	32
2.5	PROCESSAMENTO DE ERROS GROSSEIROS	34
2.6	CONCLUSÃO	37
<b>3</b>	<b>TEORIA DA INFORMAÇÃO APLICADA À ESTIMAÇÃO DE ESTADOS</b>	<b>39</b>
3.1	INTRODUÇÃO	39
3.2	TEORIA DA INFORMAÇÃO: ASPECTOS GERAIS	40
3.2.1	Entropia, Correntropia e Janelas de Parzen	40
3.3	ESTIMAÇÃO DE ESTADOS SOB CRITÉRIO DE MÁXIMA CORRENTROPIA	48
3.3.1	Formulação Matemática	48
3.4	CONCLUSÃO	51
<b>4</b>	<b>ALGORITMO ORTOGONAL E CRITÉRIO MCC NA ESTIMAÇÃO ROBUSTA DE ESTADOS</b>	<b>53</b>
4.1	INTRODUÇÃO	53
4.2	MÉTODO ORTOGONAL-SEQUENCIAL	54
4.3	EQUAÇÕES BÁSICAS DO MÉTODO ORTOGONAL DAS ROTAÇÕES DE GIVENS	54
4.3.1	Versão com Três Multiplicadores das Rotações de Givens	56
4.4	ROTAÇÕES ELEMENTARES EM FUNÇÃO DE CORRENTROPIA	56
4.5	PROCESSAMENTO DE ERROS GROSSEIROS ATRAVÉS DAS ROTAÇÕES DE GIVENS	58
4.6	ESTRATÉGIA DE AJUSTE DAS JANELAS DE PARZEN	59
4.7	ALGORITMO MCC	61
4.8	ESTUDO DE CASO ILUSTRATIVO	63

4.8.1	Propriedades da Maximização da Correntropia . . . . .	64
4.8.2	Desempenho Numérico e Processamento do Algoritmo MCC . . . . .	70
4.9	AVALIAÇÃO DOS MÉTODOS DE SOLUÇÃO DO ESTIMADOR MCC	73
4.9.1	Aspectos Qualitativos . . . . .	73
4.9.2	Aspectos Quantitativos . . . . .	74
4.10	CONCLUSÃO . . . . .	76
<b>5</b>	<b>ESTIMADOR HÍBRIDO MCC: PROCESSAMENTO DE MEDIDAS FASORIAIS SINCRONIZADAS . . . . .</b>	<b>78</b>
5.1	INTRODUÇÃO . . . . .	78
5.2	ESTRATÉGIA DE ESTIMAÇÃO EM DOIS ESTÁGIOS . . . . .	79
5.3	MODELO MCC DE INFORMAÇÕES DE ESTADOS <i>A PRIORI</i> . . . . .	82
5.3.1	Processamento de APSI por Algoritmo Ortogonal . . . . .	83
5.4	PROCESSAMENTO DE <i>OUTLIERS</i> VIA ESTIMADOR HÍBRIDO . . . . .	85
5.5	RASTREAMENTO DE ERROS GROSSEIROS EM MEDIDAS CONVENCIONAIS . . . . .	86
5.5.1	Símbolos e Nomenclatura Específica . . . . .	86
5.5.2	Filtragem de Informações <i>A Priori</i> de Estado . . . . .	87
5.5.3	Identificação de Erros Grosseiros em Medidas SCADA . . . . .	88
5.5.4	Observações . . . . .	89
5.6	CONCLUSÃO . . . . .	90
<b>6</b>	<b>RESULTADOS DE SIMULAÇÃO . . . . .</b>	<b>92</b>
6.1	INTRODUÇÃO . . . . .	92
6.2	AMBIENTE DE SIMULAÇÃO E CONSIDERAÇÕES COMPUTACIONAIS . . . . .	92
6.2.1	Índices de Desempenho do Estimador . . . . .	94
6.3	RESULTADOS PARA O ESTIMADOR ORTOGONAL MCC . . . . .	95
6.3.1	Resultados para o Sistema-teste do IEEE de 14 barras . . . . .	95
6.3.2	Resultados para o Sistema-teste do IEEE de 57 barras . . . . .	98
6.3.3	Avaliação da Resiliência a Erros Grosseiros e Desempenho Computacional . . . . .	102
6.4	RESULTADOS PARA ESTIMAÇÃO HÍBRIDA MCC/APSI DE ESTADOS	107
6.4.1	Resultados Ilustrativos para o Sistema-teste do IEEE de 14 Barras . . . . .	108
6.4.1.1	Experimentos sob a condição A de Observabilidade . . . . .	109
6.4.1.2	Experimentos sob a condição B de Observabilidade . . . . .	113
6.4.1.3	Métricas do estimador MCC/APSI para os ensaios do sistema-teste do IEEE de 14 barras . . . . .	117
6.4.1.4	Rastreamento de erros grosseiros . . . . .	118
6.4.2	Avaliação de desempenho com sistemas de médio porte . . . . .	121
6.4.3	Validação do Estimador MCC/APSI . . . . .	125

6.5	ANÁLISE GERAL DOS RESULTADOS . . . . .	131
6.6	CONCLUSÃO . . . . .	132
<b>7</b>	<b>CONCLUSÕES GERAIS . . . . .</b>	<b>134</b>
7.1	CONSIDERAÇÕES FINAIS . . . . .	134
7.2	SUGESTÕES PARA TRABALHOS FUTUROS . . . . .	136
	<b>REFERÊNCIAS . . . . .</b>	<b>139</b>
	<b>APÊNDICE A – SISTEMA-TESTE DE 3 BARRAS . . . . .</b>	<b>152</b>

# 1 INTRODUÇÃO

## 1.1 INTRODUÇÃO

A necessidade de estabelecer uma base confiável dos dados que retrate com fidelidade as condições de operação da rede elétrica, tornou a modelagem em tempo real uma ferramenta fundamental na moderna operação de Sistemas Elétricos de Potência (SEP). A Estimação de Estados em Sistemas de Potência (EESP) é um componente primordial utilizado nos Centros de Operação do Sistema e tem o objetivo de subsidiar os aplicativos que procuram garantir a segurança da operação do sistema contribuindo assim para cumprir as exigências de confiabilidade, qualidade e continuidade do suprimento da energia elétrica.

Existem vários fatores que influenciam nas características e no desempenho da estimação de estados, dentre os quais mencionam-se as inexatidões e erros grosseiros na aquisição/transmissão das telemidas realizadas na rede elétrica, que podem se tornar significativos e conseqüentemente afetar a análise de segurança em virtude dos erros associados.

O processamento da EESP é realizado a partir de medidas redundantes do sistema elétrico, coletadas através do Sistema de Supervisão e Aquisição de Dados (*Supervisory Control and Data Acquisition* (SCADA)), que fornece informações como as magnitudes de tensão e injeções de potência nas barras, fluxo de potência nas linhas de transmissão, entre outros dados. Estas medidas analógicas coletadas do SEP e fornecidas ao estimador estão sujeitas a erros grosseiros, isto é, existe a possibilidade da presença de medidas portadoras de erros de medição cujo grau de inexatidão é muito maior do que o admitido pelo modelo de medição. Para afirmar que as estimativas obtidas pelo Estimador de Estados (EE) são confiáveis, é imprescindível que o EE processe medidas isentas de tais erros, o que não é verdadeiramente possível antes de uma análise conjunta de todos os dados (ABUR; GOMEZ EXPOSITO, 2004).

Mais recentemente, a inclusão do Sistema de Medição Fasorial Sincronizada (SMFS) tem sido amplamente estudada e denuncia mudanças relevantes na supervisão e controle de sistemas elétricos de potência. Com a disseminação desta tecnologia espera-se que, ao longo dos próximos anos, as Unidades de Medição Fasorial (Phasor Measurement Units (PMU)) sejam amplamente instaladas em diversas partes dos sistemas elétricos e que, neste processo, as medidas fasoriais sejam incluídas no conjunto de dados disponíveis ao Operador do sistema elétrico. Contudo, tais medidas são também suscetíveis a erros de diversas naturezas, como tempo na sincronização e na propagação das informações das medidas, ataques cibernéticos, entre outros (HUG; GIAMPAPA, 2012; TAHA *et al.*, 2018).

Assim, o desempenho dos estimadores de estados baseados nos modelos tradicionais é afetado de forma severa pela presença de medidas espúrias. Por este motivo,

deve-se dotar os estimadores de técnicas capazes de detectar, identificar e eliminar medidas com erros grosseiros (MONTICELLI, 1999), normalmente implementadas como um estágio de pós-processamento. Entretanto, a desvantagem deste procedimento é que a estimação deve ser refeita de forma a obter estimativas sem a influência de tais erros.

A utilização de modelos não-quadráticos para a estimação de estados é um fator que pode contornar a necessidade de executar o EE múltiplas vezes para uma mesma varredura dos medidores. Isto se deve ao fato de que tais modelos proporcionam robustez face à ocorrência de erros grosseiros e portanto emprestam maior confiabilidade ao processo de estimação de estados.

Dentre as abordagens realizadas ao longo dos anos para o robustecimento dos estimadores de estados via critérios não-quadráticos, destacam-se as primeiras pesquisas, que têm por base a análise dos resíduos de estimação dentro do processo de estimação (MERRILL; SCHWEPPE, 1971; HANDSCHIN *et al.*, 1975). Menciona-se também a aplicação de teorias mais específicas, visando aumentar a robustez estatística (MILI *et al.*, 1996; PIRES; SIMÕES COSTA; MILI, 1999).

Nestas abordagens, outro arcabouço teórico é usado como base para a solução do problema da EESP, fornecendo um algoritmo dotado de propriedades de resiliência superiores às dos estimadores existentes. Neste trabalho, o termo *resiliência* deve ser entendido como a propriedade do algoritmo rejeitar automaticamente dados espúrios. Desta forma, um *algoritmo de estimação de estados resiliente* é capaz de fornecer estimativas de boa qualidade mesmo na presença de medidas portadoras de erros grosseiros. Em outras palavras, o algoritmo não requer um estágio de pós-processamento de erros grosseiros para produzir estimativas confiáveis.

Na busca por estes algoritmos, surge a aplicação das propriedades baseadas na Teoria da Informação (TI) para a definição de um novo critério para a estimação de estados (MIRANDA; SANTOS; PEREIRA, 2009; KRSTULOVIC; MIRANDA *et al.*, 2013), centrado no conceito de correntropia. A partir deste, é possível propor algoritmos de estimação de estados capazes de rejeitar os efeitos de erros grosseiros em medidas.

Neste sentido, esta tese de doutorado propõe a associação de estimadores de estados resilientes, fundamentados na Teoria da Informação, à aplicação de algoritmos numericamente robustos. Nesta proposta, utilizam-se propriedades e modelos que têm por base o critério da máxima correntropia para conceber estimadores de estados. A robustez numérica, por sua vez, é assegurada mediante implementação que faz uso de um algoritmo ortogonal baseado na versão rápida das Rotações de Givens.

## 1.2 REVISÃO BIBLIOGRÁFICA

Nesta seção é apresentada cronologicamente uma breve revisão bibliográfica das contribuições mais relevantes associadas aos tópicos principais abordados nesta

tese de doutorado. Estes relacionam-se à estimação de estados por métodos não-quadráticos e à teoria de informação como paradigma para a estimação de estados em sistemas de potência.

### 1.2.1 Estimação de Estados baseada em Métodos Não-Quadráticos

De modo obter estimativas confiáveis utilizando os métodos quadráticos convencionais, as fases de detecção e identificação de erros grosseiros são imprescindíveis. Consequentemente, vários estudos têm sido direcionados à solução do problema de identificação de medidas espúrias (MONTICELLI; GARCIA, 1983; MONTICELLI; WU; YEN, 1986; WU, 1990). Entretanto, com o objetivo de desvincular a estimação de estados da necessidade da etapa de processamento de erros grosseiros, foram também desenvolvidas técnicas baseadas em critérios não-quadráticos. Estes possibilitam a eliminação das medidas espúrias como parte do próprio processo de estimação.

As principais contribuições que fundamentam a proposta desta tese são apresentadas em (MERRILL; SCHWEPPE, 1971; HANDSCHIN *et al.*, 1975; MILI *et al.*, 1996; PIRES; SIMÕES COSTA; MILI, 1999; MIRANDA; SANTOS; PEREIRA, 2009; KRSTULOVIC; MIRANDA *et al.*, 2013) e sumarizadas na Figura 1.1. Estes estudos destacam-se pela aplicação de métodos não-quadráticos que viabilizam a estimação robusta de estados em sistemas de potência.

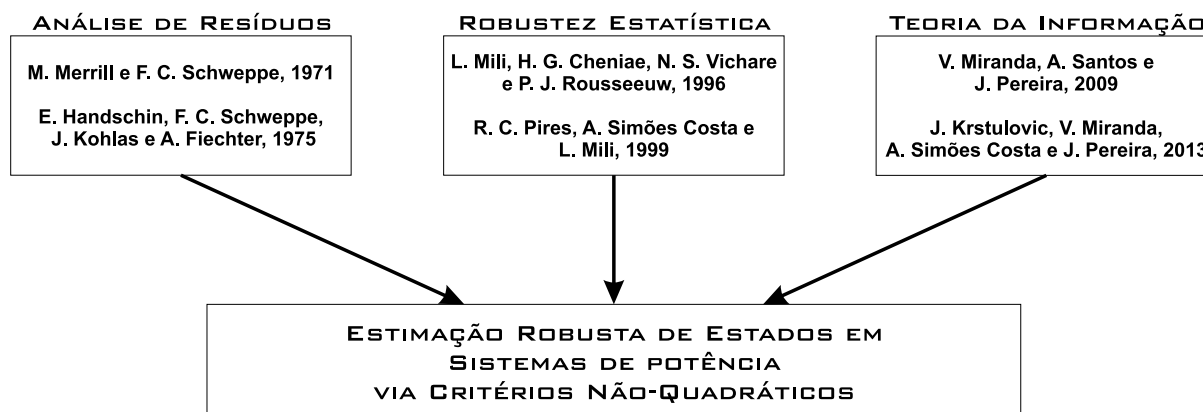


Figura 1.1 – Estudos que contribuem para a estimação robusta de estados em SEP

As primeiras contribuições, investigadas por Merrill e Schweppe (MERRILL; SCHWEPPE, 1971), surgem na década de 70, e propõem um estimador para supressão de erros grosseiros mediante a aplicação de um método não-quadrático. Este fundamenta-se em uma análise heurística dos resíduos em cada iteração, com o objetivo de controlar os efeitos dos erros grosseiros sobre as estimativas e contornar a necessidade de pós-processamento.

Posteriormente, Handschin e colaboradores (HANDSCHIN *et al.*, 1975) contribuem com esforços para a detecção e identificação de erros grosseiros em medidas, utilizando também critérios de estimação não-quadráticos e avaliando efeitos da iterati-

vidade dos erros grosseiros e redundância das medidas. Estes estimadores procuram detectar automaticamente as medidas cujos resíduos crescem rapidamente, de modo a suprimir a influência destas na estimação de estados. Entretanto, a falta de uma base teórica sólida prejudicou a aceitação ampla desta metodologia.

Na década de 90, a abordagem introduzida por Mili e colaboradores (MILI *et al.*, 1996) propõe estimadores estatisticamente robustos. Esta metodologia tem o objetivo adicional de identificar pontos de alavancamento, além de conceitos de estatística robusta capazes de eliminar dados discrepantes (*outliers*), os quais conduzem à classe de estimadores conhecidos como *M-estimators* (MILI *et al.*, 1996; BALDICK *et al.*, 1997). Já a abordagem realizada por Pires e colaboradores (PIRES; SIMÕES COSTA; MILI, 1999) aplica as vantagens dos estimadores não-quadráticos articulados com algoritmos numericamente robustos e de baixo custo computacional. Outras contribuições, como as relatadas em (ZHUANG; BALASUBRAMANIAN, 1985; SIMÕES COSTA; ROLIM; AITCHISON, 1991; FALCAO; COOKE; BRAMELLER, 1982; BALDICK *et al.*, 1997), também propõem a implementação de algoritmos baseados na supressão de erros grosseiros mediante critérios não-quadráticos e resolução dos algoritmos por métodos numericamente robustos. Entretanto, os métodos citados podem resultar em problemas de mínimos locais e de convergência.

Para contornar os problemas citados anteriormente, outras alternativas robustas de critérios não-quadráticos, agora baseados na Teoria da Informação, podem ser aplicados à EESP com base no conceito de correntropia, abordado no tópico seguinte.

### 1.2.2 Função de Correntropia Aplicada à Estimação de Estados

As primeiras abordagens da aplicação de recentes conceitos de TI à EESP são relatadas em estudos como em Miranda e colaboradores (MIRANDA; SANTOS; PEREIRA, 2009) e Krstulovic e colaboradores (KRSTULOVIC; MIRANDA *et al.*, 2013). Os algoritmos correspondentes, sejam eles aplicados ao processamento de sinais (PRINCIPE; DONGXIN, 1999; ERDOGMUS; PRINCIPE, 2001, 2002; LIU; POKHAREL; PRINCIPE, 2006; LIU; POKHAREL; PRINCIPE, Jose C., 2006; LIU, W.; POKHAREL; PRINCIPE, 2007; PRINCIPE, 2013) ou para solucionar problemas do sistemas elétricos de energia (MIRANDA; SANTOS; PEREIRA, 2009; MIRANDA, 2013, 2015), apresentam como principais vantagens a rejeição automática dos efeitos das medidas espúrias de modo que, mesmo na presença destas, têm a capacidade de fornecer estimativas confiáveis. Do mesmo modo que outras abordagens com base em métodos não-quadráticos, como os trabalhos citados na seção 1.2.1, estas estão sujeitas a extremos locais, porém esta dificuldade pode ser solucionada através da aplicação criteriosa das Janelas de Parzen (PARZEN, 1962). Outros estudos, como a maximização de funções de expoente quadrático (WU *et al.*, 2011), advém da mesma concepção teórica. Entretanto, apresentam algumas diferenças em relação ao algoritmo de otimi-

zação utilizado.

A aplicação da teoria da informação à EESP se estabelece a partir da extração de informações diretamente das medidas analógicas presentes no sistema (PRINCIPE; DONGXIN, 1999; KRSTULOVIC; MIRANDA *et al.*, 2013). A quantidade de informação extraída é mensurada pelo conceito de Entropia, introduzida por Shannon (SHANNON, 1948). A entropia é uma função escalar que está relacionada à quantidade de informação contida em uma variável aleatória cuja função densidade de probabilidade é conhecida. O critério da entropia pode ser empregado como uma alternativa para o método baseado no critério dos Mínimos Quadrados ou do Erro Quadrático Médio (EQM), pois preserva sua natureza não-paramétrica (PRINCIPE; DONGXIN, 1999; ERDOGMUS; PRINCIPE, 2002). Adicionalmente, a estimação de estados realizada através da aplicação de Janelas de Parzen, com base no *kernel* Gaussiano, habilita maior extração de informações e assegura soluções mais precisas que o EQM, principalmente quando o processo é não-Gaussiano (LIU; POKHAREL; PRINCIPE, 2006). Isto significa que os algoritmos baseados na aplicação das Janelas de Parzen são menos suscetíveis aos efeitos de erros aleatórios de alta magnitude, enquanto que a presença de tais erros em métodos baseados em modelos quadráticos afetam severamente seus resultados.

Outro conceito relevante da Teoria da Informação é o de correntropia. Este conceito está diretamente relacionado à similaridade entre duas variáveis aleatórias em uma vizinhança do espaço conjunto definida por uma função densidade de probabilidade.

Uma outra interpretação deste conceito pode ser vista como a distribuição dos erros presentes entre as variáveis aleatórias e a média zero, na qual a função densidade de probabilidade é controlada pela largura de uma função *kernel*. A largura desta janela é definida por uma função Gaussiana cuja a variância utilizada para controlar uma “janela de observação” dentro da qual a similaridade é avaliada (LIU; POKHAREL; PRINCIPE, 2006; MIRANDA; SANTOS; PEREIRA, 2009; MIRANDA, 2015). Sendo ajustável, esta janela fornece um instrumento essencial para atenuar ou eliminar o efeito perturbador de pontos discrepantes (PRINCIPE; DONGXIN, 1999; ERDOGMUS; PRINCIPE, 2001, 2002; LIU; POKHAREL; PRINCIPE, 2006; LIU; POKHAREL; PRINCIPE, Jose C., 2006; MIRANDA; SANTOS; PEREIRA, 2009; PRINCIPE, 2013; MIRANDA, 2013, 2015).

Mais recentemente, o conceito de Correntropia é incluído como um caso particular da Correntropia Generalizada, definida em uma família de funções *kernel* que podem variar com a forma como são considerados os tipo de erros e ruídos nas medidas para resolver o problema de Estimação de Estados (PESTEH; MOAYYED; MIRANDA *et al.*, 2019; CHEN *et al.*, 2015). As propriedades fundamentadas neste conceito podem ser atrativamente combinadas com métodos numéricos eficientes de



otimização, com o objetivo de fornecer estimativas confiáveis no final de processo de estimação (PESTEH; MOAYYED; MIRANDA, 2020). Contudo, faz-se necessária a inclusão de restrições de igualdade e de desigualdade, assim como de funções de *kernel* fortemente não-lineares. Como resultado, a solução do problema via Correntropia generalizada deve ser obtida mediante métodos avançados de programação não-linear.

O conceito de correntropia tem sido aplicado à EESP e gerado algumas publicações na área de estimação de estados (KRSTULOVIC; MIRANDA *et al.*, 2013; MIRANDA; SANTOS; PEREIRA, 2009; WU *et al.*, 2011; MIRANDA; KRSTULOVIC *et al.*, 2012), com o processo de solução baseado em propriedades de redes neurais autoassociativas e algoritmos meta-heurísticos. Diferentemente desta abordagem, este trabalho visa aliar o conceito de Correntropia a métodos de solução numericamente robustos, como os métodos ortogonais.

### 1.2.3 Processamento de Erros Grosseiros em Modelos Híbridos de Estimação

Nos últimos anos, arquiteturas híbridas de estimação de estados têm sido alvo de estudos para a modelagem em tempo-real de sistemas elétricos de potência, principalmente no que concerne à inclusão de medidas fasoriais sincronizadas obtidas de dispositivos PMUs instalados na rede elétrica. O processamento de tais medidas pode melhorar significativamente a qualidade dos resultados de estimação de estados mediante sua integração com medidas convencionais, adquiridas através do sistema SCADA.

Desta forma, diversos métodos foram desenvolvidos para promover tal integração, como as propostas realizadas por (ZHOU *et al.*, 2006; SIMÕES COSTA; ALBUQUERQUE, 2011; SIMÕES COSTA; ALBUQUERQUE; BEZ, 2013; DUBEY; CHAKRABARTI; TERZIJA, 2019; BEZ *et al.*, 2020). O método proposto por Zhou *et al.* (ZHOU *et al.*, 2006) incorpora os resultados do estimador de estados convencional e fasores de medidas em um estágio de pós-processamento configurado como um estimador linear. A metodologia descrita em (SIMÕES COSTA; ALBUQUERQUE; BEZ, 2013) apresenta uma arquitetura com distintos módulos de estimação que processam medidas SCADA e PMU de forma independente. Nesta abordagem, os respectivos estados estimados obtidos a partir do conjunto de medidas fornecidos por cada sensor são processadas por um módulo de fusão de estimativas e resolvido através de um problema linear de mínima variância. Em (ZHU; ABUR, 2007), mostra-se que problemas numéricos encontrados no processo de inicialização com partida plana dos estados podem ser evitados através da formulação de fasores de corrente em coordenadas retangulares. Um estimador híbrido de estados utilizando medidas convencionais, assim como medidas fasoriais na forma retangular, é apresentado em (BI; QIN; YANG, 2008). Os efeitos causados pela falta de sincronismo nas medidas e o benefício da

inclusão de PMUs na precisão da estimativa do estado são analisados em (HURTGEN; MAUN, 2008). Medidas convencionais e do sistema de medição fasorial são combinadas em uma formulação baseada nos mínimos quadrados ponderados em (CHAKRABARTI; KYRIAKIDES *et al.*, 2009), e as incertezas paramétricas de modelos de linhas de transmissão são considerados para a atribuição dos pesos das medidas fasoriais em (CHAKRABARTI; KYRIAKIDES, 2009). Em (BEZ *et al.*, 2020) é proposta uma arquitetura de estimação em dois estágios, em que um algoritmo ortogonal em blocos é empregado para processar as medidas fasoriais sem o uso de aproximações que desprezam a correlação entre medidas, as quais podem afetar as propriedades estatísticas da solução. Em (DO COUTTO FILHO; STACCHINI DE SOUZA; GUIMARAENS, 2014), apresenta-se uma metodologia para processar erros grosseiros em medidas convencionais e fasoriais. A estratégia combina os resultados de estimação fornecidos por estimadores executados de forma independentes baseados somente em medidas SCADA e PMU, seguida da validação das quantidade estimadas para as medidas, o que viabiliza o processamento de erros grosseiros. Por fim, a inclusão e a avaliação de medidas PMUs incorporadas ao estimador convencional baseado no modelo MQP e aplicados à sistemas reais são reportados em (SLUTSKER *et al.*, 1995; AVILA-ROSALES *et al.*, 2009).

Os trabalhos citados preservam os estimadores de estados convencionais, os quais processam somente medidas SCADA, e utilizam arquiteturas de estimação em que o processamento de medidas fasoriais é realizado separadamente. Tal abordagem, baseada no uso de diferentes módulos de estimação, que processa apenas medidas fasoriais, mantém intacto o estimador de estados tradicional, e é vista como uma solução de transição até que a crescente, porém gradual instalação de PMUs na rede elétrica possa satisfazer os requisitos de observabilidade necessários para aplicação a sistemas reais.

Desta forma, os resultados do segundo módulo de estimação, que processa apenas medidas fasoriais, são combinados com as estimativas baseadas em medidas SCADA, obtidas por estimadores baseados no critério dos MQP. Métodos de estimação distintos são reportados nos trabalhos acima para integrar as medidas de diferentes sensores. Embora todos confirmem as vantagens de integração entre as medidas SCADA e PMU, e apesar de contribuições importantes relatadas na literatura (DO COUTTO FILHO; STACCHINI DE SOUZA; GUIMARAENS, 2014), o processamento de erros grosseiros em conexão com arquiteturas híbridas de estimação de estados ainda mantém-se como um problema que merece esforços adicionais de pesquisa. A proposta apresentada em (DO COUTTO FILHO; STACCHINI DE SOUZA; GUIMARAENS, 2014) pressupõe independência de processamento entre medidas SCADA e PMU. Esta conjectura permite rastrear erros grosseiros em ambos os conjuntos de medidas considerando diferentes condições de redundância, mediante o uso de técnicas

convencionais de processamento de dados errôneos.

Trabalhos baseados em estimação robusta também são propostos na literatura para a resolução do problema de estimação híbrida. Uma metodologia híbrida considerando observabilidade parcial do sistema elétrico com medidas PMU é reportada em (DUBEY; CHAKRABARTI; TERZIJA, 2019) e (GLAVIC; CUTSEM, 2011). Um estimador generalizado baseado na máxima similaridade vizinha e utilizando projeções estatísticas é proposto em (MILI *et al.*, 1996), cuja metodologia empregue vem proporcionando o surgimento de outros modelos baseados na teoria da estatística robusta, com a possibilidade de processar medidas fasoriais.

Recentemente, o conceito de máxima correntropia tem sido aplicado ao processo de fusão de estimativas (ASCARI; SIMÕES COSTA; MIRANDA, 2019), aproveitando as vantagens das características de resiliência fornecida aos estimadores face à presença de erros grosseiros. A proposta baseia-se na arquitetura de fusão em dois estágios em (SIMÕES COSTA; ALBUQUERQUE; BEZ, 2013), onde medidas SCADA e PMU são processadas por módulos distintos de estimação MCC. Desta forma, o módulos de estimação independentes em (ASCARI; SIMÕES COSTA; MIRANDA, 2019) baseiam-se no critério de máxima correntropia para fornecer dois conjuntos de estimativas que sejam isentos de erros grosseiros e que, conseqüentemente, produzem informações não contaminadas por erros grosseiros sobre os erros de estimação. Ao fim do processo de fusão das estimativas, espera-se a produção de um conjunto de informações confiáveis sobre o estado da rede elétrica.

A estimação híbrida de estados também é contemplada entre os objetivos desta tese de doutorado, especificamente no que tange ao processamento de erros grosseiros possivelmente presentes tanto entre as medidas oriundas de sistemas de medição fasorial quanto nas adquiridas via sistemas SCADA. Diferentemente da estratégia de fusão de estimativas realizada em (ASCARI; SIMÕES COSTA; MIRANDA, 2019), é proposta uma arquitetura robusta em dois níveis de estimação baseada em algoritmo ortogonal e informações *a priori* sobre os estados, que busca preservar o estimador de estados convencional e simultaneamente tirar proveito da inclusão de medidas fasoriais sincronizadas e do algoritmo ortogonal baseado na versão rápida das Rotações de Givens. Deve-se enfatizar que a preservação do estimador tradicional decorre pelo fato de ainda ocorrer a transição gradual dos medidores convencionais SCADA para o sistema de medição fasorial. Desta forma, a execução do estimador robusto descrito nesta arquitetura pode ser realizado após à estimação de estados baseado somente nas medidas SCADA, sem a necessidade de quaisquer modificações no estimador tradicional.

A estratégia de estimação híbrida descrita acima permite, portanto, a incorporação de medidas fasoriais sincronizadas no processo de estimação de estados em sistemas de potência. Ressalta-se que o constante aprimoramento desta tecnologia de

medição e a possibilidade de sua implementação em grandes áreas dos sistemas de potência gera novas perspectivas para a melhoria do controle e da operação de redes elétricas, o que inclui a utilização de tais medidas em ferramentas mais avançadas de monitoração em tempo real, como por exemplo a estimação dinâmica de estados. Estes modelos dinâmicos de estimação têm por objetivo rastrear os fenômenos dinâmicos que ocorrem no sistema, extraindo informações valiosas de uma sucessão de estados estáticos que evoluem no tempo, podendo atuar em esquemas de controle e proteção (MODIR; SCHLUETER, 1981; MELIPOULOS *et al.*, 2017; LIU; MELIPOULOS *et al.*, 2017; FAN *et al.*, 2015; CUI; KAVASSERI; BRAHMA, 2017). O desenvolvimento de estimadores dinâmicos de estados e parâmetros torna-se hoje particularmente oportuno para fazer face ao aumento da complexidade operativa resultante de incertezas relacionada à inclusão de novas tecnologias nos lados da geração e da demanda (ZHAO; WANG *et al.*, 2018). Os primeiros estudos relacionados à estimação dinâmica de estados datam da década de 70 (DEBS; LARSON, 1970; ALLAM; LAUGHTON, 1976; SRINIVASAN; ROBICHAUD, 1974), porém as limitações tecnológicas da época não garantiram avanços concretos para a afirmação destas ferramentas nos centros de operação e controle. Isto não impediu, entretanto, o prosseguimento de estudos voltados à concepção de algoritmos de estimação dinâmica de estados, como reportados em (DO COUTTO FILHO; GLOVER; LEITE DA SILVA, 1993; ROUSSEAU; CUTSEM; DY LIACCO, 1990).

O advento do sistema de medição fasorial sincronizada, e principalmente as altas taxas de amostragem relacionadas às medidas fasoriais, permitiram o impulso de novas abordagens para a estimação dinâmica de estados em sistemas de potência nos últimos anos, com maior relevância para associação de medidas convencionais, provenientes do sistema SCADA, com medidas fasoriais sincronizadas. Uma preocupação recorrente dos pesquisadores é o processamento do estimador de estados a partir deste dois tipos de sensores, que possuem grandes diferenças entre suas taxas de amostragem. Diversos trabalhos fornecem metodologias para produzir estimativas considerando este problema na estimação dinâmica de estados, como as abordagens apresentadas em (DO COUTTO FILHO; STACCHINI DE SOUZA, 2009; ROUHANI; ABUR, 2018; ZHAO, Junbo; MILI, Lamine, 2018a; ZHAO, J.; MILI, L., 2018; ZHAO; QI *et al.*, 2019; ZHAO; WANG *et al.*, 2018; ZHAO; NETTO; MILI, 2017).

Em que pese a reconhecida importância dos estudos sobre estimação dinâmica de estados e parâmetros mencionados acima, neste trabalho as atenções se concentram na concepção de algoritmos híbridos voltados à estimação estática em sistemas elétricos de potência, considerando o processamento de medidas provenientes de duas classes de sensores, a saber, sistemas SCADA e unidades de medição fasorial sincronizada.

### 1.3 OBJETIVOS E CONTRIBUIÇÕES DA TESE

Em termos gerais, esta tese de doutorado tem como objetivo propor uma abordagem unificada para a estimação de estados de sistemas de potência composta por um algoritmo baseado no Critério de Máxima Correntropia e em uma implementação que privilegia as propriedades de robustez numérica propiciadas pela versão rápida das rotações ortogonais de Givens. Esta combinação de métodos é também explorada para a concepção de uma arquitetura híbrida de estimação capaz de processar simultaneamente erros em medidas convencionais e em medidas fasoriais sincronizadas.

Dentre os objetivos específicos estão:

- Formular o problema de Estimação de Estados de Sistemas Elétricos de Potência baseado no conceito de máxima correntropia para permitir sua solução pelo método das Rotações Rápidas de Givens, bem como conceber um algoritmo eficiente para esta finalidade;
- Propor um estimador híbrido de estados com capacidade de processar medidas SCADA e medidas fasoriais, que seja resiliente face à ocorrência de erros grosseiros mediante sua supressão durante a execução da estimação de estados, e que adicionalmente permita a identificação posterior dos dados contaminados;
- Formular e desenvolver matematicamente outros recursos e instrumentos para viabilizar a execução eficiente das metas acima enunciadas. Estes são: a consideração de informações *a priori* no contexto do critério da máxima correntropia, e a concepção de estratégias mais seletivas para ajuste das janelas de Parzen baseado no cálculo dos resíduos de estimação, visando a eliminação de dados espúrios no processo de estimação de estados.

### 1.4 ORGANIZAÇÃO DA TESE

No Capítulo 2 é feita uma revisão dos conceitos teóricos e métodos tradicionais associados à estimação de estados em sistemas de potência, que consiste na descrição do modelo de medição, da formulação matemática pelo método dos Mínimos Quadrados Ponderados e a sua interpretação, e do método clássico de solução. São tratados, brevemente, os conceitos e técnicas para o processamento de erros grosseiros.

No Capítulo 3 são apresentados os conceitos da Teoria da Informação aplicados à estimação de estados, cujo objetivo é maximizar a quantidade de informações que podem ser extraídas das medidas disponíveis ao estimador. São abordados os conceitos de Entropia, de Correntropia e de Janelas de Parzen. Descreve-se também como a estimação de estados é formulada com base no Critério de Máxima Correntropia, e a sua resolução através de uma equação matricial com reponderação de medidas.

O Capítulo 4 apresenta as bases desta tese de doutorado, abordando a resolução do estimador de estados baseado no critério de máxima correntropia pelo algoritmo ortogonal baseado nas Rotações Rápidas de Givens. Além disso, apresenta-se a metodologia de ajuste dinâmico das janelas de Parzen e a aplicação do método proposto a um sistema-teste de pequeno porte.

O Capítulo 5 aborda a estratégia de dois estágios, para processar medidas SCADA e medidas fasoriais sincronizadas, com características robustas face à ocorrência de erros grosseiros. Propõe-se a inclusão de informações *a priori* sobre as variáveis de estado na formulação do critério de máxima correntropia. Adicionalmente, é proposta uma técnica de rastreamento e identificação das medidas corrompidas por erros grosseiros que foram automaticamente suprimidas durante o processo de estimação pelo estimador híbrido.

O Capítulo 6 apresenta resultados numéricos obtidos da aplicação dos métodos propostos nos Capítulos 4 e 5 aos sistemas-teste de 14, 30, 57 e 118 barras do IEEE.

No Capítulo 7 são apresentadas as principais conclusões sobre o trabalho e sugestões para trabalhos futuros.

## 2 ESTIMAÇÃO DE ESTADOS VIA MÉTODOS QUADRÁTICOS

### 2.1 INTRODUÇÃO

Os problemas relacionados à estimação de estados no SEP têm sido estudados desde o final da década de sessenta, e os primeiros trabalhos de EESP devem-se a Schweppe (SCHWEPPE; WILDES, 1970; SCHWEPPE; ROM, 1970; SCHWEPPE, 1970). Nesses artigos, o problema é definido como um procedimento que visa estimar os valores das variáveis de natureza elétrica (variáveis de estado) que caracterizam um dado ponto de operação do sistema a partir de um conjunto de medidas passíveis de conter erros aleatórios de diferentes tipos. O objetivo da EESP é, portanto, fornecer uma base de dados em tempo real confiável, a partir das medidas redundantes coletadas da rede, que são então processadas de forma a fornecer estimativas ótimas (em um sentido ainda a ser definido) para as tensões complexas em todas as barras do sistema.

Com os avanços nos estudos de técnicas para a monitoração e análise de segurança em sistemas elétricos de potência, diversos métodos de solução da EE estão disponíveis na literatura. A escolha do método de solução da EE, bem como o tipo de modelagem a ser considerada para o sistema, deve ser pautado no nível de detalhamento das informações fornecidas, robustez e confiabilidade do algoritmo utilizado e esforço computacional requerido, entre outros fatores.

Neste capítulo será apresentada a formulação convencional para o problema da estimação de estados, abordando-se também suas características intrínsecas, a modelagem e métodos de resolução consagrados na literatura. A Seção 2.2 trata do modelo de medição, e a formulação da EESP de acordo com o método dos Mínimos Quadrados Ponderados é apresentada na Seção 2.3. A Seção 2.4 descreve o método de solução via Equação Normal, enquanto a Seção 2.5 aborda a análise e processamento de erros grosseiros na estimação de estados.

### 2.2 MODELO DE MEDIÇÃO

Considerando-se um sistema de potência formado por  $N$  barras, o problema de EESP é resolvido a partir de um conjunto sobredeterminado de equações lineares, descritas como:

$$\mathbf{z} = \mathbf{h}(\mathbf{x}) + \boldsymbol{\varepsilon} \quad (2.1)$$

onde:

$\mathbf{z}$  é o vetor de ordem  $(m \times 1)$  das quantidades medidas<sup>1</sup>;

<sup>1</sup> Tratando-se do modelo não-linear da rede, as medidas provenientes do sistema de medição SCADA são as magnitudes de tensão nas barras, os fluxos de potência ativa e reativa em ramos que

- $\mathbf{x}$  é o vetor de estados ( $n \times 1$ ) composto pelas magnitudes e ângulos de tensão nas barras, com  $n = 2N - 1$ ;
- $\mathbf{h}(\cdot)$  é o vetor ( $m \times 1$ ) formado pelas funções não-lineares que relacionam as quantidades medidas às variáveis de estado  $\mathbf{x}$ ;
- $\boldsymbol{\varepsilon}$  é o vetor de ordem ( $m \times 1$ ) dos erros aleatórios de medição.

É notório que os valores verdadeiros das variáveis de estado do sistema, e consequentemente das quantidades medidas, são desconhecidos. Para estimá-los, faz-se necessário realizar certas suposições sobre o modelo de medição do sistema. Na ausência de medidas contaminadas por erros grosseiros, os valores fornecidos pelos medidores situam-se em uma faixa de tolerância aceitável, a qual está relacionada à sua respectiva classe de exatidão.

Portanto, o vetor de erros  $\boldsymbol{\varepsilon}$  apresenta estas inexatidões das quantidades medidas, com desvio padrão  $\sigma_m$ , oriundos dos equipamentos utilizados, como os transformadores dos instrumentos de medição, efeitos de conversão analógica/digital, entre outros. Supondo que este vetor possui média zero e que os erros de medição não são correlacionados, a matriz de covariância correspondente é diagonal e seus elementos são definidos pelas variâncias dos erros de medição, calculados com base na precisão dos medidores.

Assim:

$$\begin{aligned} E\{\boldsymbol{\varepsilon}\} &= \mathbf{0} \\ E\{\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}^T\} &= \mathbf{R} \end{aligned} \quad (2.2)$$

onde  $E\{\cdot\}$  é o operador expectância e  $\mathbf{R}$  é a matriz de covariância ( $m \times m$ ) dos erros de medição, suposta diagonal, cujos elementos são definidos por  $R_{ij} = \sigma_{m,i}^2$ .

Uma das formas de caracterizar um dado plano de medição com relação ao respectivo grau de redundância, é defini-lo com base na relação da quantidade de medidas disponíveis ao estimador e o número de variáveis de estado, o que leva à formação de um índice de redundância global das medidas realizadas na rede elétrica, dado por:

$$\rho \triangleq \frac{m}{n} \quad (2.3)$$

De acordo com o modelo de medição apresentado nas Equações (2.1) e (2.2), uma condição necessária para que um sistema elétrico seja observável é que  $m \geq n$  ou  $\rho \geq 1$ , embora tal condição não seja suficiente para garantir a observabilidade e consequentemente a estimação dos estados. Uma condição desejável é que, além da observabilidade, haja redundância das medidas em grau suficiente, pois isto propicia tanto a estimação quanto a facilidade em detectar e identificar erros grosseiros

---

interconectam as barras, as injeção de potência ativa e reativa nas barras e magnitudes de correntes nas linhas de transmissão.



(LARSON; TINNEY; PESCHON, 1970; CLEMENTS; KRUMPHOLZ; DAVIS, 1981; CLANNENTS; KRUTNPOLZ; DAVIS, 1983; ANTONIO; TORREÃO; DO COUTTO FILHO, 2001).

### 2.3 CRITÉRIO DOS MÍNIMOS QUADRADOS PONDERADOS

O problema de estimação de estados consiste em determinar as estimativas para o vetor de estados que apresentem o melhor ajuste às medidas do plano de medição, o que pode ser formulado como um problema de otimização. Uma técnica clássica para a estimação de estados é o método dos Mínimos Quadrados Ponderados (MQP), inicialmente aplicada em (SCHWEPPE; WILDES, 1970).

Considerando o modelo de medição apresentado na Seção 2.2, o vetor dos resíduos de estimação das medidas de ordem  $(m \times 1)$  é definido como:

$$\mathbf{r} = \mathbf{z} - \mathbf{h}(\hat{\mathbf{x}}) \quad (2.4)$$

onde  $\hat{\mathbf{x}}$  é o vetor de estados estimados do sistema de dimensão  $(n \times 1)$ , e os vetores  $\mathbf{z}$  e  $\mathbf{h}(\cdot)$  são definidos conforme a Equação (2.1).

Pode-se formular o problema de estimação de estados com base nos MQP como a minimização da soma dos quadrados dos resíduos de estimação, cuja função-objetivo é:

$$J(\hat{\mathbf{x}}) = \frac{1}{2} \sum_{i=1}^m \left( \frac{r_i}{\sigma_{m,i}} \right)^2 \quad (2.5)$$

sendo  $r_i$  definido pelo resíduo da  $i$ -ésima medida cujo desvio padrão é  $\sigma_{m,i}$ .

O critério (2.5) pode ser reescrito na forma matricial como:

$$J(\hat{\mathbf{x}}) = \frac{1}{2} \mathbf{r}^T \mathbf{R}^{-1} \mathbf{r} \quad (2.6)$$

A ponderação dos termos quadráticos dos resíduos em (2.6) é realizada pela matriz  $\mathbf{R}^{-1}$ , cujos elementos diagonais são iguais ao inverso da variância de cada medida. Ou seja, quanto maior for a exatidão do medidor  $i$ , menor será o valor do desvio padrão  $\sigma_{m,i}$  e conseqüentemente maior o valor do peso associado  $R_{ii}^{-1}$ . Desta forma, os medidores que fornecem medidas mais confiáveis recebem maior peso na formulação do problema de mínimos quadrados ponderados.

### 2.4 SOLUÇÃO VIA MÉTODO DA EQUAÇÃO NORMAL

O modelo de medição proposto por (SCHWEPPE; WILDES, 1970; SCHWEPPE; ROM, 1970; SCHWEPPE, 1970) e formulado para o problema de minimização a partir do critério MQP, pode ser descrito utilizando as Equações (2.4) e (2.6), apresentado na seguinte forma:

$$\min_{\hat{\mathbf{x}}} J(\hat{\mathbf{x}}) = [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})] \quad (2.7)$$

Para a solução do problema apresentado na Equação (2.7), aplicam-se as condições de otimalidade de primeira ordem de Karush-Kuhn-Tucker (KKT), que consistem na garantia de que o ponto considerado como solução seja um ponto estacionário, isto é:

$$\frac{\partial J(\mathbf{x})}{\partial \mathbf{x}} = 0 \quad (2.8)$$

$$-2\mathbf{H}^T(\mathbf{x})\mathbf{R}^{-1}[\mathbf{z}-\mathbf{h}(\mathbf{x})] = \mathbf{0} \quad (2.9)$$

onde  $\mathbf{H}(\mathbf{x})$  é a matriz Jacobiana de dimensão  $(m \times n)$ , dada por:

$$\mathbf{H}(\mathbf{x}) = \frac{\partial \mathbf{h}(\mathbf{x})}{\partial \mathbf{x}} \quad (2.10)$$

Como a Equação (2.9) é fortemente não-linear, expande-se em série de Taylor a função vetorial de equações não-lineares  $\mathbf{h}(\mathbf{x})$  em torno do ponto  $\hat{\mathbf{x}}^k$  e ao longo da direção  $\Delta \mathbf{x}$  truncando-a no termo de primeira ordem, obtendo-se a seguinte expressão:

$$\mathbf{h}(\hat{\mathbf{x}}^k + \Delta \mathbf{x}) \cong \mathbf{h}(\hat{\mathbf{x}}^k) + \mathbf{H}(\hat{\mathbf{x}}^k)\Delta \mathbf{x} \quad (2.11)$$

de modo que:

$$\mathbf{H}(\mathbf{x}^k) = \left. \frac{\partial \mathbf{h}(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}^k} \quad (2.12)$$

Definindo o vetor  $\Delta \mathbf{z}$  como o vetor  $(m \times 1)$  de medidas incrementais, dado por:

$$\Delta \mathbf{z} \triangleq \mathbf{z} - \mathbf{h}(\hat{\mathbf{x}}^k) \quad (2.13)$$

é então possível definir o modelo linearizado do problema apresentado na Equação (2.7) a partir dos termos nas Equações (2.11) e (2.13), e desta forma, a função-objetivo a ser minimizada torna-se:

$$J(\Delta \mathbf{x}) = [\Delta \mathbf{z} - \mathbf{H}(\hat{\mathbf{x}}^k)\Delta \mathbf{x}^k]^T \mathbf{R}^{-1} [\Delta \mathbf{z} - \mathbf{H}(\hat{\mathbf{x}}^k)\Delta \mathbf{x}^k] \quad (2.14)$$

Aplicando as condições de otimalidade de primeira ordem na Equação (2.14), obtém-se a seguinte relação:

$$\frac{\partial J(\Delta \mathbf{x})}{\partial \Delta \mathbf{x}} = \mathbf{0} \quad (2.15a)$$

$$-2\mathbf{H}^T(\hat{\mathbf{x}}^k)\mathbf{R}^{-1}[\Delta \mathbf{z} - \mathbf{H}(\hat{\mathbf{x}}^k)\Delta \mathbf{x}^k] = \mathbf{0} \quad (2.15b)$$

Tal expressão resulta em:

$$[\mathbf{H}^T(\hat{\mathbf{x}}^k)\mathbf{R}^{-1}\mathbf{H}(\hat{\mathbf{x}}^k)]\Delta \mathbf{x}^k = \mathbf{H}^T(\hat{\mathbf{x}}^k)\mathbf{R}^{-1}\Delta \mathbf{z} \quad (2.16)$$

A Equação (2.16) é conhecida como Equação Normal de Gauss e representa o sistema de equações linearizadas a ser resolvido a cada iteração para a determinação do incremento do vetor de estados  $\Delta \mathbf{x}$ . A matriz de coeficientes no lado esquerdo

da equação é comumente chamada de matriz ganho, ou matriz de informação, do problema:

$$\mathbf{G}(\mathbf{x}^k) = \mathbf{H}^T(\mathbf{x}^k) \mathbf{R}^{-1} \mathbf{H}(\mathbf{x}^k) \quad (2.17)$$

Logo, A Equação Normal de Gauss fica resumida a:

$$\mathbf{G}(\hat{\mathbf{x}}^k) \Delta \mathbf{x}^k = \mathbf{H}^T(\hat{\mathbf{x}}^k) \mathbf{R}^{-1} \Delta \mathbf{z} \quad (2.18)$$

É importante ressaltar que a matriz ganho é de fato uma aproximação para a matriz Hessiana  $\nabla^2 J(\hat{\mathbf{x}}) = \partial^2 J(\hat{\mathbf{x}}) / \partial \mathbf{x}^2$  próxima da solução, e o lado direito da Equação (2.16) é o negativo do gradiente de  $J(\hat{\mathbf{x}})$ , ambos calculados no ponto  $\mathbf{x}^k$  (MONTICELLI, 1999; ABUR; GOMEZ EXPOSITO, 2004).

O método da Equação Normal consiste em resolver um conjunto de equações não-lineares, como o apresentado em (2.9), através de um processo iterativo para obter o vetor de incrementos  $\Delta \mathbf{x}$  pela equação (2.16). Portanto, o vetor de estados estimados é atualizado a cada iteração conforme:

$$\hat{\mathbf{x}}^{k+1} = \hat{\mathbf{x}}^k + \Delta \mathbf{x}. \quad (2.19)$$

O processo é inicializado em um ponto inicial  $\hat{\mathbf{x}}^0$  (na falta de valores mais recentes, o perfil do plano das tensões complexas pode ser adotado). Assim, a atualização realizada em (2.19) continua até que uma pequena tolerância pré-definida seja satisfeita para a magnitude do passo  $\Delta \mathbf{x}$ .

Embora sob condições usuais o método da Equação Normal seja capaz de resolver problemas práticos, este método possui como desvantagem a tendência ao mau condicionamento numérico (ABUR; GOMEZ EXPOSITO, 2004), o que pode ser verificado a partir do número de condicionamento da matriz de informação (2.17). Este fato ocorre devido à seguinte propriedade:

$$\text{Cond}(\mathbf{H}^T \mathbf{H}) = [\text{Cond}(\mathbf{H})]^2 \quad (2.20)$$

ou seja, se  $\mathbf{H}$  não é bem condicionada,  $\mathbf{G}$  será mal condicionada. O fator  $\text{Cond}(\cdot)$  é dado pela relação entre o máximo e o mínimo autovalores de uma matriz simétrica (GOLUB; VAN LOAN, 2012; CHEN, 1999). Valores muito elevados indicam que a solução de um dados sistema linear é susceptível a erros de aproximação e arredondamento que ocorrem no armazenamento da matriz  $\mathbf{G}$  (NOCEDAL; WRIGHT, 2006).

## 2.5 PROCESSAMENTO DE ERROS GROSSEIROS

No contexto de EESP, erros grosseiros são medidas que possuem maior grau de inexatidão do que é assumido quando os erros de medição são modelados. Algumas medidas podem ser rejeitadas na etapa de pré-filtragem, pois para estas medidas os erros grosseiros são evidentemente claros, isto é, ocorre o descarte de uma ou

mais medidas que não estão dentro de certos limites plausíveis (MONTICELLI, 1999; HANDSCHIN *et al.*, 1975).

A presença de medidas errôneas processadas pelo estimador de estados baseado no critério dos Mínimos Quadrados faz com que seu desempenho seja afetado, normalmente em resultados da estimação de estados não aderentes à real condição de operação. Em casos mais severos, pode até mesmo ocorrer a não-convergência do algoritmo computacional. Portanto, faz-se necessário a aplicação de técnicas para realizar a detecção de medidas portadoras de erros grosseiros no conjunto de medidas, além da sua devida identificação, para que possam ser eliminadas do plano de medição ou substituídas por pseudomedidas (MONTICELLI; GARCIA, 1983; CUTSEM; RIBBENS-PAVELLA; MILI, 1984).

Convencionalmente, o tratamento de erros grosseiros é realizado em uma etapa de pós-processamento, isto é, após a obtenção das estimativas dos estados  $\hat{\mathbf{x}}$  e das quantidades medidas  $\mathbf{z}$ . O processamento de erros grosseiros inicia-se pela aplicação de testes de hipóteses sobre funções destas quantidades, com o objetivo de verificar se as estimativas são compatíveis com a exatidão preconizada pelos respectivos desvios-padrão. Uma das formulações analíticas do processo de detecção de erros grosseiros mais difundidas é o teste- $J(\hat{\mathbf{x}})$ . Este teste se caracteriza como uma forma indireta para detectar a presença de medidas portadoras de erro grosseiro no plano de medição utilizando um teste estatístico. Quando não ocorre a presença dessas medidas, a variável aleatória  $J(\hat{\mathbf{x}})$  (soma ponderada do quadrado dos resíduos) segue uma distribuição do qui-quadrado ( $\chi^2$ ) (HANDSCHIN *et al.*, 1975; DOPAZO; KLITIN; SASSON, 1973). Em outras palavras, o estimador de estados fornece um valor de  $J(\hat{\mathbf{x}})$ , para um dado vetor de estados estimados  $\hat{\mathbf{x}}$ , e deve-se verificar se o valor observado atende ou não à hipótese da distribuição do  $\chi^2$ , considerando-se uma probabilidade de falso alarme pré-fixada  $\alpha$ . Caso o valor computado de  $J(\hat{\mathbf{x}})$  exceda o limiar calculado a partir da distribuição do  $\chi^2$  e do valor de  $\alpha$  conclui-se com uma probabilidade de erro de falso alarme  $\alpha$ , que há a presença de erro grosseiro (DOPAZO; KLITIN; SASSON, 1973).

A conclusão acima parte da hipótese que os erros das medidas são variáveis aleatórias gaussianas independentes sem a presença de erros grosseiros. Neste caso o valor de  $J(\hat{\mathbf{x}})$  apresenta uma distribuição do qui-quadrado com  $\ell$  graus de liberdade, sendo  $\ell = m - n$ , onde  $m$  é o número de medidas e  $n$  o número de estados de acordo com modelo de medição na Seção 2.2 (HANDSCHIN *et al.*, 1975).

Por conseguinte, o valor do limiar  $K$  é dado por:

$$K = \chi_{\ell, \alpha}^2 \quad (2.21)$$

onde  $\chi_{\ell, \alpha}^2$  é o valor do percentil da distribuição do  $\chi^2$  para  $\ell$  graus de liberdade, com uma probabilidade de falso alarme  $\alpha$  fixada, assumida previamente como parâmetro de projeto.

Portanto, pode-se firmar duas hipóteses para o teste de detecção de erros:

- $H_0$ : Se  $J(\hat{\mathbf{x}}) \leq K$ , então não existem medidas com erros grosseiros;
- $H_1$ : Se  $J(\hat{\mathbf{x}}) > K$ , então existem medidas com erros grosseiros.

Caso a hipótese  $H_1$  seja verdade, o conjunto de resíduos resultante do processo de estimação deve ser, portanto, submetido à análise de identificação de medidas espúrias.

O método convencional para a identificação de erros grosseiros tem por base a utilização do vetor de resíduos determinado pelo modelo não-linear da Equação (2.4), cujos elementos são definidos como os desvios entre as medidas coletadas da rede e os valores das medidas computadas com base nos estados estimados pelo método MQP. Assim sendo, uma das ferramentas mais utilizadas nos Centros de Operação do sistema para se identificar medidas errôneas consiste na análise dos resíduos normalizados, ou Teste do Máximo Resíduo Normalizado (LNRT)<sup>2</sup>. Para obtê-los, é necessário o cálculo da matriz de covariância dos resíduos, dada por (MONTICELLI, 1999; HANDSCHIN *et al.*, 1975):

$$\mathbf{\Omega} = \mathbf{R} - \mathbf{H}\mathbf{G}^{-1}\mathbf{H}^T \quad (2.22)$$

em que  $\mathbf{G}$  é a matriz ganho calculada conforme a Equação (2.17). Prova-se que o inverso da matriz ganho a matriz de covariância dos erros de estimação (HANDSCHIN *et al.*, 1975; CUTSEM; RIBBENS-PAVELLA; MILI, 1984), denotada por  $\mathbf{\Sigma}$ :

$$\mathbf{\Sigma} = \mathbf{G}^{-1} = (\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} \quad (2.23)$$

Logo, os resíduos normalizados são computados dividindo-se cada componente do vetor de resíduos  $\mathbf{r}$  pelo desvio-padrão correspondente, obtido da matriz de covariância dos resíduos, proveniente da Equação (2.22), ou seja:

$$r_i^N = \frac{r_i}{\sqrt{\Omega_{ii}}} \quad (2.24)$$

em que  $r_i^N$  é o resíduo normalizado associado à medida  $i$ , e  $\Omega_{ii}$  é o elemento da diagonal da matriz de covariância dos resíduos.

É possível demonstrar matematicamente que, se apenas uma medida do plano de medição for portadora de erro grosseiro e as demais perfeitas, o maior resíduo normalizado corresponde à medida com erro, quando comparado a um limiar pré-definido para a detecção da presença de erros grosseiros (HANDSCHIN *et al.*, 1975; SCHWEPPE; WILDES, 1970). Desde que o nível de redundância seja adequado, esta propriedade será válida para o caso de erros múltiplos, procedimento este denominado

<sup>2</sup> Das iniciais em Inglês

de Identificação por Eliminação (CLEMENTS; DAVIS, 1985). Várias metodologias para o processamento de erros grosseiros foram desenvolvidos com base neste princípio, onde ciclos sucessivos de detecção, identificação e reestimação são efetuados até que todas as medidas com erros sejam eliminadas (MONTICELLI, 1999).

Outra método capaz de realizar tanto a detecção quanto a identificação de medidas portadoras de erros grosseiros é o teste- $\hat{b}$ . O método baseia-se em uma estimativa para a amplitude do erro associado à uma medida  $i$ , dada por (MONTICELLI; GARCIA, 1983):

$$\hat{\beta}_i = \frac{R_{ij}}{\Omega_{ij}} r_i^N \quad (2.25)$$

em que  $r_i^N$  é o resíduo normalizado à medida  $i$ . Uma interpretação para o valor de  $\hat{\beta}$  é o quanto o erro da medida  $i$  é discrepante das demais. O teste- $\hat{b}$  consiste em uma comparação de  $\hat{\beta}$  com um limiar dado por  $\lambda_{\hat{b}} \sqrt{R_{ij}}$ , sendo  $\lambda_{\hat{b}}$  um inteiro usualmente considerado igual a 3 (MONTICELLI, 1999). Com isso é possível concluir se o erro está fora ou não da faixa esperada de  $\pm 3R_{ij}$ .

A estimativa do erro associado à medida  $i$ , a qual possui o maior resíduo normalizado dentro do conjunto de medidas, pode ser expressa como uma magnitude do erro medida em números de desvios-padrão, e é dada por:

$$\hat{b}_i = \frac{|\hat{\beta}_i|}{R_{ij}} \quad (2.26)$$

ou ainda na forma:

$$\hat{b}_i = \frac{R_{ij}}{\sqrt{\Omega_{ij}}} |r_i^N|. \quad (2.27)$$

Neste caso, o valor calculado de  $\hat{b}$  de ser diretamente comparado com  $\lambda_{\hat{b}}$ .

## 2.6 CONCLUSÃO

A EESP é uma ferramenta fundamental para a modelagem em tempo real de sistemas elétricos e tem o objetivo de subsidiar os aplicativos que procuram garantir a segurança da operação do sistema, assim como cumprir as exigências de confiabilidade, qualidade e continuidade do suprimento da energia elétrica. A formulação do problema da Estimação de Estados pode ser realizada mediante ao tradicional critério dos Mínimos Quadrados Ponderados, o que viabiliza as melhores estimativas para as variáveis de estado do sistema com base nas medidas do plano de medição, as quais devem estar isentas de erros grosseiros. Dentre os métodos de solução destaca-se o Método da Equação Normal, que fornece soluções práticas, embora possa estar sujeito a instabilidade numérica causada pelo mau condicionamento da matriz Jacobiana.

Um importante processo que deve estar ligado à estimação de estado é a etapa da análise de medidas portadoras de erros grosseiros em que, considerando-se a existência de uma adequada redundância no plano de medição do sistema, faz-se

necessário a detecção, a identificação e a remoção de medidas espúrias. O método convencional para detecção consiste na aplicação do teste de hipóteses sobre a soma ponderada do quadrado dos resíduos, o qual permite observar indiretamente a presença ou não medidas espúrias. Posteriormente, dado que o teste de detecção seja positivo, a investigação prossegue com teste do máximo resíduo normalizado, a qual é considerado preciso e eficaz na identificação de erros grosseiros simples. Uma outra vertente de identificação de medidas espúrias é o teste- $\hat{b}$ , em que baseia-se na estimativa para o erro da medida com erro grosseiro. Entretanto, a ocorrência de erros grosseiros simultâneos podem diminuir a eficácia dos métodos.

A apresentação do embasamento teórico e matemático deste capítulo serve de ponto de partida e base de justificativas para o desenvolvimento do tema proposto nesta tese de doutorado.

### 3 TEORIA DA INFORMAÇÃO APLICADA À ESTIMAÇÃO DE ESTADOS

#### 3.1 INTRODUÇÃO

O problema de estimação de estados de sistemas elétricos de potência é tradicionalmente resolvido pelo Método dos Mínimos Quadrados Ponderados (MQP). Isto ocorre através da minimização da soma ponderada do quadrado dos resíduos o que, visto de outro modo, minimiza a variância da função densidade de probabilidade (fdp) dos resíduos das medidas. O resultado obtido é ótimo se os erros aleatórios associados às medidas pertencerem a uma distribuição Gaussiana. Entretanto, tal fato não é sempre válido. Além disso, podem ocorrer ruídos de magnitude elevada que se manifestam como erros grosseiros em medidas adquiridas do sistema SCADA. Estas medidas errôneas deterioram os resultados do estimador MQP, o que leva à necessidade de uma etapa de pós-processamento para a detecção e identificação de erros grosseiros.

Este capítulo tem por finalidade discutir uma nova alternativa de modelagem para o problema de Estimação de Estados em sistemas elétricos de potência. Esta é baseada na perspectiva da Teoria da Informação (TI), com o objetivo de maximizar a quantidade de informação que pode ser extraída das medidas disponíveis ao estimador de estados o que, dito de outro modo, implica em se minimizar as informações contidas na distribuição dos erros aleatórios. O indicador utilizado para medir a quantidade de informações disponíveis na fdp dos resíduos das medidas é a Entropia. Conseqüentemente, ao invés de se priorizar a busca da variância mínima que rege o critério dos mínimos quadrados, utilizam-se as propriedades relacionadas à Entropia da distribuição dos erros.

Outro conceito estabelecido pela TI tem por base a extensão de definições fundamentais das funções de correlação para processos aleatórios, o que conduz ao conceito de função Correntropia, a qual será elucidada neste capítulo. Devido às suas propriedades de relação de similaridade e distância entre dois vetores aleatórios, quais sejam, os vetores de medidas disponíveis e de valores estimados para as respectivas quantidades medidas, é possível se utilizar a função de Correntropia como um critério para o problema de Estimação de Estados.

A organização deste capítulo é feita da seguinte forma: a Seção 3.2 aborda os conceitos fundamentais da Teoria da Informação, e principalmente no que diz respeito às propriedades da função de correntropia e das janelas de Parzen; e na Seção 3.3 é tratada a modelagem do problema de estimação de estados sob o critério de máxima Correntropia, explicitando sua solução por uma equação matricial com reponderamento de medidas.



## 3.2 TEORIA DA INFORMAÇÃO: ASPECTOS GERAIS

A Teoria da Informação (TI) provê a base teórica utilizada nas áreas de comunicação, processamento de sinais e de aprendizagem automática<sup>1</sup>. Trabalhos recentes em TI (PRINCIPE; DONGXIN, 1999) proporcionam a substituição dos indicadores estatísticos convencionais de variância e covariância aplicadas nestas áreas pela implementação de estruturas de sistemas adaptativos não-paramétricas baseadas nos indicadores firmados por esta teoria, como a entropia definida sobre um conjunto de informações. As abordagens ditas não-paramétricas são frequentemente relacionadas com a TI, e estão diretamente ligadas à proposta de técnicas de estimação de modelos, os quais permitem que a função desconhecida, o que inclui a sua distribuição, seja estimada implicitamente a partir de um conjunto de funções. Isto é, em vez de produzir um modelo a partir dos dados observados utilizando funções que relacionam entrada e saída, os modelos não-paramétricos são resolvidos usando os próprios dados para produzir estimativas (WANG; INFELD, 2013; TONG; FURGALE; BARFOOT, 2012).

O conceito de *Entropia* da informação foi originalmente proposto por Shannon (SHANNON, 1948), e está associado à ideia de imprevisibilidade, ou noção sobre quantidade de diferentes informações em um determinado conjunto de dados. Seguindo os conceitos de Shannon, Rényi realizou uma generalização da ideia utilizando uma função exponencial (RÉNYI, 1960). Embora a entropia de Shannon seja a única que possui em todos os seus postulados as propriedades para a medida de informação, a forma da entropia de Rényi pode fornecer estimadores plausíveis para problemas reais (KAPUR, 1994).

O uso das propriedades de entropia pode ser aplicado na EESP para minimizar a entropia da estimação dos erros, com respeito às variáveis de estado. As subseções seguintes definem alguns conceitos gerais importantes.

### 3.2.1 Entropia, Correntropia e Janelas de Parzen

De forma geral, a entropia de Shannon compreende a quantidade de informação média contida em uma única observação sobre uma variável aleatória. Outras definições sobre entropia foram estabelecidas a partir dos conceitos formados por Shannon, como a Entropia de Rényi. Esta última é definida como uma “família de funções”, que são estabelecidas a partir do condicionamento de um parâmetro constante.

Uma função especial da família de equações de Rényi é a chamada entropia quadrática. No caso de uma variável aleatória  $X$  contínua, cuja fdp é  $p(x)$ , a entropia quadrática correspondente é definida como:

$$H_2(X) = -\log \left( \int_{-\infty}^{\infty} p(x)^2 dx \right) \quad (3.1)$$

<sup>1</sup> Ou aprendizado de máquina, da tradução livre o termo em Inglês *machine learning*.

No geral, expressões analíticas para a fdp são dificilmente conhecidas em problemas realísticos, e uma maneira prática de obtê-las é realizar uma aproximação da distribuição de forma não-paramétrica para a fdp a partir das amostras disponíveis. Desta forma, a técnica mais eficiente é o uso das *Janelas de Parzen* (PARZEN, 1962), que consiste em aproximar uma fdp com base em uma distribuição de dados (XU *et al.*, 1998). A aproximação é realizada mediante a soma de funções de *kernel* cujos centros são os valores de cada uma das observações (PARZEN, 1962). A função Gaussiana é adequada e comumente utilizada como a função do *kernel*, devido aos fatos de ser continuamente diferenciável e de fornecer uma simplificação computacional para os algoritmos projetados (ERDOGMUS; PRINCIPE, 2002, 2001; LIU; POKHAREL; PRINCIPE, 2006; LIU, W.; POKHAREL; PRINCIPE, 2007).

Logo, considerando-se o *kernel Gaussiano*  $G(\mu, \sigma^2)$  (substituído pela notação  $G_\sigma(\mu)$ ) de média  $\mu$  e variância  $\sigma^2$ :

$$G_\sigma(x - x_j) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[ -\frac{(x - x_j)^2}{2\sigma^2} \right], \quad (3.2)$$

a estimação de uma fdp  $\hat{p}(x)$  por meio das Janelas de Parzen a partir de um conjunto  $x_1, x_2, \dots, x_N$  de  $N$  amostras, é dado por:

$$\hat{p}(x) = \frac{1}{N} \sum_{i=1}^N G_\sigma(x - x_i) \quad (3.3)$$

Conclui-se que a Equação (3.3), que resulta em um escalar, pode ser estimada diretamente a partir das amostras, sem a necessidade da resolução de integrais, e dispondo apenas dos *kernels* Gaussianos. Esta função é utilizada a seguir para a definição de similaridade entre medidas.

Para delinear os efeitos da escolha da largura das janelas de Parzen, as figuras 3.1 e 3.2 ilustram uma representação para a forma da distribuição de uma fdp estimada com base em um conjunto de dados composto por 7 valores de erros, a saber:  $-0,55$ ,  $-0,4$ ,  $-0,15$ ,  $-0,1$ ,  $0,13$ ,  $0,14$  e  $0,25$ , em que são utilizadas diferentes larguras de *kernels* gaussianos. As figuras apresentam as formas das distribuições quando o valor da largura da janela de Parzen são de  $\sigma = 0,1$  e  $\sigma = 0,05$ , respectivamente. Pode-se notar que cada dado do conjunto é aproximado por um *Delta de Dirac*, centrado no respectivo valor do erro, e que ao seu entorno é aplicado um *kernel* gaussiano de largura  $\sigma$ . A estimação da fdp final é a média do conjunto de probabilidades. Portanto, o parâmetro  $\sigma$  define a forma da distribuição dos erros. Pode-se verificar na figura 3.1 que a distribuição apresenta uma forma mais suave do que a representada na figura 3.2.

A função *Correntropia*, também denominada de medida de correlação generalizada, é uma função que está diretamente relacionada com a entropia quadrática de Rényi e com o objetivo de se obter uma fdp mediante a técnica das Janelas de Parzen.

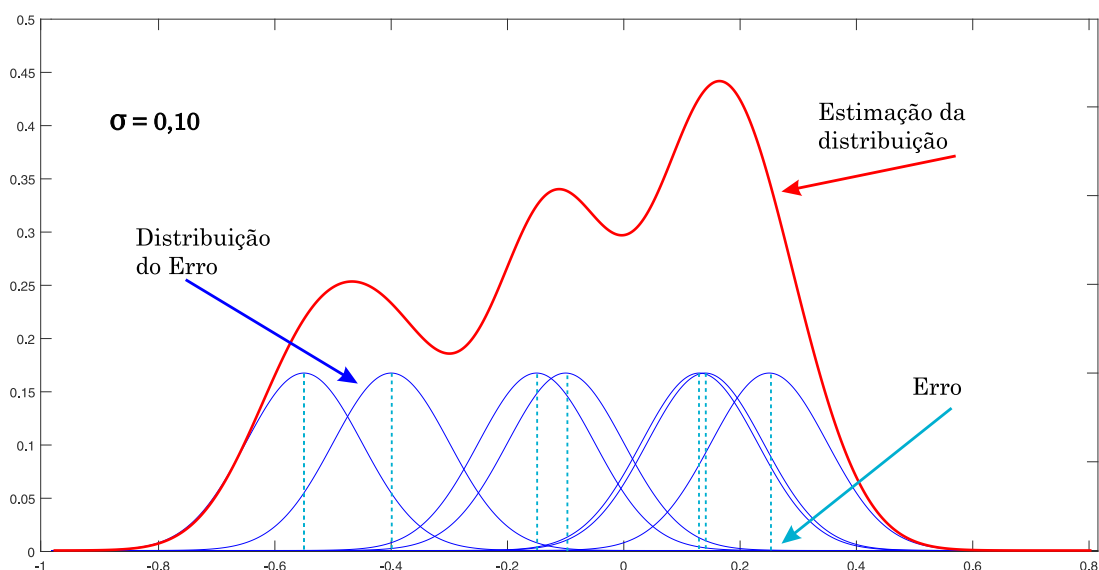


Figura 3.1 – Estimação da fdp de um conjunto de dados para um *kernel* gaussiano de largura  $\sigma = 0,1$ .

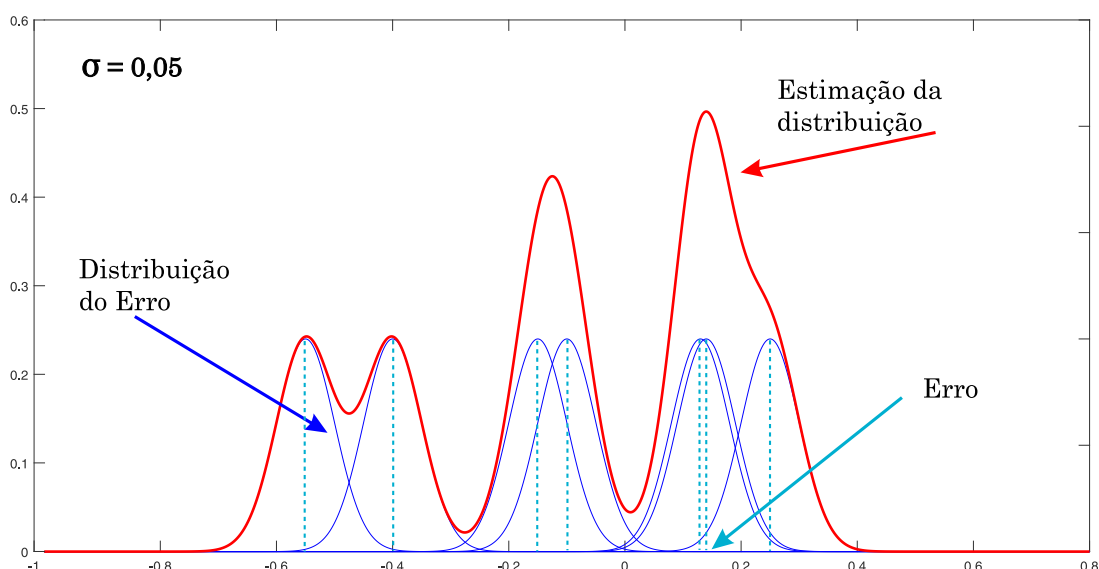


Figura 3.2 – Estimação da fdp de um conjunto de dados para um *kernel* gaussiano de largura  $\sigma = 0,05$ .

A correntropia foi inicialmente proposta em (SANTAMARIA; POKHAREL; PRINCIPE, 2006), definida através de uma conexão entre as funções de entropia e a robustez estatística de Huber. Este conceito está relacionado com a probabilidade de duas variáveis aleatórias serem semelhantes em uma vizinhança do espaço conjunto controlado pela largura de uma função *kernel*. Isto implica em que a largura da janela definida pelo *kernel* atua no controle da largura de uma “janela de observação” dentro da qual a similaridade é avaliada (LIU; POKHAREL; PRINCIPE, 2006; MIRANDA; SANTOS; PEREIRA, 2009; MIRANDA, 2013). Esta janela ajustável fornece um instrumento útil para atenuar ou eliminar o efeito perturbador de pontos discrepantes (*outliers*) (PRINCIPE; DONGXIN, 1999; SANTAMARIA; POKHAREL; PRINCIPE, 2006; ERDOGMUS;

PRINCIPE, 2002; LIU; POKHAREL; PRINCIPE, 2006; LIU; POKHAREL; PRINCIPE, Jose C., 2006; MIRANDA; SANTOS; PEREIRA, 2009; PRINCIPE, 2013; MIRANDA, 2013, 2015).

Considerando-se duas variáveis aleatórias  $X$  e  $Y$  independentes, a medida de similaridade generalizada, correntropia cruzada, ou simplesmente correntropia, é dada por (SANTAMARIA; POKHAREL; PRINCIPE, 2006; LIU; POKHAREL; PRINCIPE, 2006; LIU, W.; POKHAREL; PRINCIPE, 2007):

$$\mathcal{V}(X, Y) = E[G_\sigma(X - Y)] = \int_x \int_y G_\sigma(x - y) p_{X, Y}(x, y) dx dy \quad (3.4)$$

em que  $G_\sigma$  é o *kernel* Gaussiano em (3.2) com variância de  $\sigma^2$  e  $p_{X, Y}(x, y)$  é a função densidade de probabilidade conjunta. Na prática, a fdp conjunta  $p_{X, Y}(x, y)$  é desconhecida e apenas um número finito de dados  $(x_i, y_i)_{i=1}^N$  está disponível (LIU; POKHAREL; PRINCIPE, 2006), levando ao seguinte estimador baseado em correntropia:

$$\hat{\mathcal{V}}(X, Y) = \frac{1}{N} \sum_{i=1}^N G_\sigma(x_i - y_i) \quad (3.5)$$

Algumas observações podem ser realizadas sobre as equações (3.4) e (3.5). Quando o tamanho do *kernel* tende a zero, a função *kernel* Gaussiano torna-se um Delta de Dirac,  $\delta(x - y)$ , e a Equação (3.4) passa a ser:

$$\lim_{\sigma \rightarrow 0} \mathcal{V}(X, Y) = \int_x p_{X, Y}(x, x) dx \quad (3.6)$$

Uma estimativa para a fdp conjunta  $p_{X, Y}(x, y)$  pode ser obtida aplicando-se o método das janelas de Parzen (LIU, W.; POKHAREL; PRINCIPE, 2007):

$$\hat{p}_{X, Y}(x, y) = \frac{1}{N} \sum_{i=1}^N G_\sigma(x - x_i) G_\sigma(y - y_i) \quad (3.7)$$

É importante notar que a correntropia estimada pela integral da fdp conjunta  $\hat{p}_{X, Y}(x, y)$  ao longo da reta  $x = y$  estima a probabilidade de  $X$  ser igual a  $Y$ . Então, uma das propriedades relacionadas é que a correntropia deve ser maximizada, uma vez que este processo corresponde também à maximização da probabilidade das duas variáveis aleatórias serem iguais. Na Figura 3.3 apresenta-se o plano de soluções obtidos na condição de  $x = y$  e a fdp conjunta  $\hat{p}_{X, Y}(x, y)$ . O exemplo mostra o comportamento tridimensional da correntropia, para uma largura do *kernel*  $\sigma = 1$ , estabelecida pela integral da fdp conjunta. Nota-se que a correntropia é incapaz de avaliar a similaridade em todo o espaço conjunto, entretanto, para o conjunto de soluções fornecidos ao longo da reta  $x = y$  é possível estimar a densidade de probabilidade (LIU; POKHAREL;




Figura 3.3 – Visualização tridimensional da correntropia como a integral do espaço Gaussiano ao longo da reta  $x = y$

PRINCIPE, 2006). Pode-se verificar que a função assume seu valor máximo somente ao longo da reta  $x = y$ .

Adicionalmente, a Figura 3.4 apresenta as características da correntropia como um somatório de duas distribuições Gaussianas de média zero para largura do *kernel*  $\sigma = 1$ . Percebe-se que quanto mais as variáveis se afastam das suas médias, o valor da correntropia diminui drasticamente. Por outro lado, seu valor máximo ocorre quando a diferença entre as variáveis é nulo, o que confirma as características de máxima probabilidade conjunta para  $x = y$ , de acordo como ilustrado na figura 3.3.

Algumas propriedades importantes da correntropia são apresentadas a seguir:

1. É uma função simétrica:  $\mathcal{V}(X, Y) = \mathcal{V}(Y, X)$ ;
2. É uma função positiva e limitada, de modo que  $0 < \mathcal{V}(X, Y) < 1/\sqrt{2\pi}\sigma$ . A função atinge seu valor máximo quando  $X = Y$ ;
3. A correntropia é uma extensão da ideia de correlação, entretanto ela envolve todos os momentos de ordem par da variável aleatória  $X - Y$  (SANTAMARIA; POKHAREL; PRINCIPE, 2006). É pertinente verificar esta propriedade através da expansão de Taylor da função de correntropia em (3.4):

$$\mathcal{V}(X, Y) = \frac{1}{\sqrt{2\pi}\sigma} \sum_{n=0}^{\infty} \frac{(-1)^n}{2^n \sigma^{2n} n!} E[\|X - Y\|^{2n}] \quad (3.8)$$




Figura 3.4 – Correntropia sobre duas distribuições Gaussianas de média zero

Quando o valor de  $\sigma$  aumenta, os momentos de ordem elevada decaem rapidamente e o momento de segunda ordem tende a prevalecer, indicando que a correntropia se aproxima da correlação de  $X - Y$ . Esta constatação estabelece, sendo esta a base para relacionar o critério de máxima correntropia com o critério dos mínimos quadrados (LIU, W.; POKHAREL; PRINCIPE, 2007);

4. Assumindo que as variáveis aleatórias  $X$  e  $Y$  são estatisticamente independentes, então a probabilidade conjunta se torna:

$$p_{X,Y}(x,y) = p_X(x)p_Y(y) \tag{3.9}$$

Portanto, as probabilidades de  $\hat{p}_{X,Y}(x,y)$ ,  $\hat{p}_X(x)$  e  $\hat{p}_Y(y)$  são estimadas mediante as Janelas de Parzen conforme (3.3), tem-se que:

$$\hat{p}_{X,Y}(x,y) = \frac{1}{N} \sum_{i=1}^N G_\sigma(x-x_i) \cdot G_\sigma(y-y_i) \tag{3.10}$$

$$\hat{p}_X(x) = \frac{1}{N} \sum_{i=1}^N G_\sigma(x-x_i) \tag{3.11}$$

$$\hat{p}_Y(y) = \frac{1}{N} \sum_{i=1}^N G_\sigma(y-y_i) \tag{3.12}$$

5. Outra propriedade em que neste trabalho recebe uma atenção especial é a métrica

associada à correntropia, denominada de Métrica Induzida por Correntropia ( $CIM$ )<sup>2</sup> (LIU, W.; POKHAREL; PRINCIPE, 2007). Esta é caracterizada como uma função que computa a distância dentro de um espaço controlado por um *kernel* definido pelas Janelas de Parzen. Desta forma, sejam dois vetores  $X = (x_1, x_2, \dots, x_N)^T$  e  $Y = (y_1, y_2, \dots, y_N)^T$ ; então a  $CIM$  é estabelecida como:

$$CIM(X, Y) = [\hat{\nu}(0, 0) - \hat{\nu}(X, Y)]^{1/2} = [G_\sigma(0) - \hat{\nu}(X, Y)]^{1/2} \quad (3.13)$$

O valor obtido pela função  $CIM$ , da mesma forma que a correntropia, está associado à similaridade entre as variáveis, de modo que quanto menor for a distância  $CIM$ , maior é similaridade das duas distribuições. Além disso, a medida  $CIM$  contém todos as propriedades de uma métrica, podendo-se citar:

- Não-negatividade: de acordo com a propriedade da correntropia do *item 2*,  $CIM(X, Y) \geq 0$ ;
- Da identidade: também de acordo com *item 2*,  $CIM(X, Y) = 0$  se, e somente se,  $X = Y$ ;
- Simetria:  $CIM(X, Y) = CIM(Y, X)$ , pela propriedade do *item 1*;
- Desigualdade triangular:  $CIM(X, Z) \leq CIM(X, Y) + CIM(Y, Z)$ .

De acordo com (LIU, W.; POKHAREL; PRINCIPE, 2007), a função  $CIM$  não é homogênea, e pode induzir diferentes normas entre as amostras contidas em um espaço. A Figura 3.5 apresenta a distância  $CIM$  da variável  $X$  até a origem do espaço, isto é,  $CIM(X, 0)$ , dentro de um *kernel* Gaussiano de valor unitário ( $\sigma = 1$ ). É interessante observar que, dependendo do valor atribuído à forma da distribuição dos erros dados pelo parâmetro  $\sigma$ , verifica-se que a distância  $CIM$  pode assumir as características das normas  $L_2$ ,  $L_1$  e  $L_0$ , como indicado na Figura 3.5(a). Em outras palavras:

- Se dois pontos no espaço estiverem suficientemente próximos, a norma  $CIM$  se comporta como a norma Euclidiana ( $L_2$ );
- Após a primeira região, a  $CIM$  assume a norma  $L_1$ ;
- Se dois pontos estiverem distantes, a  $CIM$  se aproxima da norma  $L_0$ , indicando que a distância entre os vetores torna-se indiferente, mantendo um valor constante.

Verifica-se também que função  $CIM$  é controlada pela largura do *kernel* Gaussiano. Desta maneira, a distância entre dois pontos é determinada com respeito à largura do *kernel*. A Figura 3.5(b) mostra o formato tridimensional da função  $CIM$  para um *kernel* Gaussiano de  $\sigma = 1$ . Com tal característica, pode-se dizer que quanto maior o valor do *kernel*  $\sigma$ , maior é a região na qual a distância  $CIM$  se torna equivalente à distância Euclidiana (LIU, W.; POKHAREL; PRINCIPE, 2007).

<sup>2</sup> Da tradução livre do termo em Inglês *Correntropy Induced Metric*

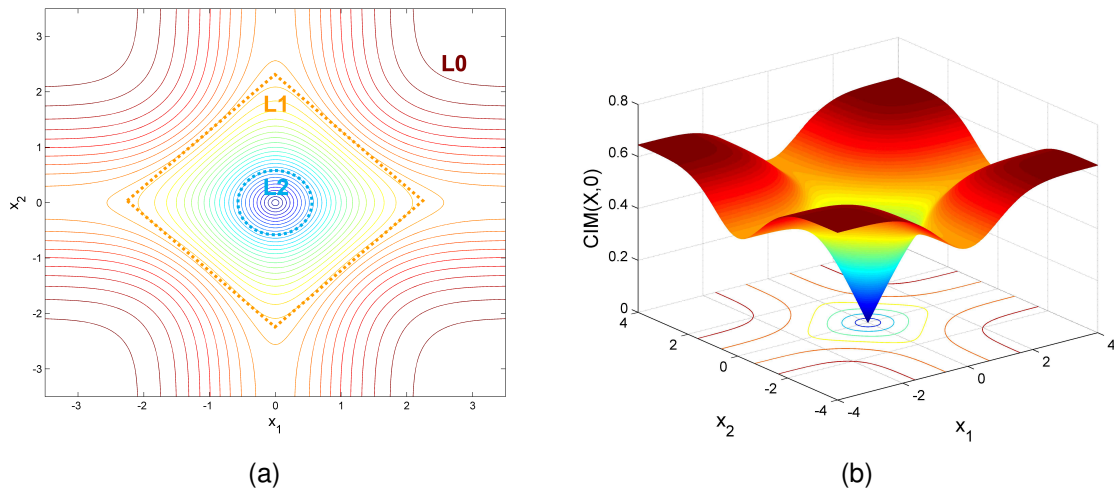


Figura 3.5 – Representação da Função  $CIM(X,0)$ : Curvas de Níveis da Função  $CIM(X,0)$ , indicando as regiões do espaço que estão sob as Normas  $L2$ ,  $L1$  e  $L0$  (a), e o Comportamento tridimensional da função  $CIM$  (b)

De maneira generalizada, a maximização da similaridade entre duas variáveis define um critério de otimização a ser aplicado em problemas realísticos, chamado de *Critério de Máxima Correntropia (MCC)* (LIU, W.; POKHAREL; PRINCIPE, 2007). Desta forma, seja o erro  $\epsilon$  uma variável aleatória em que  $\epsilon = X - Y$ , sendo  $\epsilon = \{\epsilon_i\}$ ,  $X = \{x_i\}$  e  $Y = \{y_i\}$ , com  $i = \{1, \dots, N\}$ , então a aproximação para uma fpd  $\hat{p}_\epsilon(\epsilon)$  realizada mediante as Janelas de Parzen é dada por:

$$\hat{p}_\epsilon(\epsilon) = \frac{1}{N} \sum_{i=1}^N G_\sigma(\epsilon - \epsilon_i) \quad (3.14)$$

Então,  $\hat{\nu}(X, Y)$  é o valor de  $\hat{p}_\epsilon(\epsilon)$  caracterizado no ponto  $\epsilon = x - y = 0$ . Portanto, comparando com a Equação (3.5) tem-se que:

$$\hat{\nu}(X, Y) = \hat{p}_\epsilon(0) = \frac{1}{N} \sum_{i=1}^N G_\sigma(x_i - y_i) = \frac{1}{N} \sum_{i=1}^N G_\sigma(\epsilon_i) = E[G_\sigma(\epsilon)] \quad (3.15)$$

Por conseguinte, a solução de um problema de otimização em que busca-se minimizar o erro entre duas variáveis pode ser obtida mediante a maximização da correntropia, cuja função-objetivo é dada:

$$J_{MCC}(w) = \frac{1}{N} \sum_{i=1}^N G_\sigma(\epsilon_i) \quad (3.16)$$

onde  $w$  são os parâmetros submetidos ao processo de otimização.

Considerando o critério MCC e suas propriedades citadas nesta subseção, bem como o objetivo de utilizar técnicas de TI na EESP, as próximas seções abordam a concepção da aplicação do método MCC à estimação de estados, para atender o objetivo de atenuar pontos discrepantes (*outliers*) com respeito à distribuição normal dos erros das medidas.



### 3.3 ESTIMAÇÃO DE ESTADOS SOB CRITÉRIO DE MÁXIMA CORRENTROPIA

Um estimador de estados baseado no modelo MCC é fundamentado na extração de informações de um conjunto de medidas disponíveis que formam a observação atual do sistema (MIRANDA; SANTOS; PEREIRA, 2009; KRSTULOVIC; MIRANDA *et al.*, 2013). Para alcançar tal objetivo, a aplicação da *correntropia* visa medir a similaridade generalizada entre as quantidades medidas da rede elétrica e as estimativas para as quantidades medidas com respeito às variáveis de estado. A diferença do critério descrito para o método dos mínimos quadrados ponderados é que este último quantifica a similaridade entre os dois vetores somente sob a norma  $L_2$ , isto é, a norma Euclidiana. Por esta razão, a solução via método MQP é ótima somente sob a hipótese dos erros aleatórios das quantidades medidas pertencerem à região definida pelos respectivos desvios-padrão esperados, como caracterizado na Seção 2.2.

Considerando duas variáveis aleatórias  $X$  e  $Y$  e realizando uma conexão entre o método MQP com a função de correntropia, a diferença entre os métodos está principalmente sobre os pontos muito discrepantes de  $X$  e  $Y$ , de modo que a presença destes pontos no método MQP geram grande influência sobre a solução final. De forma contrária, a métrica induzida pelo método MCC induz valores que decrescem exponencialmente, e tendem a zero à medida que em que os pontos de  $X$  e  $Y$  se afastam entre si, ou seja, tais erros são subponderados pelas normas  $L_1$  ou  $L_0$ , sendo controlados diretamente pela largura do *kernel* Gaussiano.

Esta seção aborda a aplicação do critério de máxima correntropia ao problema de estimação de estados, apresentando os aspectos de formulação matemática do problema, assim como as características de robustez face a presença de dados discrepantes.

#### 3.3.1 Formulação Matemática

Considerando o modelo de medição para rede não-linear apresentado no Capítulo 2 - Seção 2.2, a estimação de estados com base no critério MCC é estabelecida pela similaridade entre o vetor de quantidades medidas  $\mathbf{z}$  e o vetor de estimativas para as quantidades medidas  $\hat{\mathbf{z}}$ , ou seja:

$$\mathcal{V}(\mathbf{z}, \hat{\mathbf{z}}) = \frac{1}{m} \sum_{i=1}^m G_{\sigma}(z_i - h_i(\hat{\mathbf{x}})) \quad (3.17)$$

sendo  $\hat{\mathbf{z}} = \mathbf{h}(\hat{\mathbf{x}})$  e  $\hat{\mathbf{x}}$  o vetor de variáveis de estado estimadas. Consequentemente, o *kernel* Gaussiano, especificado pelo parâmetro  $\sigma$ , é definido para cada medida da seguinte forma:

$$G_{\sigma}(z_i - \hat{z}_i) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(z_i - \hat{z}_i)^2}{2\sigma^2}} \quad (3.18)$$

O processo dado pelas equações (3.17) e (3.18) pode ser entendido considerando-se que a minimização dos valores dos resíduos das medidas ocorre quando as funções de  $\mathcal{V}(\cdot)$  tendem à função Delta de Dirac, isto é, quando se busca maximizar as fdp's contínuas entre os resíduos e zero, sendo estas funções aproximadas localmente por um *kernel* Gaussiano  $G_\sigma$  (ERDOGMUS; PRINCIPE, 2002). Portanto, a função-objetivo do problema de EESP, com  $m$  medidas proveniente do sistema SCADA e que deve ser maximizada, é dada por:

$$J_{MCC}(\hat{\mathbf{x}}) = \sum_{i=1}^m R_{ii}^{-1} e^{-\frac{(z_i - h_i(\hat{\mathbf{x}}))^2}{2\sigma_i^2}} \quad (3.19)$$

onde o inverso da variância de cada medida é incluído para levar em consideração sua importância relativa, e as constantes existentes em (3.17) e (3.18) são descartadas, já que não têm nenhum efeito no processo de otimização.

A aplicação da função de correntropia da Equação (3.19) à EESP contribui com a propriedade de robustez e resiliência ao processo de estimação. Isto é caracterizado com base no ajuste iterativo das janelas de Parzen mediante a determinação dos valores de  $\sigma$ . Quando  $\sigma$  é substancialmente grande, a solução do método MCC é equivalente à solução do método MQP, como relatado na Subseção 3.2.1, pois isto corresponde a se utilizar a norma  $L2$  no problema de otimização sobre todos os resíduos. À medida que o valor de  $\sigma$  diminui progressivamente, as propriedades da correntropia são gradativamente aplicadas, principalmente sobre os resíduos de maior magnitude. O efeito resultante é aplicação de outras normas como a  $L1$  ou  $L0$  sobre estes resíduos. Se o resíduo de uma medida pertence à zona relativa às normas  $L1$  ou  $L0$ , a medida é subponderada correspondentemente ao longo do processo de otimização, reduzindo-se assim drasticamente os efeitos do erro grosseiro na solução final. Portanto, verifica-se que a largura do *kernel* Gaussiano está diretamente ligada ao desempenho da função-objetivo do modelo MCC, pois regula o impacto de cada medida na solução final da estimação. É em princípio possível se conceber estratégias nas quais um único parâmetro  $\sigma$  é empregado para todos os resíduos. Entretanto, é mais racional o uso de uma janela de Parzen pra cada uma das medidas em particular. O mecanismo de ajuste aos *kernels* Gaussianos utilizado no curso do processo de otimização será abordado no Capítulo 4.

Com o objetivo de maximizar a função Correntropia descrita em (3.19), aplica-se a condição de otimalidade de primeira ordem:

$$\nabla J_{MCC} = \sum_{i=1}^m \frac{R_{ii}^{-1}}{\sigma^2} [z_i - h_i(\hat{\mathbf{x}})] e^{-\frac{[z_i - h_i(\hat{\mathbf{x}})]^2}{2\sigma^2}} \frac{\partial h_i(\mathbf{x})}{\partial \mathbf{x}} = 0 \quad (3.20)$$

Com a descrição na forma vetorial, a Equação (3.20) passa a ser:

$$\nabla J_{MCC} = \mathbf{H}^T \mathbf{D} \Delta \mathbf{z} = \mathbf{0} \quad (3.21)$$

onde  $\mathbf{H}$  é a matriz Jacobiana  $m \times n$  de  $\mathbf{h}(\cdot)$  computada no ponto  $\mathbf{x}^k$ ,  $\Delta \mathbf{z} = \mathbf{z} - \mathbf{h}(\hat{\mathbf{x}}^k)$  o vetor  $m \times 1$  de medidas incrementais e  $\mathbf{D}$  uma matriz diagonal  $m \times m$  com o  $i$ -ésimo elemento da diagonal definido como:

$$D_{ii} = \frac{R_{ii}^{-1}}{\sigma^2} e^{-\frac{[z_i - h_i(\hat{\mathbf{x}}^k)]^2}{2\sigma^2}} \quad (3.22)$$

Aplicando a condição de otimalidade de segunda ordem, tem-se que:

$$\begin{aligned} \nabla^2 J_{MCC} = & \frac{1}{\sigma^2} \sum_{i=1}^m \left[ -\frac{R_{ii}^{-1}}{\sigma^2} (1 - [z_i - h_i(\hat{\mathbf{x}}^k)]^2) \right] e^{-\frac{[z_i - h_i(\hat{\mathbf{x}}^k)]^2}{2\sigma^2}} \left( \frac{\partial h_i(\mathbf{x})}{\partial \mathbf{x}} \right)^2 \\ & + \frac{1}{\sigma^2} \sum_{i=1}^m \left[ R_{ii}^{-1} [z_i - h_i(\hat{\mathbf{x}}^k)] e^{-\frac{[z_i - h_i(\hat{\mathbf{x}}^k)]^2}{2\sigma^2}} \frac{\partial^2 h_i(\mathbf{x})}{\partial \mathbf{x}^2} \right] \end{aligned} \quad (3.23)$$

Desconsiderado o termo que contém a segunda derivada de  $\mathbf{h}(\cdot)$ , a forma matricial correspondente à matriz Hessiana em (3.23) equivale a:

$$\nabla^2 J_{MCC} = -\mathbf{G}_{MCC} = -\mathbf{H}^T \mathbf{D} [\mathbf{I} - \mathbf{R}_W] \mathbf{H} \quad (3.24)$$

sendo  $\mathbf{G}_{MCC}$  a matriz ganho  $n \times n$  modificada,  $\mathbf{I}$  a matriz identidade  $m \times m$  e  $\mathbf{R}_W$  uma matriz diagonal  $m \times m$  cujos elementos são dados por:

$$R_{W,ii} = \frac{1}{\sigma^2} [z_i - h_i(\hat{\mathbf{x}}^k)]^2 \quad (3.25)$$

As simplificações realizadas nas equações (3.21) a (3.24) levam à formação do sistema matricial de equações não-lineares no formato  $\mathbf{A}\mathbf{x} = \mathbf{b}$ , a ser resolvido a cada iteração para a determinação do vetor de estados incrementais  $\Delta \mathbf{x}$ , que apresenta forma semelhante ao método clássico de Gauss-Newton:

$$\mathbf{G}_{MCC} \cdot \Delta \mathbf{x} = \mathbf{H}^T \mathbf{W} \Delta \tilde{\mathbf{z}} \quad (3.26)$$

em que

$$\mathbf{W} = \mathbf{D} [\mathbf{I} - \mathbf{R}_W] \quad (3.27)$$

$$\Delta \tilde{\mathbf{z}} = [\mathbf{I} - \mathbf{R}_P]^{-1} \Delta \mathbf{z} \quad (3.28)$$

Desta forma, o vetor de estados estimados é atualizado a cada iteração conforme (3.29) a partir dos incrementos calculados em (3.26), até que a norma infinita de  $\Delta \mathbf{x}$  seja menor que uma tolerância pré-especificada.

$$\hat{\mathbf{x}}^{k+1} = \hat{\mathbf{x}}^k + \Delta \mathbf{x}. \quad (3.29)$$

Diferentemente do que ocorre no método MQP, em que os fatores de ponderação sobre as medidas são contantes, o método MCC requer que a matriz  $\mathbf{W}$  na

Equação (3.27) seja atualizada dinamicamente ao longo das iterações em função da largura das janelas de Parzen, como indicado nas Equações (3.22) e (3.25). A realização deste procedimento é importante para implementação do critério MCC, que recai na estratégia de ajuste da largura dos *kernels* Gaussianos para cada dado processado. Outro relevante aspecto a ser mencionado é a necessidade de manter a matriz  $\mathbf{W}$  positiva-definida ao longo das iterações. Isto requer o monitoramento contínuo dos elementos contidos em sua diagonal no processo de estimação de estados para garantir que

$$\mathbf{W} > \mathbf{0}. \quad (3.30)$$

Na presença de medidas portadoras de erros grosseiros, cujos resíduos atingem valores significativamente grandes, e ainda face à redução da largura do *kernel*  $\sigma$ , esta condição pode deixar de ser numericamente satisfeita. Para contornar esta dificuldade, os valores diagonais de  $\mathbf{W}$  que violam a condição de positividade são ajustados como:

$$W_{jj} = D_{jj}(1 - R_{W, jj}) = \eta \quad (3.31)$$

em que  $\eta$  é um número real, positivo e pequeno<sup>3</sup>.

Pode ser também mencionado que outras classes de estimadores, como a dos *M-estimators*, visando melhorar a robustez estatística e identificar pontos de alavancamento, foram previamente propostas na literatura de estimação de estados (PIRES; SIMÕES COSTA; MILI, 1999). Além de também destes métodos serem baseados em uma função-objetivo não quadrática, eles compartilham com estimador MCC a forma de como sua solução iterativa é obtida, uma vez que ambos dependem de uma versão dinâmica da matriz de ponderação da equação normal. Enquanto em (PIRES; SIMÕES COSTA; MILI, 1999) os pesos de medição variam em função das projeções estatística dos pontos de dados, no estimador MCC são atualizados de acordo com os valores atuais da largura do *kernel* Gaussiano.

### 3.4 CONCLUSÃO

A utilização da Teoria da Informação (TI) na estimação de estados tem o objetivo de extrair o máximo de informações que estão presentes nas medidas disponíveis para se obter estimativas para as variáveis de estado consistentes com a operação atual da rede elétrica. Esta extração de informações pode ser realizada mediante a determinação da similaridade generalizada entre os vetores das quantidades medidas e estimativas para as quantidades medidas, definida com base no Critério de Máxima Correntropia (MCC). Esta função empresta propriedades de resiliência ao processo de estimação de estados, no sentido de que este é capaz de fornecer estimativas de boa qualidade mesmo na presença de medidas portadoras de erros grosseiros.

<sup>3</sup> Neste trabalho, faz-se  $\eta = 1 \times 10^{-3}$ .

O uso da função de Correntropia induz a métrica  $CIM$ , a qual estabelece a distância entre dois vetores aleatórios, sendo computada de acordo com a largura das janelas de Parzen. Desta forma, diferentemente ao que ocorre com o critério dos Mínimos Quadrados Ponderados, cuja medida de similaridade é dada somente em termos da distância Euclidiana (norma  $L_2$ ), a função correntropia aplica sobre os resíduos das medidas as normas  $L_2$ ,  $L_1$  ou  $L_0$ , de acordo com a magnitude dos resíduos computados. Isto significa que, se a diferença entre os valores das medidas provenientes da rede elétrica e seus valores estimados for pequena, ocorre atuação da norma Euclidiana, e o modelo MCC equivale ao MQP. Entretanto, se tal diferença estiver dentro da zona da norma  $L_0$ , seus efeitos passam a ser desconsiderados pelo estimador de estados, ou seja os respectivos erros de grande magnitude são vistos como erros grosseiros.

A métrica  $CIM$ , e conseqüentemente o critério MCC, permite ainda correlacionar outras informações incluídas ao processo de estimação de estados, como as informações de estado *a priori*, a partir da sua modelagem sob o critério de máxima correntropia. Este será abordado neste trabalho nos capítulos seguintes.

Em resumo, conclui-se que um estimador de estados baseado no critério MCC contém no próprio processo de estimação todas as funções características normalmente associadas a um estimador de estados em sistemas de potência, isto é, o processamento de medidas da rede elétrica e a detecção, identificação e eliminação de erros grosseiros, sem que seja necessário qualquer tipo de estágio de pós-processamento e re-processamento.

A implementação deste modelo por meio de uma equação análoga à Equação Normal torna mais simples a comparação do método MCC com o método MQP. Entretanto, as matrizes de informação e de ponderação do método MCC agora são dinamicamente atualizadas no curso das iterações de acordo com as propriedades da correntropia, o que facilita a utilização de outras técnicas para a resolução do problema. Uma delas, particularmente atraente neste contexto, é a baseada em algoritmos ortogonais, como as rotações de Givens, por suas propriedades de robustez numérica. A solução do estimador baseado no MCC mediante métodos ortogonais será tratada no capítulo seguinte.

## 4 ALGORITMO ORTOGONAL E CRITÉRIO DE MÁXIMA CORRENTROPIA NA ESTIMAÇÃO ROBUSTA DE ESTADOS

### 4.1 INTRODUÇÃO

De acordo com a proposta do capítulo anterior, a utilização do critério MCC para a resolução do problema de estimação de estados surge como um método robusto e dotado de características de resiliência perante a presença de medidas portadoras de erros grosseiros. Desta forma, o processo de maximização da função de correntropia é realizada mediante a aplicação do método de Gauss-Newton estendido para considerar o ajuste dinâmico das Janelas de Parzen. Entretanto, a solução obtida por este método pode ser afetada principalmente pelo mau condicionamento numérico na formação da matriz ganho em termos de correntropia ou matriz ganho modificada. De modo geral, os problemas numéricos surgem devido à precisão finita das variáveis em ponto flutuante, utilizadas pelas ferramentas computacionais para armazenar valores numéricos. No MCC, as medidas estão sujeitas a ponderações bastante distintas entre si, o que é um conhecido fator que pode conduzir à instabilidade numérica do método da equação normal (HOLTEN *et al.*, 1988). Outras técnicas de resolução do método MCC, como o uso de artifícios de redes neurais auto-associativas, implementados em (MIRANDA; SANTOS; PEREIRA, 2009; KRSTULOVIC; MIRANDA *et al.*, 2013; KRSTULOVIC; MIRANDA, 2015) não são susceptíveis a problemas desta natureza.

Este trabalho propõe a concepção de um estimador de estados para sistemas de potência com base no Critério de Máxima Correntropia, cuja solução é obtida mediante a implementação de um algoritmo ortogonal baseado na versão rápida das Rotações de Givens, com a finalidade de garantir a robustez numérica na solução do problema proposto, propriedade esta que assim se associa às propriedades de resiliência face à presença de erros grosseiros (FREITAS; SIMÕES COSTA; MIRANDA, 2020).

O tópico apresentado neste capítulo é uma das contribuições desta tese de doutorado. O capítulo inicia pela descrição das principais propriedades desejáveis do método ortogonal-sequencial a ser utilizado, na Seção 4.2. As Seções 4.3 e 4.4 abordam as equações básicas das rotações de Givens com quatro e três multiplicadores e os processos que envolvem as rotações elementares do método, respectivamente. A Seção 4.5 discute as facilidades do processamento de erros grosseiros a partir da utilização método ortogonal. A metodologia para ajustar as janelas de Parzen visando o tratamento de medidas espúrias é apresentada na Seção 4.6. As Seções 4.7 e 4.8 apresentam, respectivamente, o algoritmo do estimador MCC de estados proposto e a aplicação do método a um sistema-teste de pequeno porte. Por fim, uma avaliação qualitativa e quantitativa dos métodos de solução de estimação MCC com respeito ao condicionamento numérico é abordada na Seção 4.9.

## 4.2 MÉTODO ORTOGONAL-SEQUENCIAL

A utilização de métodos ortogonais na resolução de sistemas de equações onde a matriz de informação tende a ser numericamente mal-condicionada é apresentada em (GENTLEMAN, 1973). A aplicação deste método em problemas de estimação de estados, baseado no algoritmo da versão rápida das Rotações de Givens e visando sistemas elétricos de potência, é tratada em (SIMÕES COSTA; QUINTANA, 1981b,a; VEMPATI; SLUTSKER; TINNEY, 1991) como uma alternativa de melhorar o desempenho numérico dos estimadores de estados modelados de acordo com o tradicional Método dos Mínimos Quadrados Ponderados.

Algumas das principais vantagens decorrentes da utilização dos métodos ortogonais são descritos a seguir (GENTLEMAN, 1973; HAMMARLING, 1974; KUGA, 1982; WANG; QUINTANA, 1984):

- O número de condicionamento numérico das matrizes ortogonais é unitário, que é a melhor condição numérica possível. Por esta razão, torna-se vantajosa a aplicação das matrizes ortogonais;
- Não é necessário o cálculo explícito da matriz de informação, ou ganho, seja ela determinada pelos aspectos do método MQP ou MCC. Ou seja, o produto matricial do lado esquerdo das equações (2.18) e (3.26), descritos nos capítulos anteriores, deixa de ser explicitamente computado, e assim o número de condicionamento do problema não é deteriorado;
- Os métodos ortogonais-sequenciais trabalham com a estrutura do problema de EESP por linhas, processando as medidas em sequência, em geral uma de cada vez. Desta forma, este tipo de processamento por linhas tende a apresentar melhor desempenho que as variantes que operam por coluna (GOUVÊA; SIMÕES COSTA, 1998; SIMÕES COSTA; GOUVÊA, 2000).

As características numéricas citadas são amplamente exploradas pelo método MCC para o processo de estimação de estados, que será descrito a seguir. Outro atrativo decorrente do método ortogonal refere-se ao processo de identificação e eliminação de medidas portadoras de erros grosseiros pela maximização da correntropia. Algumas características básicas inerentes à formulação do método ortogonal para o problema considerado são melhor esclarecidas a seguir.

## 4.3 EQUAÇÕES BÁSICAS DO MÉTODO ORTOGONAL DAS ROTAÇÕES DE GIVENS

Seja um sistema linear  $\mathbf{A} \cdot \Delta \mathbf{x} = \Delta \mathbf{y}$ , sendo  $\mathbf{A}$  uma matriz  $m \times n$ ,  $m > n$ , e  $\Delta \mathbf{y}$  um vetor  $m \times 1$ , a ser resolvido mediante transformações ortogonais. Com base nas pro-

priedades de uma matriz ortogonal  $\mathbf{Q}$ , definida como  $\mathbf{Q}^T \mathbf{Q} = \mathbf{Q} \mathbf{Q}^T = \mathbf{I}$ , sendo  $\mathbf{I}$  a matriz identidade, e na preservação da norma Euclidiana de um vetor ao qual é aplicada uma matriz ortogonal, isto é,  $\|\mathbf{Q} \cdot \mathbf{y}\| = \|\mathbf{y}\|$ , é possível estabelecer as seguintes equações (GENTLEMAN, 1973; SIMÕES COSTA; QUINTANA, 1981b,a):

$$\|\mathbf{Q} \cdot (\mathbf{A} \cdot \Delta \mathbf{x})\| = \|\mathbf{A} \cdot \Delta \mathbf{x}\| \quad (4.1)$$

$$\|\mathbf{Q} \cdot (\Delta \mathbf{y})\| = \|\Delta \mathbf{y}\| \quad (4.2)$$

Seja  $\mathbf{Q}$  definida como uma sequência de rotações elementares de Givens de forma a triangularizar a matriz de coeficientes  $\mathbf{A}$ , isto é,  $\mathbf{Q} \cdot \mathbf{A} = \mathcal{P}$  e  $\mathbf{Q} \cdot \Delta \mathbf{y} = \mathcal{P} \mathbf{y}$ , em que:

$$\mathcal{P} = \begin{bmatrix} \bar{\mathbf{U}} \\ \mathbf{0} \end{bmatrix} \quad (4.3a)$$

$$\mathcal{P} \mathbf{y} = \begin{bmatrix} \Delta \mathbf{y}' \\ \Delta \mathbf{y}'' \end{bmatrix} \quad (4.3b)$$

onde  $\bar{\mathbf{U}}$  é uma matriz triangular superior de dimensão  $n \times n$ , e  $\mathbf{0}$  uma matriz nula de ordem  $(m-n) \times n$ . Similarmente, os vetores  $\Delta \mathbf{y}'$  e  $\Delta \mathbf{y}''$  possuem dimensão  $n \times 1$  e  $(m-n) \times 1$ , respectivamente. Com as transformações realizadas em (4.3), verifica-se que a solução do sistema linear pode ser obtida através de substituição inversa aplicada ao sistema:

$$\bar{\mathbf{U}} \Delta \mathbf{x} = \Delta \mathbf{y}' \quad (4.4)$$

Um aparente obstáculo para aplicar as rotações de Givens sem raízes quadradas (GENTLEMAN, 1973) aos estimadores MCC é que tal estratégia de solução é particularmente eficiente para resolver sistemas sobredeterminados de equações lineares usando os princípios dos mínimos quadrados *ponderados*. Com o objetivo de superar tal obstáculo, note que a Equação (3.26) pode ser visualizada como a solução de um problema de mínimos quadrados ponderados que recai no seguinte modelo adaptado de medida:

$$\begin{aligned} \Delta \tilde{\mathbf{z}} &= \mathbf{H} \Delta \mathbf{x} + \boldsymbol{\varepsilon} \\ E\{\boldsymbol{\varepsilon}\} &= \mathbf{0} \quad ; \quad E\{\boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^T\} = \mathbf{S} \end{aligned} \quad (4.5)$$

onde  $\mathbf{S} = \mathbf{W}^{-1}$ . Com base na Equação (4.5), o seguinte problema MQP equivalente pode ser formulado:

$$\min_{\Delta \mathbf{x}} J_{MCC}(\Delta \mathbf{x}) = (\Delta \tilde{\mathbf{z}} - \mathbf{H} \Delta \mathbf{x})^T \mathbf{W} (\Delta \tilde{\mathbf{z}} - \mathbf{H} \Delta \mathbf{x}) \quad (4.6)$$

É possível notar que a solução do Problema (4.6) é fornecida através da Equação (3.26), e portanto, pode ser estabelecida uma semelhança entre o Problema (3.19) e a formulação em (4.6). Em outras palavras, resolver o problema de estimação de estados considerando o critério de máxima correntropia descrito na Equação (3.19) equivale a resolver o Problema (4.6).



### 4.3.1 Versão com Três Multiplicadores das Rotações de Givens

A solução do estimador MCC no Problema (4.6) é obtida mediante a aplicação do algoritmo baseado nas rotações de Givens, utilizando a versão com três multiplicadores e denominada de *G3M*, ao invés de resolver a Equação (3.26), a qual é similar à Equação Normal. Para delinear o método proposto neste trabalho, sucessivas rotações ortogonais devem ser aplicadas à matriz Jacobiana  $\mathbf{H}$ , ampliada com uma coluna extra cujos elementos são os valores do vetor  $\Delta\tilde{\mathbf{z}}$ . Portanto, o processamento ortogonal descrito pelas equações (4.1) a (4.4) para resolver o problema (4.6) fica da seguinte forma:

$$\mathbf{Q} \left( \mathbf{W}^{\frac{1}{2}} [\mathbf{H} \mid \Delta\tilde{\mathbf{z}}] \right) = [\bar{\mathbf{U}} \mid \bar{\mathbf{c}}] \quad (4.7)$$

em que  $\mathbf{W}$  é o produto matricial definido na Equação (3.27),  $\Delta\tilde{\mathbf{z}}$  é o vetor de medidas incrementais cujos elementos são ponderados por um fator estabelecido em função do modelo de correntropia (ver Equação (3.28)), e  $\mathbf{Q}$  é a matriz ortogonal,  $\bar{\mathbf{U}}$  uma matriz triangular superior  $n \times n$ , e  $\bar{\mathbf{c}}$  um vetor  $n \times 1$  (GENTLEMAN, 1973).

A utilização da abordagem original das rotações de Givens da Equação (4.7), entretanto, requer o cálculo de raízes quadradas e quatro multiplicações por rotação elementar, o que tem um impacto negativo no desempenho computacional do método (SIMÕES COSTA; QUINTANA, 1981b; GENTLEMAN, 1973). Um esquema mais eficiente que elimina a realização do cálculo de raízes quadradas e reduz o número de multiplicações elementares é obtido pela decomposição da matriz do lado direito da Equação (4.7) de forma (GENTLEMAN, 1973):

$$[\bar{\mathbf{U}} \mid \bar{\mathbf{c}}] = \mathbf{T}^{\frac{1}{2}} [\mathbf{U} \mid \mathbf{c}] \quad (4.8)$$

onde  $\mathbf{T}$  é uma matriz diagonal de pesos,  $\mathbf{U}$  é uma matriz triangular superior cujos elementos da diagonal são iguais a 1, e  $\mathbf{c}$  é a versão escalonada do vetor  $\bar{\mathbf{c}}$ . A inclusão dos fatores de escala para as linhas da matriz  $\mathbf{U}$  é o artifício principal que evita o cálculo de raízes quadradas durante as fatorações na Equação (4.7) (SIMÕES COSTA; QUINTANA, 1981b; GENTLEMAN, 1973). Após o processamento de todas as medidas a partir da Equação (4.8), a solução do estimador MCC é computada por substituição inversa, e sendo o vetor  $\mathbf{c}$  do lado direito da equação resultante das transformações ortogonais aplicadas aos vetor  $\Delta\tilde{\mathbf{z}}$ , tem-se que:

$$\mathbf{U}\Delta\mathbf{x} = \mathbf{c} \quad (4.9)$$

## 4.4 ROTAÇÕES ELEMENTARES EM FUNÇÃO DE CORRENTROPIA

Esta seção descreve as rotações elementares que compõem a matriz de transformação  $\mathbf{Q}$  da Equação (4.7). Como relatado anteriormente, assume-se que os fatores de escala, ou simplesmente pesos, são atribuídos individualmente para medidas e

para as linhas da matriz triangular superior unitária  $\mathbf{U}$ . Deve-se notar que os fatores de escala especificados para cada medida variam de acordo com a estratégia de reponderação, com base no valor da largura da Janela de Parzen, conforme as Equações (3.22), (3.25) e (3.27).

Cada equação de medição composta por uma linha  $\mathbf{h}$  da matriz  $\mathbf{H}$ , aumentada pelo correspondente elemento do vetor  $\Delta\tilde{\mathbf{z}}$ , deve passar por rotações sequenciais com as linhas da matriz  $\mathbf{U}$ . Em um dado estágio do processo de transformações ortogonais, seja  $\mathbf{u}$  a  $i$ -ésima linha de  $\mathbf{U}$  em que a linha  $\mathbf{h}$  da matriz Jacobiana aumentada deve ser rotacionada:

$$\begin{aligned}\mathbf{u} &= [0 \ \dots \ 0 \ 1 \ u_{i+1} \ \dots \ u_n \ | \ u_{n+1}] \\ \mathbf{h} &= [0 \ \dots \ 0 \ h_i \ h_{i+1} \ \dots \ h_n \ | \ h_{n+1}]\end{aligned}\quad (4.10)$$

Deve-se notar que o vetor  $\mathbf{u}$  é aumentado pela correspondente entrada do vetor  $\mathbf{c}$ . O vetor  $\mathbf{h}(\mathbf{x})$  representa a nova linha  $j$  da matriz Jacobiana a ser processada, cuja entrada  $h_{n+1}$  corresponde ao elemento  $\Delta\tilde{z}_j$ . De acordo com a Equação (4.7), assume-se que um peso  $\sqrt{w}$  é atribuído à nova medida a ser processada. Da mesma forma, um peso  $\sqrt{t}$  deve ser atribuído à linha  $\mathbf{u}$  da matriz triangular, como descrito na Equação (4.8). A próxima rotação entre  $\mathbf{h}$  e  $\mathbf{u}$  visa zerar o  $i$ -ésimo elemento de  $\mathbf{h}$ . Após a aplicação desta rotação elementar tem-se:

$$\begin{aligned}\mathbf{u}' &= [0 \ \dots \ 0 \ 1 \ u'_{i+1} \ \dots \ u'_n \ | \ u'_{n+1}] \\ \mathbf{h}' &= [0 \ \dots \ 0 \ 0 \ h'_{i+1} \ \dots \ h'_n \ | \ h'_{n+1}]\end{aligned}\quad (4.11)$$

Para realizar a rotação acima de modo a zerar o elemento  $h_i$ , a matriz de transformações ortogonais  $\mathbf{Q}$  deve ser dada por (GENTLEMAN, 1973; SIMÕES COSTA; QUINTANA, 1981b,a):

$$\mathbf{Q} = \begin{bmatrix} \tau & v \\ -h_i & 1 \end{bmatrix}\quad (4.12)$$

sendo  $\tau$  e  $v$  os parâmetros que definem cada rotação elementar. Pela condição imposta que  $h'_i = 0$ , pode-se determinar as equações que definem as relações entre os elementos originais e as transformações de  $\mathbf{u}$  e  $\mathbf{h}$ :

$$t' = t + wh_i^2 \quad (4.13a)$$

$$w' = \frac{tw}{t'} \quad (4.13b)$$

$$\tau = \frac{t}{t'} \quad (4.13c)$$

$$v = \frac{wh_i}{t'} \quad (4.13d)$$

$$\left. \begin{aligned} h'_k &= h_k - h_i u_k \\ u'_k &= \tau u_k + v h_i \end{aligned} \right\}, \quad k = i+1, \dots, n+1 \quad (4.14)$$

A coluna  $n+1$  dos vetores  $\mathbf{u}'$  e  $\mathbf{h}'$  representa as informações dos valores das medidas, que são rotacionadas juntamente com as linhas da matriz de observação.

As equações em (4.13) indicam que os fatores  $\tau$  e  $\nu$  variam em consequência da rotação, assim como as linhas de  $\mathbf{U}$  e os elementos da diagonal da matriz  $\mathbf{T}$ . O artifício de escalonamento torna-se atrativo pelo fato de evitar o cálculo das raízes quadradas implícitas na Equação (4.7). Além disso, na prática  $\mathbf{T}^{\frac{1}{2}}$  também não precisa ser calculado, pois apenas os valores em  $\mathbf{T}$  são efetivamente utilizados.

Após todos os elementos da linha  $\mathbf{h}$  serem rotacionados com as linhas correspondentes com a matriz  $\mathbf{U}$ , os elementos de uma linha subsequente (ou medida) também serão rotacionados de forma similar. O processo continua até que todas as linhas aumentadas de  $\mathbf{H}$  sejam rotacionadas. No princípio do processo,  $\mathbf{T}$  e  $\mathbf{U}$  são inicializadas como matriz nula e identidade, respectivamente, enquanto os pesos  $w$  para cada linha são inicializados com os correspondentes valores da matriz diagonal  $\mathbf{W}$ , calculada como detalhado na Equação (3.27). As linhas de  $[\mathbf{H} \mid \Delta\tilde{\mathbf{z}}]$  são sequencialmente processadas, os elementos de  $\mathbf{T}$  e  $\mathbf{U}$  são atualizados através das Equações (4.13) e (4.14).

#### 4.5 PROCESSAMENTO DE ERROS GROSSEIROS ATRAVÉS DAS ROTAÇÕES DE GIVENS

Um das qualidades que o algoritmo G3M aporta para a resolução do método MCC é a facilidade com que os pesos de  $\mathbf{W}$  são introduzidos nas transformações. O valor  $w = W_{ij}$  inicialmente atribuído a uma medida  $i$  depende do valor da largura do *kernel* Gaussiano, que diminui no decorrer do processo de otimização. Como cada medida é processada de cada vez, o valor do peso  $w$  pode ser prontamente verificado. Quando este valor se torna menor do que um determinado limiar, evita-se a execução de novas rotações associadas à medida  $i$ . Isto é justificado de acordo com o modelo de correntropia: o resíduo da medida  $i$  tornou-se grande o suficiente comparado com o seu respectivo *kernel* Gaussiano para que ela seja identificada como *outlier*, e portanto a medida  $i$  não deve contribuir para o processo de estimação de estados. Em outras palavras, o natural processamento sequencial das medidas facilita amplamente a implementação dos princípios da janela de Parzen.

Uma segunda observação referente ao uso da técnica das rotações de Givens é a propriedade de reprocessamento de medidas (SIMÕES COSTA; QUINTANA, 1981b; GENTLEMAN, 1973). Ainda em conexão com o tratamento de erros grosseiros via janelas de Parzen, é possível que uma medida anteriormente eliminada seja considerada como medida válida em uma iteração subsequente; logo, a atualização do peso  $w$  relacionado a esta medida se torna maior que um dado limiar positivo. Neste caso, não há nenhuma dificuldade para o reprocessamento da medida através das rotações de Givens com o novo valor de peso.

Finalmente, as propriedades de robustez numérica associada às rotações ortogonais garantem soluções viáveis mesmo na presença de fatores de ponderação com diferentes amplitudes que podem surgir com a aplicação dos conceitos das janelas de Parzen.

#### 4.6 ESTRATÉGIA DE AJUSTE DAS JANELAS DE PARZEN

Como abordado preliminarmente na subseção 3.2.1, os efeitos da aplicação das propriedades da correntropia são controlados com base nos ajustes das Janelas de Parzen, isto é, na largura do *kernel* Gaussiano. No processo de estimação de estados, a largura do *kernel* Gaussiano tem por objetivo quantificar a similaridade entre os vetores das quantidades medidas e estimadas, e conseqüentemente de atribuir um peso para cada medida de acordo com as propriedades da correntropia. Em resumo, o tamanho das janelas de Parzen regula diretamente o nível de atenuação de eventuais erros de grande magnitude presente nas medidas, que assim não afetarão a solução final.

Para suprimir os erros grosseiros do processo de otimização apresentado na Equação (3.19), o valor da largura das janelas de Parzen,  $\sigma$ , deve decrescer até o suposto nível esperado do ruído Gaussiano admitido pelo modelo de medição. Para tal, o algoritmo deve ser inicializado com um valor de  $\sigma^0$  que torne as janelas de Parzen suficientemente grandes para abranger todos os ruídos Gaussianos das medidas. Os ajustes introduzidos na largura das janelas de Parzen ao longo das iterações reduzem o valor de  $\sigma$  de modo a rejeitar o efeito de possíveis erros grosseiros presentes nas medidas submetidas ao estimador.

Para considerar as particularidades de cada medida, diferentes *kernels* Gaussianos são aplicados ao processo de otimização. A aplicação deste procedimento pode levar em conta a importância individual dos dados de medição sobre a estimação de estados, que depende do tipo de medida, da classe de exatidão, localização no sistema, redundância local, etc.

A alternativa descrita neste trabalho para o ajuste iterativo das janelas de Parzen faz o uso do valor atual do máximo resíduo normalizado. A estimação das magnitudes dos erros pelo teste- $\hat{b}$  (MONTICELLI, 1999; ABUR; GOMEZ EXPOSITO, 2004) é também empregada para prevenir a redução excessiva das janelas, pois isto pode ocasionar a ocorrência de falsos positivos, isto é, a identificação como errônea de uma medida que não está contaminada por erro grosseiro.

De modo a implementar os procedimentos acima, o produto do desvio-padrão de cada resíduo  $i$ , computado a partir da matriz de covariância dos resíduos  $\Omega$ , conforme a Equação (2.22) (MONTICELLI, 1999), e ponderados pelo máximo resíduo normalizado do conjunto de medidas, fornece a nova largura do *kernel* Gaussiano da medida  $i$  para

$(k + 1)$ -ésima iteração, conforme:

$$\sigma_i^{(k+1)} = \sqrt{\Omega_{ii}} \cdot \max_j \left( \frac{|r_j|}{\sqrt{\Omega_{jj}}} \right), \quad i, j \in \{1, \dots, m\} \setminus \mathcal{S}^k \quad (4.15)$$

em que  $\mathcal{S}^k$  é o conjunto de índices das medidas suspeitas, determinadas na iteração atual, que é inicializado como conjunto vazio  $\mathcal{S} = \phi$ . Na Equação (4.15) o símbolo “\” significa a diferença de conjuntos. É importante ressaltar que o conceito de resíduo normalizado é utilizado neste trabalho para a normalização das janelas de Parzen com o objetivo de suprimir os efeitos da presença de medidas espúrias dentro do processo iterativo, ao invés da utilização propriamente dita do método do máximo resíduo normalizado como etapa de pós-processamento, descrito no Capítulo 2, Seção 2.5.

Se o resíduo absoluto  $|r_j| < \sigma_j$ , a medida  $z_j$  é caracterizada como uma medida válida, e portanto sua janela de Parzen é atualizada apropriadamente de acordo com a Equação (4.15). Por outro lado, aquelas medidas cujo resíduo absoluto  $|r_j|$  exceder a sua largura do *kernel*  $\sigma_j$  na iteração atual, será incluída no conjunto de medidas suspeitas em  $\mathcal{S}$ . Adicionalmente, o correspondente valor do parâmetro  $\sigma_j$  de tais medidas suspeitas é atualizado conforme:

$$\sigma_i^{(k+1)} = \lambda_{\mathcal{S}} \cdot \sqrt{R_{ii}}, \quad i \in \mathcal{S}^k \quad (4.16)$$

onde o valor de  $\lambda_{\mathcal{S}}$  corresponde a atribuir um número de desvios-padrão para qual a medida  $i$  é considerada isenta de erros grosseiros.

A justificativa que redefine o valor de  $\sigma_j$  através da Equação (4.16) é dada a seguir. O fato de uma medição falhar no teste  $|r_j| < \sigma_j$  não é usado para defini-la como errônea de forma permanente, pois seu resíduo pode estar contaminado por erros grosseiros de outros dados (o chamado efeito de “espalhamento do erro”). Em vez disso, essa medida é considerada apenas suspeita, até que estimativas mais precisas, calculadas nas iterações subseqüentes, confirmem ou rejeitem o resultado do teste preliminar. O parâmetro  $\lambda_{\mathcal{S}}$  pode ser determinado a partir de um procedimento de testes de hipóteses com base em um dado nível de significância. Neste trabalho, é utilizado  $\lambda_{\mathcal{S}} = 3$ , o que corresponde a um nível de significância de cerca de 0,3%.

Os procedimentos de atualização das janelas de Parzen descrito acima podem ser facilmente implementados através do algoritmo das rotações de Givens, pois o novo valor de  $\sigma$ , seja a regra de atualização dada pela Equação (4.15) ou (4.16), afeta apenas o peso  $w$  a ser atribuído às linhas aumentadas da matriz Jacobiana, como descrito na Seção 4.4.

Uma questão final que ainda deve ser abordada é a definição de um valor mínimo para  $\sigma$ , usado para interromper o processo de diminuição da largura da janela do kernel. Isso é importante porque a regra descrita na Equação (4.15) leva a uma redução contínua da largura das janelas de Parzen para as medidas boas ao longo das

iterações, que deve cessar antes que medidas isentas de erros grosseiros sejam indevidamente rotuladas como errôneas. Neste trabalho, o limite inferior é determinado com base no uso das estimativas de magnitudes de erro de medição, determinadas pelos valores de  $\hat{b}$  (MONTICELLI, 1999; ABUR; GOMEZ EXPOSITO, 2004). Tais valores são calculados em termos de resíduos e são facilmente interpretados, pois fornecem uma estimativa dos erros de medição individuais expressos como um múltiplo dos desvios-padrão da medida. Portanto, se o valor  $\hat{b}_i$  calculado para a medida  $i \in \{1, \dots, m\} \setminus \mathcal{S}^k$  com o maior resíduo normalizado ultrapassar o limite de  $\lambda_{\hat{b}}$ , conclui-se que erros grosseiros permanecem presentes no conjunto de medidas, e desta forma ainda são necessárias mais iterações do estimador baseado no critério MCC para eliminar todos os erros grosseiros. Se, por outro lado,  $\hat{b}_i < \lambda_{\hat{b}}$ , conclui-se que o conjunto de medidas está finalmente livre de erros grosseiros e o algoritmo encerra. O limite traduzido por  $\lambda_{\hat{b}}$  pode ser determinado utilizando o mesmo procedimento já empregado para  $\lambda_{\mathcal{S}}$ . Neste trabalho,  $\lambda_{\hat{b}}$  também é feito igual a 3 desvios-padrão da medida.

#### 4.7 ALGORITMO MCC

Com base nas ferramentas detalhadas neste capítulo para a resolução do problema de estimação de estados sob o critério de máxima correntropia, é estabelecido um algoritmo cuja solução é obtida mediante a aplicação de um Estimador Ortogonal baseado nas Rotações Rápidas de Givens (MCC+G3M). O passo-a-passo da resolução é apresentado no *Algoritmo 1*, que possui um processamento interno (ou *laço interno*) que diz respeito ao algoritmo G3M, descrito no *Algoritmo 2*.

Para processar o *Algoritmo 1*, é suposto que um conjunto de medidas disponíveis assegura a observabilidade do sistema. Desta forma, podem-se destacar algumas características intrínsecas ao modelo proposto:

- O algoritmo do estimador MCC+G3M é composto por dois laços iterativos. O *laço externo* inicia pelo processamento do *laço interno*, onde basicamente corre o algoritmo ortogonal G3M descrito nas Seções 4.3 e 4.4, utilizando uma largura de janela de Parzen previamente determinada (ou inicializada ao considerar a primeira iteração);
- Com o fim das iterações realizadas pelo *laço interno*, o *laço externo* executa o identificador de *outliers*, seguido pela avaliação do critério de parada baseado no teste- $\hat{b}$  para as medidas válidas. Com o resultado desta avaliação, pode-se, portanto, encerrar o algoritmo de estimação de estados ou seguir para outra iteração do *laço externo*. A aplicação desta estratégia impede a diminuição das janelas de Parzen quando a estimativa  $\hat{b}$  para magnitude do erro da medida que corresponde ao maior resíduo normalizado for menor que um limiar pré-especificado, evitando, portanto, a eliminação indevida de medidas válidas. A

**Algoritmo 1** Estimador de Estados MCC+G3M - *Laço Externo*

1. **Definir dados de entrada:** Dados da rede, vetor de medidas  $\mathbf{z}$ ,  $\mathbf{R}$ , parâmetros constantes:  $tol$ ,  $k_G^{(max)}$ ,  $\lambda_{\hat{b}}$ ,  $\eta$ ,  $\sigma^{(0)}$  e  $\sigma_{min}$ , com  $\sigma^{(0)} \gg \sigma_{min}$ ;
2. Arbitrar valores para o vetor  $\hat{\mathbf{x}}^0$ , geralmente como partida plana dos estados;
3. **Iniciar** contador de iterações  $k \leftarrow 0$  (*laço externo*)
4. **Fazer**  $\sigma_i^k = \sigma^0$
5. **Realizar** o *laço interno* para computar  $\hat{\mathbf{x}}^{(k)}$  através do *Algoritmo 2*;
6. (**Identificação de outliers**) Se  $|r_i| > \sigma_i^{(k)}$ :
  - 6.1  $z_i$  é suspeita de conter erros grosseiros;
  - 6.2 Incluir  $z_i$  no conjunto de medidas suspeitas:  $\mathcal{S}^k \leftarrow i$ .
7. **Implementar** o teste- $\hat{b}$  para medidas que  $\notin \mathcal{S}^{(k)}$ 
  - 7.1 Se  $\hat{b} < \lambda_{\hat{b}}$ , assume-se que a solução não está contaminada por erros grosseiros: **PARAR**. Fazer  $\hat{\mathbf{x}}_{MCC} \leftarrow \hat{\mathbf{x}}^{(k)}$ ;
  - 7.2 Caso contrário, ir para o passo **8**.
8. **Atualização** da largura das Janelas de Parzen:
  - 8.1 Computar  $\sigma^{(k+1)}$  de acordo com Eq. (4.15) para medidas  $z_i \notin \mathcal{S}^{(k)}$ ;
  - 8.2 Computar  $\sigma^{(k+1)}$  de acordo com Eq. (4.16) para medidas  $z_i \in \mathcal{S}^{(k)}$ ;
  - 8.3 Atualizar  $k \leftarrow k + 1$ ; e voltar para o passo **5**.

continuidade para uma próxima iteração ocorre após a atualização das janelas de Parzen, de acordo com os princípios detalhados na Seção 4.6;

- Com base no processamento de uma medida por vez pelo algoritmo G3M, as medidas do grupo  $\mathcal{S}$  não precisam ser de fato removidas do vetor de medidas (o que iria gerar aumento do custo computacional). A eliminação destas medidas e dos seus efeitos no processo iterativo pode ser feita mediante verificação dos respectivos pesos na matriz  $\mathbf{W}$ , conforme detalhado no *Algoritmo 2*;
- Sobre as iterações do *Algoritmo 1*, somente a primeira é inicializada com valores arbitrários para o vetor de estados estimados (neste trabalho adota-se a partida plana dos estados: 1,0 p.u. para as magnitudes de tensão e 0,0 rad para os ângulos nas barras), enquanto que as subseqüentes mantêm o vetor já estimado.

**Algoritmo 2** Rotações Rápidas de Givens (G3M) e cálculo dos estados

1. **Iniciar** contador  $k_G \leftarrow 0$  e  $\hat{\mathbf{x}}^{(k_G)} \leftarrow \hat{\mathbf{x}}^{(k)}$
2. **Enquanto**  $k_G \leq k_G^{(max)}$ 
  - a) Utilizando  $\hat{\mathbf{x}}^{(k_G)}$ , computar a matriz  $\mathbf{H}^{(k_G)}$ , o vetor  $\Delta \tilde{\mathbf{z}}^{(k_G)}$  e a matriz de pesos  $\mathbf{W}^{(k_G)}$  conforme Eq. (3.27)
  - b) Inicializar  $\mathbf{T}^0 = \mathbf{0}$ ,  $\mathbf{U}^0 = \mathbf{I}$ , e  $\mathbf{c}^0 = \mathbf{0}$
  - c) Inicializar  $j \leftarrow 0$  e  $[\mathbf{U}^0 \mid \mathbf{c}^0]$ 

**Enquanto**  $j \leq m$

$w = W_{jj}^{(k_G)}$

**Se**  $w \leq \eta$

Processar próxima medida, atualizando  $j \leftarrow j + 1$

**Caso Contrário**

    - (i) Zerar os elementos de  $[\mathbf{H}^{(k_G)} \mid \Delta \tilde{\mathbf{z}}^{(k_G)}]$  através das Rotações de Givens com as linhas de  $[\mathbf{U} \mid \mathbf{c}]$
    - (ii) Atualizar  $j \leftarrow j + 1$

**Fim Enquanto**
  - d) Solucionar o problema  $\mathbf{U} \Delta \mathbf{x} = \mathbf{c}$
  - e) Atualizar  $\hat{\mathbf{x}}^{(k_G+1)} \leftarrow \hat{\mathbf{x}}^{(k_G)} + \Delta \mathbf{x}$
  - f) Critério de parada: **Se**  $\|\Delta \mathbf{x}\|_\infty \leq tol$ : **Fim Algoritmo e retorna**  $\hat{\mathbf{x}}^{(k)} \leftarrow \hat{\mathbf{x}}^{(k_G+1)}$ ;

**Caso Contrário:** atualizar  $k_G \leftarrow k_G + 1$  e retornar ao passo (a)

**Fim Enquanto**

## 4.8 ESTUDO DE CASO ILUSTRATIVO

Nesta seção apresenta-se um estudo de caso ilustrativo em que é aplicado o estimador de estados baseado no critério MCC+G3M. Para tal, são realizados testes considerando o sistema-teste de 3 barras, apresentado na Figura 4.1, que também indica o plano de medição empregado. Os dados da rede e o detalhamento do plano de medição são mostrados no Apêndice A.

As medidas são obtidas a partir do resultado do fluxo de potência convergido, nas quais são inseridos erros aleatórios com distribuição normal nos valores correspondentes. O valor de exatidão das medidas de tensão e de potência é de  $1 \times 10^{-2}$  p.u.

O sistema-teste em questão é utilizado para ilustrar o comportamento e as propriedades da correntropia, com a apresentação dos valores numéricos obtidos na solução. Alguns casos são simulados e detalhados a seguir.



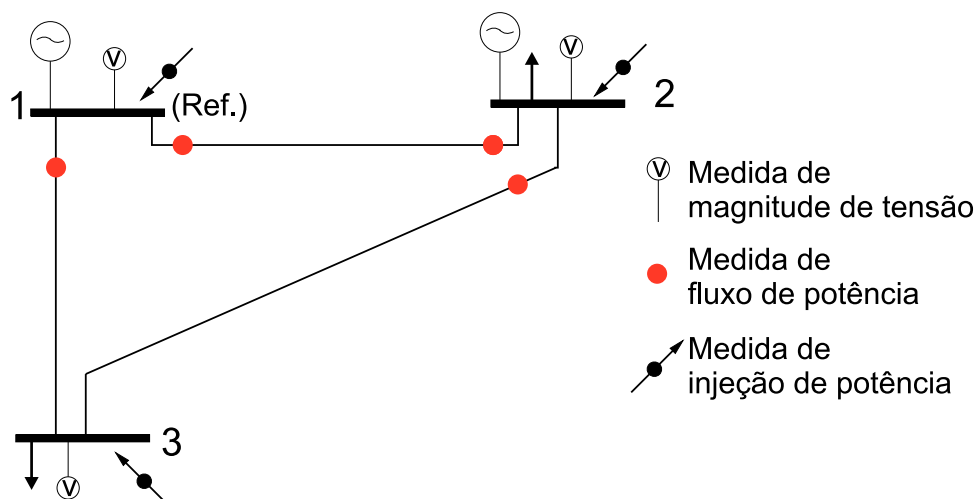


Figura 4.1 – Sistema-teste de 3 barras

#### 4.8.1 Propriedades da Maximização da Correntropia

Com o objetivo de verificar a atuação das propriedades da correntropia no processo de otimização, um erro grosseiro de magnitude 15 desvios-padrão é adicionado à medida de magnitude de tensão da barra 2. Os valores computados pelo fluxo de potência e as medidas simuladas pelo algoritmo, destacando em **negrito** os dados referentes ao erro grosseiro em  $V_2$ , são apresentados na Tabela 4.1. As estimativas obtidas mediante o método MCC+G3M são comparadas com os resultados do Estimador MQP<sup>1</sup>, sendo que neste último não é realizada nenhuma etapa de pós-processamento de erro grosseiro. Os estados estimados (magnitudes de tensão  $V$  e ângulo  $\theta$ ) tanto pelos métodos MQP quanto MCC+G3M são apresentados na Tabela 4.2.

A partir dos resultados das Tabelas 4.1 e 4.2, verifica-se o bom desempenho do estimador MCC+G3M, principalmente quando seus resultados são comparados com os valores obtidos através do estimador MQP. Como já esperado, o erro grosseiro na medida de magnitude de tensão na barra 2 afeta severamente os estados estimados pelo método MQP, culminando em erros de alta magnitude sobre as medidas estimadas em relação aos valores do fluxo de potência, verificados na Tabela 4.1, assim como sobre as variáveis de estado estimadas em comparação com os respectivos valores ótimos ( $V^*$  e  $\theta^*$ ) fornecidos pelo método, resultando em elevadas médias desses erros, apresentadas na Tabela 4.2. Por outro lado, observa-se que o estimador de estados baseado no método MCC+G3M elimina os efeitos do erro grosseiro, fornecendo estimativas próximas ao ideal, isto é, o estimador fornece um resultado bem próximo aos valores do fluxo de potência convergido.

Para visualizar a atenuação do efeito do erro grosseiro no processo de otimização do Estimador MCC+G3M mediante a diminuição das janelas de Parzen para cada medida, é adotado neste exemplo um decremento pré-determinado, isto

<sup>1</sup> A técnica de resolução utilizada é o da Equação Normal, apresentado no Capítulo 2.

Tabela 4.1 – Medidas estimadas e resíduos obtidos pelos Estimadores MQP e MCC+G3M

Medida	Fluxo de potência	Valor medido	Medidas estimadas		Resíduos	
			MQP	MCC	MQP	MCC
$V_1$	1,0500	1,0412	1,1111	1,0473	-0,0699	-0,0062
$V_2$	<b>1,0000</b>	<b>1,2121</b>	<b>1,0640</b>	<b>0,9972</b>	<b>0,1482</b>	<b>0,2149</b>
$V_3$	0,9868	0,9889	1,0510	0,9838	-0,0622	0,0051
$p_{1-2}$	0,7114	0,7102	0,7179	0,7165	-0,0077	-0,0063
$p_{2-1}$	-0,7114	-0,7161	-0,7179	-0,7165	0,0018	0,0004
$p_{1-3}$	0,8014	0,8117	0,8080	0,8094	0,0037	0,0023
$p_{2-3}$	0,4114	0,4038	0,4165	0,4166	-0,0127	-0,0128
$q_{1-2}$	0,5271	0,5266	0,5205	0,5276	0,0061	-0,0011
$q_{2-1}$	-0,4959	-0,4914	-0,5020	-0,4951	0,0106	0,0037
$q_{1-3}$	0,3081	0,3095	0,3013	0,3102	0,0083	-0,0007
$q_{2-3}$	0,0319	0,0319	0,0304	0,0332	0,0015	-0,0013
$P_1$	1,5129	1,5276	1,5259	1,5259	0,0017	0,0017
$P_2$	-0,3001	-0,3016	-0,3014	-0,2999	-0,0002	-0,0017
$P_3$	-1,2000	-1,2141	-1,2129	-1,2128	-0,0012	-0,0013
$Q_1$	0,8352	0,8391	0,8217	0,8379	0,0174	0,0013
$Q_2$	-0,4639	-0,4639	-0,4716	-0,4619	0,0077	-0,0021
$Q_3$	-0,2504	-0,2512	-0,2690	-0,2490	0,0178	-0,0022

Tabela 4.2 – Estados estimados obtidos através dos Estimadores MQP e MCC+G3M

Barra	$V^*$	$V_{MQP}$	$V_{MCC}$	$ V^* - V_{MQP} $	$ V^* - V_{MCC} $
1	1,0500	1,1111	1,0473	0,0611	0,0027
2	1,0000	1,0640	0,9972	0,0640	0,0028
3	0,9868	1,0510	0,9838	0,0642	0,0030
<b>Média dos erros absolutos:</b>				0,0631	0,0028
Barra	$\theta^*$	$\theta_{MQP}$	$\theta_{MCC}$	$ \theta^* - \theta_{MQP} $	$ \theta^* - \theta_{MCC} $
2	-0,0678	-0,0608	-0,0687	0,0070	0,0009
3	-0,1505	-0,1346	-0,1529	0,0159	0,0024
<b>Média dos erros absolutos:</b>				0,0115	0,0017

é,  $\sigma_i^{k+1} = \sigma_i^k - \Delta\sigma$ . Embora este procedimento torne muito mais lento o processo de convergência, ele é adotado aqui com propósito exclusivamente tutorial, para possibilitar observação da evolução da fdp dos resíduos em função da largura das janelas de Parzen  $\sigma^k$ . Este procedimento também permite verificar como os parâmetros envolvidos no método atuam no decorrer do processo iterativo.

O valor absoluto dos resíduos de todas as medidas pertencentes ao plano de medição da Figura 4.1 e computados durante o processo iterativo estão representados em forma de histograma na Figura 4.2. Dentre os vários valores estabelecidos para a largura das janelas de Parzen, seis são selecionados para a verificar o desempenho do Estimador MCC+G3M, a saber  $\sigma = \{10,0; 1,0; 0,17; 0,05; 0,02; 0,01\}$ , sendo que  $\sigma^0 = 10,0$  e  $\sigma_{min} = 0,01$  são os valores inicial e final atribuídos às janelas de Parzen

no processo de otimização, respectivamente. Pode-se observar que para o valor de  $\sigma^0$ , o efeito do erro grosseiro em  $V_2$  se espalha para outras medidas, que culmina no aumento dos valores dos resíduos, do mesmo modo como ocorre para o método MQP. Contudo, com a diminuição da largura do *kernel* Gaussiano destaca-se a janela cuja largura é de  $\sigma = 0,17$ , a partir da qual os resíduos começam a se diferenciar dos valores anteriores. Com o processo de redução das janelas, inicia-se uma tendência dos resíduos se estabelecerem próximos aos seus valores finais, conforme apresentados na Tabela 4.1. Este é, por exemplo, o caso da medida  $V_2$ , cujo resíduo apresenta-se bem próximo do seu valor final a partir de  $\sigma = 0,05$ .

Verifica-se que a eliminação do erro grosseiro já é efetuada quando o algoritmo atinge a largura do *kernel* Gaussiano no valor de  $\sigma = 0,05$ . Entretanto, para a visualização do efeito deste importante parâmetro, diminui-se o valor de  $\sigma$  até 0,01. Desta forma, observa-se que valores muito pequenos de  $\sigma$  podem atuar indevidamente sobre medidas válidas. Em outras palavras, podem eliminar medidas cujos desvios-padrão esperados estão dentro da exatidão prevista pelo modelo de medição. Isto ocorre com a medida de fluxo ativo  $p_{2-3}$ , cujo resíduo absoluto é maior que o valor da janela quando  $\sigma = 0,01$ , como mostrado na Figura 4.2(c). Neste caso, a medida é incluída no conjunto de medidas com erros grosseiros, implicando posteriormente na sua não utilização para computar as estimativas dos estados.

Partido destes resultados, justificam-se as estratégias descritas na Seção 4.6 para o estimador MCC+G3M, em que o critério de parada baseado no método do  $\hat{b}$  é aplicado para encerrar o algoritmo quando erros grosseiros não mais existem no conjunto de medidas. Uma janela de Parzen diferenciada pode ser atribuída às medidas identificadas como *outliers*, de forma a verificar se seus respectivos resíduos permanecem fora de um determinado grau de significância.

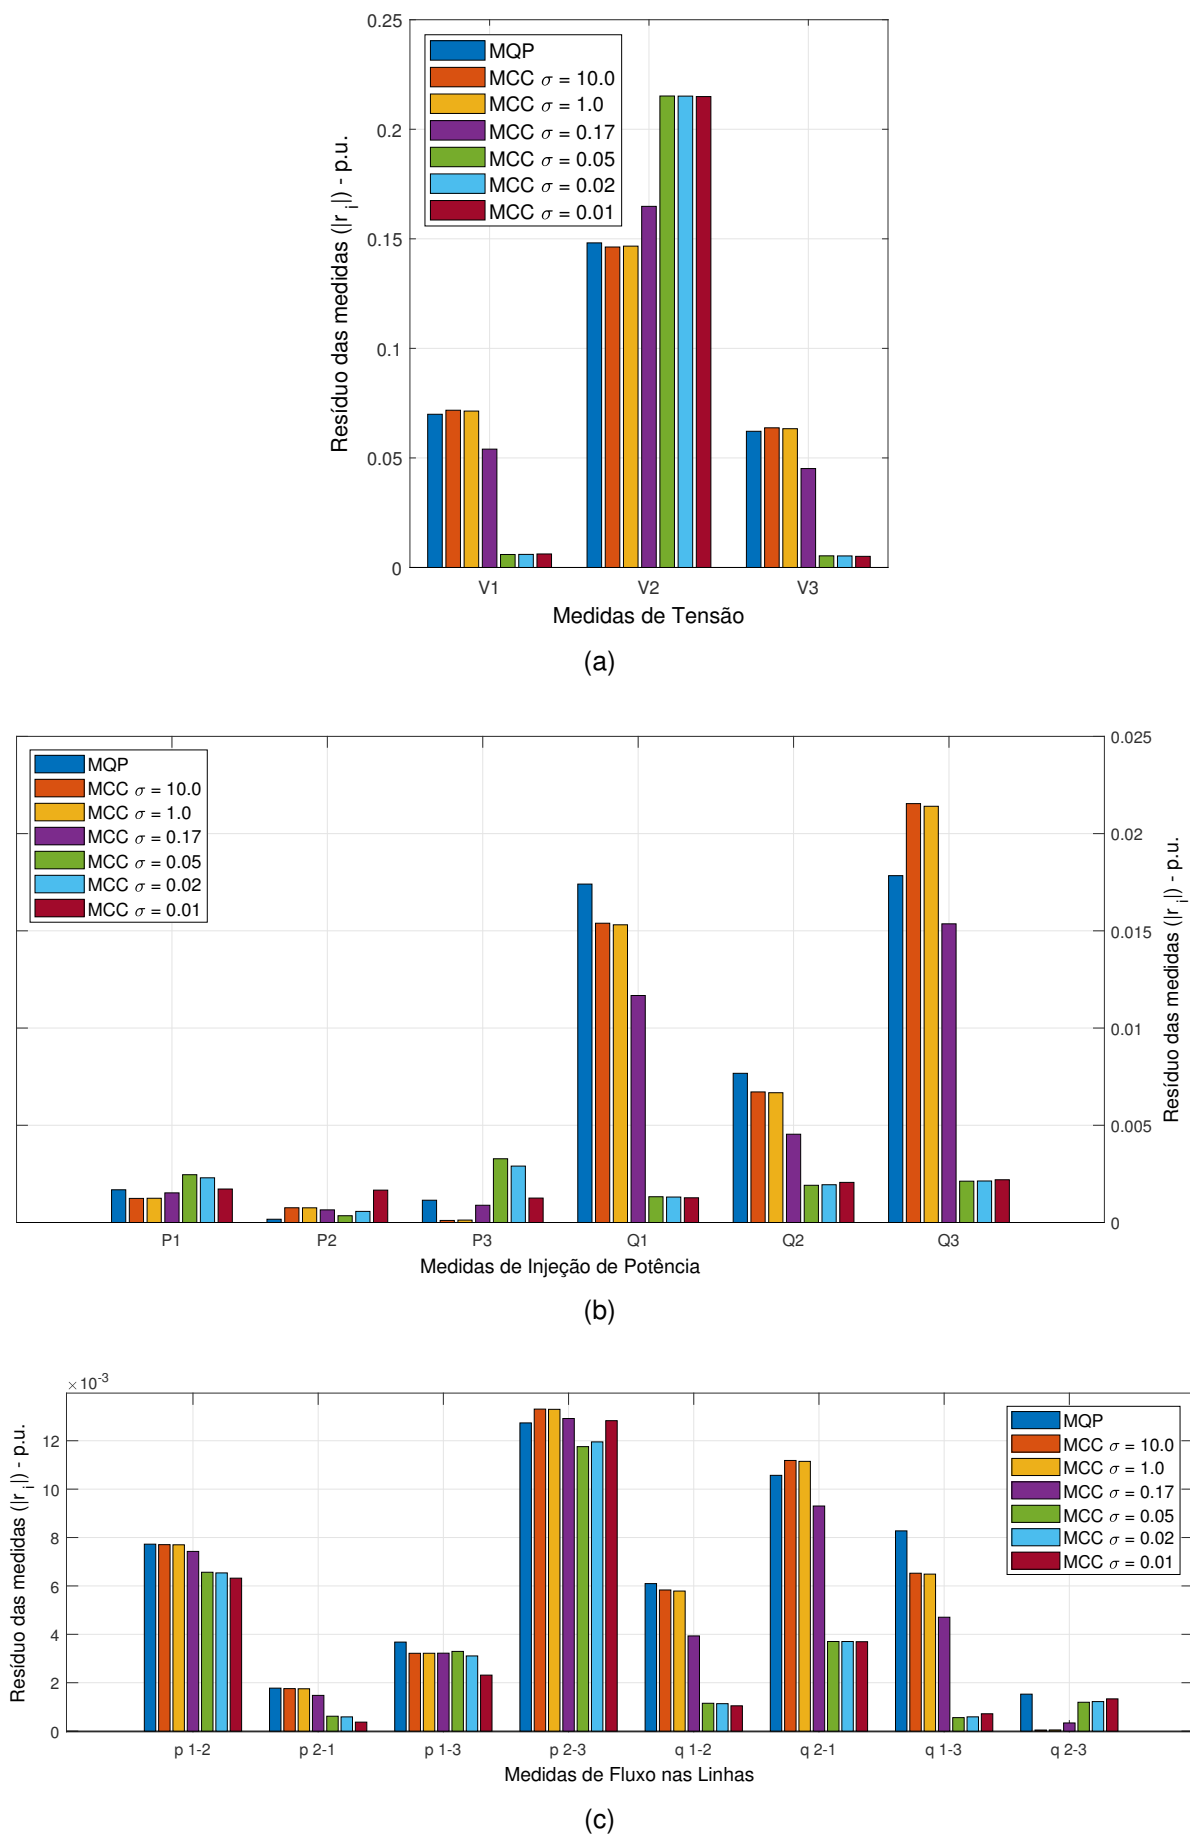


Figura 4.2 – Resíduos das medidas para o método MQP e MCC+G3M, considerando seis diferentes larguras das janelas de Parzen.

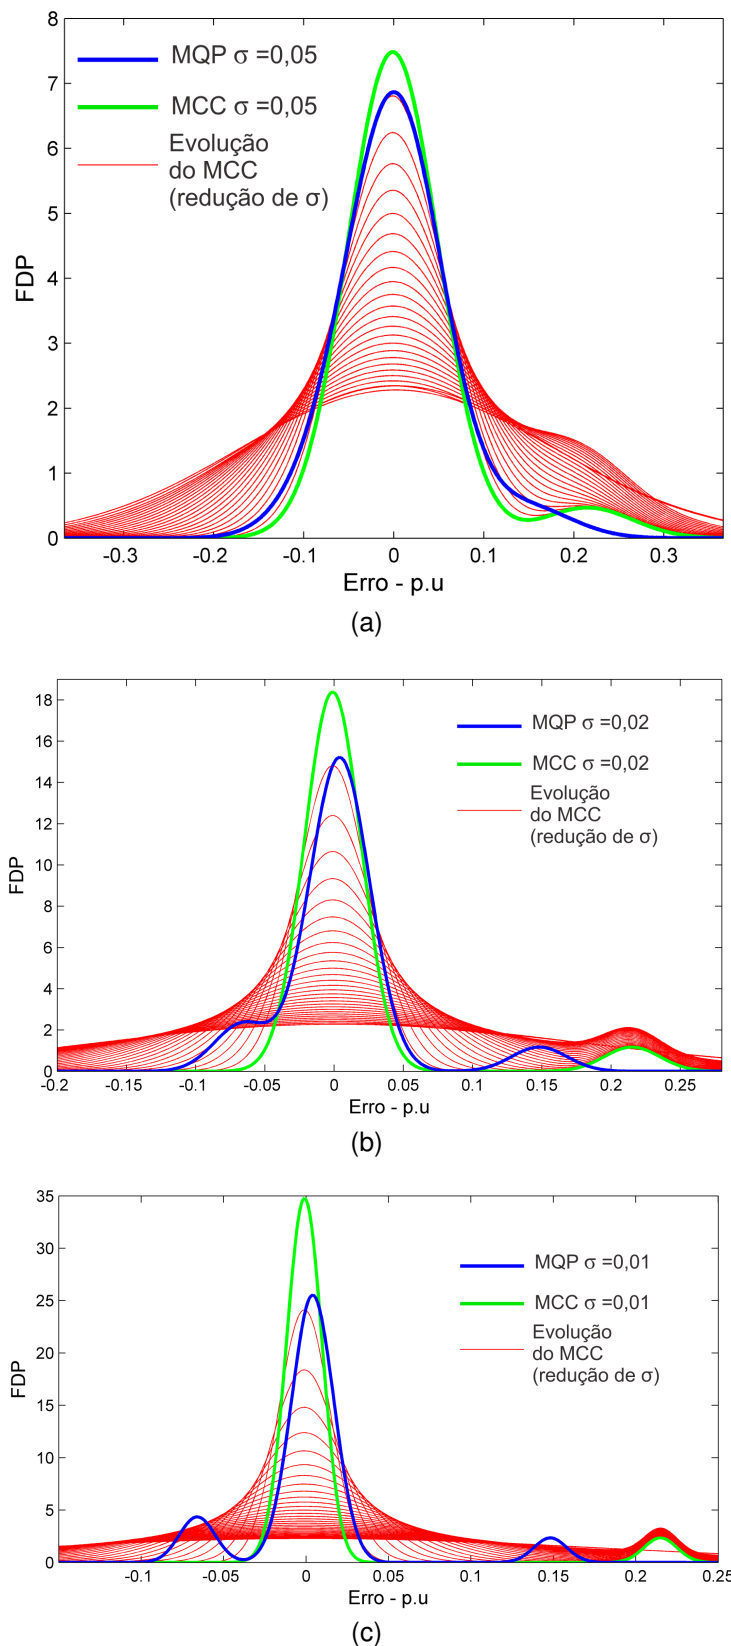


Figura 4.3 – Evolução das fdps dos erros de acordo com as larguras das janelas de Parzen.

Outra forma de observar o efeito do ajuste das janelas de Parzen é a partir da visualização das fdps dos resíduos. Tais funções são aproximadas utilizando o *kernel*

Gaussiano, e para tal, são escolhidos os valores de largura  $\sigma = \{0,05; 0,02; 0,01\}$ . As fdp dos resíduos para o método MQP também são aproximadas com base nos mesmos valores de  $\sigma$ , com o intuito de observar as respectivas distribuições. As Figuras em 4.3 apresentam a evolução da fdp dos resíduos das medidas para cada largura das Janelas de Parzen  $\sigma^k$  (em vermelho) do Estimador MCC+G3M. Ao analisar as soluções finais do método MCC+G3M (em verde) percebe-se que a maior parte dos resíduos das medidas estão concentrados em torno da média zero, e fica evidente a presença de um “outlier” em torno de  $+0.21$  p.u., devido ao erro grosseiro em  $V_2$  e que é devidamente suprimido no processo de estimação. Por sua vez, nas mesmas figuras obtêm-se de forma similar a distribuição dos resíduos das medidas obtida pelo Estimador MQP. Consta-se que os resultados da fdp dos resíduos geram funções não-Gaussianas (em azul), com uma distribuição centrada em um valor diferente de zero. É importante notar que no método MCC+G3M, quanto menor a largura do *kernel* Gaussiano, mais evidente se torna a distribuição dos resíduos em torno de zero, assim como mais destacada fica a presença do erro grosseiro suprimido. Já para o método MQP, a diminuição das janelas de Parzen faz com que a fdp se diferencie ainda mais de uma distribuição Gaussiana.

Por fim, verifica-se na Figura 4.4 o desempenho da estimação dos estados dentro de cada uma das janelas de Parzen estipuladas. Nesta figura, observam-se os erros absolutos dos estados estimados pelo método MCC+G3M para cada valor de largura do *kernel* Gaussiano utilizado no processo iterativo com respeito aos valores do fluxo de potência convergido. Apresentam-se também os erros das estimativas gerados pelo método MQP, mostrados como ordenadas da primeira abscissa do gráfico que se diferenciam dos demais resultados através de marcadores maiores. Ressaltam-se as seguintes observações:




Figura 4.4 – Erro absoluto dos estados em relação ao fluxo de potência convergido para os estimadores MQP e MCC+G3M, de acordo com diferentes larguras do *kernel* Gaussiano

- Nota-se inicialmente que os estados estimados pelo método MCC+G3M, consi-

derando a largura *kernel* de  $\sigma^0 = 10$ , gera estados cujos erros são muito próximos aos obtidos pelo método MQP. Tal fato já era esperado, já que valores grandes para o *kernel* Gaussiano geram soluções que equivalem à solução do método MQP;

- Com a diminuição da largura do *kernel* durante o processo iterativo, nota-se que o efeito do erro grosseiro é atenuado, como pode ser visualizado dentre os valores de  $\sigma = \{0,17; 0,165; 0,16\}$ . Pode-se perceber que em  $\sigma = 0,165$  o efeito do erro na medida de magnitude de tensão  $V_2$  é bastante atenuado, ocasionando de forma imediata uma melhora nas estimativas dos estados quando comparados com os erros gerados pelo valor de  $\sigma$  anterior ( $\sigma = 0,17$ ). Posteriormente com  $\sigma = 0,16$ , já com a devida identificação do erro grosseiro, os erros das estimativas dos estados apresentam-se abaixo de  $4 \times 10^{-3}$  p.u;

#### 4.8.2 Desempenho Numérico e Processamento do Algoritmo MCC

O procedimento adotado para a lenta diminuição das janelas de Parzen realizado na Subseção 4.8.1 considera um decremento fixo ao *kernel* Gaussiano. O estudo a seguir apresenta um decremento variável das janelas de Parzen baseado no máximo resíduo normalizado das medidas e nos valores do método  $\hat{b}$  tomado como critério de parada do estimador de estados MCC+G3M. Portanto, os valores de *kernel* Gaussiano são atualizado conforme as Equações (4.15) e (4.16), visando averiguar o desempenho do Estimador MCC+G3M proposto no *Algoritmo 1*. Para tal, considera-se a simulação de duas medidas portadoras de erros grosseiros do plano de medição da Figura 4.1. As medidas selecionadas são a de fluxo de potência ativa da barra 1 para barra 3 ( $p_{1-3}$ ) e a de injeção de potência ativa na barra 3 ( $P_3$ ). As magnitudes dos erros são computadas a partir de uma distribuição uniforme entre 15 a 20 desvios-padrão. Os valores das medidas simuladas e estimadas, assim como os resultados do fluxo de potência convergido e das medidas estimadas pelo método MQP são apresentados na Tabela 4.3. A partir desta tabela pode-se observar que as medidas estimadas pelo método MCC+G3M estão próximas a dos valores do fluxo de potência, diferentemente das medidas obtidas pelo método MQP. O processo de obtenção deste resultado é explanado com detalhes a seguir.

O processamento do *Algoritmo 1* do Estimador MCC+G3M leva três iterações (denotadas como  $k$ ) para a convergência. Os valores dos estados ao final de cada uma das três iterações são apresentados na Tabela 4.4. Nota-se que, ao final da primeira iteração ( $k = 0$ ), as estimativas obtidas pelo método MCC+G3M são equivalentes as do método MQP. Ao final da terceira iteração ( $k = 2$ ), os valores do estados estimados ficam próximos ao resultado do fluxo de potência, o que certifica que a estimativa final está isenta dos efeitos dos erros grosseiros presentes inicialmente no plano de

Tabela 4.3 – Medidas estimadas e resíduos obtidos pelos Estimadores MQP e MCC+G3M

Medida	Fluxo de potência	Valor medido	Medidas estimadas		Resíduos	
			MQP	MCC	MQP	MCC
$V_1$	1,0500	1,0349	1,0390	1,0444	-0,0041	-0,0095
$V_2$	1,0000	0,9947	0,9880	0,9936	0,0067	0,0011
$V_3$	0,9868	0,9847	0,9755	0,9805	0,0092	0,0042
$p_{1-2}$	0,7114	0,7070	0,7096	0,7221	-0,0026	-0,0151
$p_{2-1}$	-0,7114	-0,7099	-0,7096	-0,7221	-0,0003	0,0122
<b><math>p_{1-3}</math></b>	<b>0,8014</b>	<b>0,9752</b>	<b>0,7662</b>	<b>0,8066</b>	<b>0,2091</b>	<b>0,1687</b>
$p_{2-3}$	0,4114	0,4115	0,3776	0,4107	0,0339	0,0008
$q_{1-2}$	0,5271	0,5296	0,5328	0,5331	-0,0033	-0,0035
$q_{2-1}$	-0,4959	-0,4896	-0,4988	-0,4986	0,0093	0,0090
$q_{1-3}$	0,3081	0,3066	0,3053	0,3112	0,0013	-0,0046
$q_{2-3}$	0,0319	0,0320	0,0284	0,0318	0,0036	0,0002
$P_1$	1,5129	1,5019	1,4758	1,5287	0,0261	-0,0268
$P_2$	-0,3001	-0,3031	-0,3320	-0,3115	0,0289	0,0083
<b><math>P_3</math></b>	<b>-1,2000</b>	<b>-0,8909</b>	<b>-1,1319</b>	<b>-1,2042</b>	<b>0,2411</b>	<b>0,3133</b>
$Q_1$	0,8352	0,8456	0,8381	0,8443	0,0075	0,0013
$Q_2$	-0,4639	-0,4714	-0,4704	-0,4668	-0,0009	-0,0045
$Q_4$	-0,2504	-0,2512	-0,2546	-0,2487	0,0034	-0,0026

medição.

Tabela 4.4 – Estados estimados ao final de cada iteração do Estimador MCC+G3M

Estado	Fluxo de Potência	MQP	MCC		
			$k = 0$	$k = 1$	$k = 2$
$\theta_2$	-0,068	-0,069	-0,069	-0,070	-0,070
$\theta_3$	-0,151	-0,147	-0,147	-0,153	-0,153
$V_1$	1,050	1,039	1,039	1,044	1,044
$V_2$	1,000	0,988	0,988	0,994	0,994
$V_3$	0,987	0,976	0,976	0,981	0,981

Os estados estimados nas iterações do Estimador MCC+G3M da Tabela 4.4 são computados através do *Algoritmo 2*, que tem por base as rotações rápidas de Givens. A verificação do desempenho neste processo é dado através do número de iterações para a convergência que são realizadas pelo algoritmo das Rotações de Givens (sendo cada uma denotada por  $k_G$ ), cujo critério de parada é o valor da norma infinita do vetor de estados incrementais<sup>2</sup>  $\Delta \mathbf{x}$ . Deste modo, são apresentados na Tabela 4.5 os valores das normas infinitas das interações do *Algoritmo 2*, computadas internamente durante as três iterações ( $k$ ) do *Algoritmo 1*. Pode-se notar que, no máximo, três iterações são suficientes para que o critério de convergência do *Algoritmo 2* seja atingido, e que um

<sup>2</sup> Neste trabalho, a tolerância é dada por  $tol = 1 \times 10^{-3}$ .



número menor de iterações do *laço interno* é requerido para as demais iterações do *laço externo*.

Tabela 4.5 – Valores da norma infinita do vetor de incrementos dos estados ao longo das interações das rotações rápidas de Givens

	$\ \Delta \mathbf{x}\ _\infty$		
	$k_G = 0$	$k_G = 1$	$k_G = 2$
$k = 0$	$1,484 \times 10^{-1}$	$1,045 \times 10^{-2}$	$6,556 \times 10^{-5}$
$k = 1$	$6,363 \times 10^{-3}$	$3,279 \times 10^{-7}$	–
$k = 2$	$9,855 \times 10^{-8}$	–	–

Tabela 4.6 – Valores das Janelas de Parzen, resíduos de cada medida e valor de  $\hat{b}_i$  no processo iterativo

$z_i$	$k = 0$			$k = 1$			$k = 2$		
	$\sigma_i^{(0)} = \sigma^0$	$r_i^{MCC}$	$\hat{b}_i$	$\sigma_i^{(1)}$	$r_i^{MCC}$	$\hat{b}_i$	$\sigma_i^{(2)}$	$r_i^{MCC}$	$\hat{b}_i$
$V_1$	10	-0,0041		0,2437	-0,0095		0,1909	-0,0095	
$V_2$	10	0,0067		0,2307	0,0011		0,1861	0,0011	
$V_3$	10	0,0092		0,2274	0,0042		0,1849	0,0042	
$p_{1-2}$	10	-0,0026		0,2143	-0,0151		0,1615	-0,0151	
$p_{2-1}$	10	-0,0003		0,2143	0,0122		0,1615	0,0122	
<b><math>p_{1-3}</math></b>	<b>10</b>	<b>0,2090</b>		<b>0,2278</b>	<b>0,1687</b>	<b>13,165</b>	<b>0,1687*</b>	<b>0,1687*</b>	–
$p_{2-3}$	10	0,0339		0,1909	0,0008		0,1423	0,0008	
$q_{1-2}$	10	-0,0033		0,1954	-0,0035		0,1488	-0,0035	
$q_{2-1}$	10	0,0092		0,1966	0,0090		0,1469	0,0090	
$q_{1-3}$	10	0,0013		0,1861	-0,0046		0,1377	-0,0046	
$q_{2-3}$	10	0,0036		0,1801	0,0002		0,1317	0,0002	
$P_1$	10	0,0261		0,3049	-0,0268		0,2387	-0,0268	<b>1,4754</b>
$P_2$	10	0,0289		0,1401	0,0083		0,1374	0,0083	
<b><math>P_3</math></b>	<b>10</b>	<b>0,2411</b>	<b>24,997</b>	<b>0,2411*</b>	<b>0,3133*</b>	–	<b>0,0469†</b>	<b>0,3133†</b>	–
$Q_1$	10	0,0075		0,2005	0,0013		0,1715	0,0013	
$Q_2$	10	-0,0009		0,164	-0,0045		0,1451	-0,0045	
$Q_4$	10	0,0034		0,1352	-0,0025		0,1357	-0,0025	

\* Medida eliminada na iteração corrente;

† Medida sob largura de janela constante.

A eliminação dos erros grosseiros durante o processo iterativo é baseada no cálculo da largura das janelas de Parzen e nos valores dos resíduos das medidas, cujo procedimento é visualizado na Tabela 4.6. Na primeira iteração do *Algoritmo 1* ( $k = 0$ ), as estimativas dos estados computadas pelas rotações rápidas de Givens (*Algoritmo 2*) têm por base um conjunto de valores atribuídos às janelas de Parzen para as medidas, com a largura do *kernel* Gaussiano sendo inicializada como  $\sigma^0 = 10$ . Desta forma, ao final desta iteração são calculados os resíduos das medidas e em seguida são comparados com as suas respectivas janelas de Parzen. Como o valor de largura de *kernel* é extremamente elevado na iteração ( $k = 0$ ), todos os resíduos

estão contidos dentro da janela, restando, portanto, a realização do critério de parada baseado no teste- $\hat{b}$ . Na iteração ( $k = 0$ ), o valor estimado em termos de desvios-padrão para a magnitude do erro correspondente ao máximo resíduo normalizado (medida  $P_3$ ) encontra-se bem acima do limiar ( $\hat{b} \cong 25 > \lambda_{\hat{b}}$ ). Consequentemente, são computados os novos valores de largura para as janelas de Parzen da próxima iteração ( $k = 1$ ). Note que a medida  $P_3$  não é prontamente eliminada na iteração ( $k = 0$ ) mesmo sob o alarme positivo do teste- $\hat{b}$ , pois esta técnica é empregada somente como critério de parada do algoritmo do Estimador MCC+G3M.

No decorrer da iteração  $k = 1$  ocorre a eliminação da medida  $P_3$ , identificada a partir da comparação entre a largura do *kernel* Gaussiano da medida com o respectivo valor absoluto do resíduo. Ao final desta iteração, aplica-se o teste do critério de parada, desconsiderando os *outliers* identificados, e aponta-se que mais uma iteração do *laço externo* deve ser realizada. Todas as janelas de Parzen são atualizadas conforme a regra estabelecida pela Equação (4.15), exceto a janela correspondente ao erro grosseiro  $P_3$ , sendo atualizada conforme a Equação (4.16).

Finalmente, o efeito do erro grosseiro presente na medida  $p_{1-3}$  é atenuado na iteração  $k = 2$ , e a medida  $P_3$  permanece eliminada devido o fato da magnitude do seu resíduo ser maior que a correspondente largura do *kernel* Gaussiano. Pode-se verificar na Tabela 4.6 que o algoritmo é encerrado, pois o valor da magnitude do erro estimado para a medida  $P_1$ , a qual obtém o maior resíduo normalizado no valor de  $r^N = 1,4753$ , é menor que o limiar pré-estabelecido.

## 4.9 AVALIAÇÃO DOS MÉTODOS DE SOLUÇÃO DO ESTIMADOR MCC

As propostas até aqui abordadas são baseadas em dois métodos de solução para o Estimador MCC para a EESP: a solução direta via Equação (3.26), que pode ser vista como uma versão com reponderação de medidas da equação normal convencional; e a solução utilizando o Estimador MCC+G3M proposto, baseado na técnica ortogonal da versão rápida das rotações de Givens, como descrito nas Seções 4.3 e 4.4. Esta seção apresenta uma comparação qualitativa e quantitativa entre as duas estratégias.

### 4.9.1 Aspectos Qualitativos

A solução do Estimador MCC através da Equação matricial (3.26) é uma abordagem de processamento completo, isto é, todas as medidas são processadas simultaneamente. O fato da Equação (3.26) se assemelhar à equação normal e, portanto, manter parcialmente as técnicas de solução desenvolvidas anteriormente para os estimadores MQP, pode ser visto como um aspecto positivo. Por outro lado, sabe-se que equações como (3.26) são propensas a um mau condicionamento numérico de-

vido à estrutura de sua matriz de coeficientes ( $H^T WH$ ) (SIMÕES COSTA; QUINTANA, 1981b; MONTICELLI; MURARI; WU, 1985). Embora esses problemas atualmente sejam frequentemente mitigados pelo uso de processadores que suportam formatos de precisão estendidos, a estabilidade numérica é sempre motivo de preocupação ao lidar com equações matriciais presentes nesta forma, especialmente em situações em que outros fatores desestabilizadores podem interferir. A seguir, é demonstrado que esse é um cenário provável quando mecanismos de supressão de erros grosseiros são realizados pelo algoritmo MCC.

Como discutido na Seção 3.3, o Estimador MCC elimina os efeitos dos *ouliers* através da diminuição radical dos pesos sobre os erros grosseiros no processo de estimação de estados. Isso seria alcançado atribuindo valores muito pequenos aos elementos diagonais correspondentes da matriz  $W$ , que se tornam valores com ordens de magnitude muito menores do que os pesos para medidas válidas. No entanto, a grande diferença entre tais valores para pesos de medidas é outro conhecido fator que agrava o mau condicionamento da matriz de ganho (HOLTEN *et al.*, 1988). Conclui-se então que esse caminho para suprimir erros grosseiros não é recomendado, devido ao aumento do risco de instabilidade numérica.

Ainda sobre a utilização da equação normal com reponderação para a solução do Estimador MCC, a alternativa para evitar os problemas acima é a remoção real dos erros grosseiros identificados juntamente com os elementos correspondentes de  $W$ ,  $\Delta\tilde{z}$  e linhas do Jacobiano  $H$  antes da resolução da Equação (3.26). Isto certamente previne maiores riscos de mau condicionamento, porém aumenta significativamente o custo computacional do processo, visto que a estrutura das matrizes esparsas devem ser reconstruídas e novas fatorizações de matrizes devem ser realizadas.

Por outro lado, a solução do Estimador MCC via método G3M, além de ser numericamente mais robusta que o equivalente da equação normal, é uma técnica em que o processamento é linha-a-linha, e que permite a eliminação de medidas anteriormente identificadas como erro grosseiro sem a direta atribuição de pesos relativamente pequenos. Conseqüentemente, o método MCC+G3M contorna os possíveis problemas de estabilidade numérica que afetam a solução matricial direta de (3.26) discutida acima. A alternativa do uso do algoritmo G3M é reconhecidamente mais elaborada do ponto de vista matemático, mas isso não foi um obstáculo para seu uso como o mecanismo de solução em pacotes de *software* de estimação de estados atualmente empregados em Sistemas de Gerenciamento de Energia de Centros de Operação e Controle de grandes redes elétricas (ALSAC *et al.*, 1998; VEMPATI; SILVA *et al.*, 2005).

#### 4.9.2 Aspectos Quantitativos

Nesta seção, são detalhados os aspectos quantitativos para comparar as propriedades numéricas das soluções MCC via Equação (3.26) e a abordagem proposta

MCC+G3M. A comparação é baseada na determinação do número de condicionamento (GOLUB; VAN LOAN, 2012; CHEN, 1999) associado às equações da solução final de ambos os métodos, isto é, comparam-se os condicionamentos numéricos das matrizes ( $H^T WH$ ) da Equação (3.26) e ( $U$ ) da Equação (4.9).

O experimento do cálculo do número de condicionamento é realizado através do sistema-teste do IEEE de 30 barras, com dois esquemas de medição: (i) uma condição de redundância das medidas extremamente baixa para a qual o índice de redundância é igual a 1, e referida como *caso crítico*; e (ii) sob a condição de redundância grande para as medidas, sendo o suficiente para permitir a execução do processamento de erros grosseiros, denotada como *condição redundante*. A Tabela 4.7 apresenta os resultados para ambos os métodos na condição de redundância crítica e na ausência de medidas errôneas para as três iterações requeridas para a convergência. Os resultados na tabela mostram claramente que o Estimador MCC resolvido pela Equação (3.26) é susceptível à instabilidade numérica devido ao mecanismo de reponderação. Por outro lado, a matriz ( $U$ ) é muito melhor condicionada em todas as iterações quando comparada à matriz ( $H^T WH$ ). É também mostrado na Tabela 4.7 que o número de condicionamento da metodologia proposta alcança menos que 0,05% do valor do número obtido para a solução do Estimador MCC via equação normal com reponderação.

Tabela 4.7 – Número de condicionamento ( $Cond(\cdot)$ ) para o cálculo do vetor de incrementos do vetor de estados em cada iteração considerando 59 medidas ( $\rho = 1$ )

Iteração	MCC Eq. (3.26)	MCC+G3M Eq. (4.9)	$\frac{Cond(MCC + G3M)}{Cond(MCC)} \times 100$
1	$7,40 \times 10^4$	35,31	0,048%
2	$8,72 \times 10^4$	37,56	0,043%
3	$8,73 \times 10^4$	37,40	0,043%

Adicionalmente, simulações são realizadas no sistema-teste do IEEE de 30 barras considerando um plano de medição mais redundante ( $\rho = 3,12$ ) e com medidas livre de erros grosseiros. A Tabela 4.8 mostra os resultados do número de condicionamento para ambos métodos de estimação de estados sobre a condição redundante. Novamente, os dois estimadores convergem em três iterações, e pode-se notar que ao melhorar a redundância das medidas, o número de condicionamento das referidas matrizes também melhora, embora marginalmente. Entretanto, os valores relativos de condicionamento entre os dois métodos sofrem pouca alteração.

Finalmente, uma simulação é realizada considerando a presença de medida errônea no conjunto de medidas. A Tabela 4.9 apresenta os resultados quando uma medida de magnitude de tensão na barra 11 é contaminada por erros grosseiros, cuja magnitude é igual a 20 desvios-padrão da medida. De modo a eliminar os efeitos

Tabela 4.8 – Número de condicionamento ( $Cond(\cdot)$ ) para o cálculo do vetor de incrementos do vetor de estados em cada iteração considerando 184 medidas ( $\rho = 3, 12$ )

Iteração	MCC Eq. (3.26)	MCC+G3M Eq. (4.9)	$\frac{Cond(MCC + G3M)}{Cond(MCC)} \times 100$
1	$5,71 \times 10^4$	30,00	0,053%
2	$6,47 \times 10^4$	33,61	0,052%
3	$6,47 \times 10^4$	33,47	0,052%

dos erros grosseiros, larguras pequenas de janelas de Parzen são aplicadas pra esta simulação. Como consequência, o Estimador MCC baseado na Equação (3.26) não converge, enquanto o estimador baseado nas rotações de Givens e da Equação (4.9) leva duas iterações para a convergência com valores aceitáveis para o número de condicionamento da matriz ( $\mathbf{U}$ ) quando comparados com os resultados da Tabela 4.8, obtidos em uma condição de ausência de erros grosseiros.

Tabela 4.9 – Número de condicionamento ( $Cond(\cdot)$ ) com erro grosseiro em medida de magnitude de tensão ( $\rho = 3, 12$ )

Iteração	MCC Eq. (3.26)	MCC+G3M Eq. (4.9)	$\frac{Cond(MCC + G3M)}{Cond(MCC)} \times 100$
1	$3,20 \times 10^5$	123,84	0,039%
2	–	126,63	–

#### 4.10 CONCLUSÃO

Este capítulo introduz o algoritmo ortogonal de estimação robusta de estados baseado no critério de máxima correntropia. O princípio deste método é de garantir propriedades de resiliência ao estimador de estados, no que diz respeito à determinação de estimativas confiáveis mesmo na presença de medidas portadoras de erros grosseiros. Para tal, o algoritmo de solução do problema proposto é combinado com as propriedades de robustez numérica inerentes ao método ortogonal de resolução, baseado na versão do algoritmo de rotações de Givens com três multiplicadores.

A formulação do problema assegura que os pesos que processam as medidas sejam computados de acordo com as características da correntropia, garantindo que medidas as quais não condizem com a condição de operação real do sistema tenham seus erros atenuados no processo de otimização, e portanto não afetem a estimação de estados da rede elétrica. Para tal, uma estratégia de ajuste das janelas de Parzen é realizada a cada iteração do método de estimação, para que assim sejam levados em consideração as características de cada medida. Do mesmo modo, deve ser dado um tratamento adequado aos *outliers* identificados ao longo do processo de estimação.

Nestas condições, o uso das técnicas de máximo resíduo normalizado e da estimativa para a magnitude do erro em termos de desvios-padrão são empregadas nas atualizações das larguras dos *kernels* Gaussianos.

O método proposto é aplicado a uma sistema de três barras, com o objetivo de ilustrar as propriedades de robustez face à presença de erros grosseiros, assim como o desempenho numérico do algoritmo ortogonal-sequencial. Os resultados deste estudo de caso para o sistema de pequeno porte evidenciam as boas características de convergência e bom desempenho da estratégia proposta. Do mesmo modo, são apresentados resultados comparativos entre o método ortogonal proposto nesta tese e o método convencional de solução do MCC no que concerne ao condicionamento numérico das matrizes envolvidas nos respectivos processos de solução. Os resultados obtido mostram que a aplicação das rotações de Givens garante maior estabilidade numérica do que a solução obtida mediante à aplicação da versão com reponderação de medidas da equação normal.

A utilização das rotações de Givens também permite incluir recursos usualmente empregados no problema de estimação de estados em sistemas de potência, como é o caso das informações *a priori* de estado. O Capítulo 5 apresenta a extensão do modelo de correntropia resolvido através da técnica ortogonal para permitir processar medidas fasoriais sincronizadas através de um estimador híbrido, resiliente à presença de erros grosseiros e numericamente robusto.

## 5 ESTIMADOR HÍBRIDO MCC: PROCESSAMENTO DE MEDIDAS FASORIAIS SINCRONIZADAS

### 5.1 INTRODUÇÃO

A inclusão de medidas fasoriais sincronizadas na estimação de estados é uma importante contribuição da evolução tecnológica recente à monitoração em tempo real de sistemas de potência. É de fato reconhecido que estas medidas, obtidas através dos dispositivos de unidade de medição fasorial (PMU) e distribuídos pela rede elétrica, podem melhorar significativamente a qualidade das estimativas para os estados quando combinadas com medidas convencionais fornecidas pelo sistema SCADA.

Durante a última década, vários trabalhos foram realizados para desenvolver metodologias eficientes visando a integração de tais medidas na estimação de estados, como os métodos abordados por (ZHOU *et al.*, 2006; SIMÕES COSTA; ALBUQUERQUE, 2011; SIMÕES COSTA; ALBUQUERQUE; BEZ, 2013; DUBEY; CHAKRABARTI; SHARMA *et al.*, 2019; DUBEY; CHAKRABARTI; TERZIJA, 2019; BEZ *et al.*, 2020). Uma preocupação frequentemente relatada na literatura e que está relacionada ao desenvolvimento de estimadores híbridos é a importância de preservar o estimador de estados existente baseado nas medidas SCADA. Aparte a óbvia importância econômica do retorno de investimentos feitos no passado na tecnologia convencional, a conservação do estimador tradicional é conveniente devido ao fato que a distribuição de medidas PMUs não garante, pelo menos até o momento, uma execução segura de um estimador de estados baseado puramente nestas medidas. Consequentemente, medidas fasoriais devem ser processadas separadamente por um estimador dedicado, sendo que os resultados são de alguma forma combinados com as estimativas baseadas no sistema SCADA, fornecidos pelo algoritmo tradicional MQP. Embora arquiteturas de estimação híbrida como a descrita acima já tenham sido contempladas na literatura (ver referências acima), o processamento de erros grosseiros em conexão com estas permanecem como um problema a ser resolvido.

Este Capítulo aborda uma nova estratégia direcionada ao processamento de erros grosseiros no problema de estimação híbrida de estados em sistemas elétricos de potência, baseada na aplicação no critério de máxima correntropia (MCC). Com o objetivo de evitar a necessidade de estágios de pós-processamento para a execução dos procedimentos de identificação e remoção de erros grosseiros (modo tradicional para o tratamento de medidas errôneas), propõe-se uma estratégia que visa eliminar automaticamente a influência dos erros grosseiros durante o processamento das medidas e dentro do seu próprio estágio de estimação. Utilizando as propriedades da correntropia e dos conceitos das janelas de Parzen descritos nos capítulos anteriores deste trabalho, a metodologia proposta fornece uma particularidade interessante para processar medidas SCADA e PMU, que é a capacidade de filtrar erros grosseiros em

ambos os conjuntos de medidas.

A organização deste capítulo prossegue da seguinte forma: a Seção 5.2 descreve a estratégia de estimação em dois estágios para processar medidas fasoriais sincronizadas e manter o estimador MQP tradicional; a extensão do problema de estimação de estados baseado no critério MCC para a inclusão de informações *a priori* de estados, assim como sua solução pelo algoritmo ortogonal das rotações de Givens, é abordado na Seção 5.3; e as Seções 5.4 e 5.5 tratam, respectivamente, da estratégia de eliminação de *outliers* durante a execução do estimador de estados MCC e a metodologia para o rastreamento de erros grosseiros em medidas SCADA a partir dos resultados do estimador híbrido.

## 5.2 ESTRATÉGIA DE ESTIMAÇÃO EM DOIS ESTÁGIOS

Para levar em consideração a transição entre os estimadores de estados baseados nas tecnologias de medição SCADA e PMU, a metodologia proposta para a arquitetura híbrida considera que as medidas convencionais são processadas por um estimador MQP existente dotado da capacidade de processar de erros grosseiros por meio de técnicas tradicionais de detecção, identificação e eliminação de medidas espúrias. Contudo, a possibilidade do resultado da estimação estar contaminado por erros grosseiros não está totalmente descartada, seja pela presença de medidas errôneas que são críticas ou conformidade entre erros grosseiros (ABUR; GOMEZ EXPOSITO, 2004). Portanto, a saída ainda pode ser examinada através de uma nova inspeção. A última etapa descrita pode ser realizada em um segundo módulo de estimação que processa simultaneamente as estimativas baseadas no sistema SCADA, tratadas como Informações *A Priori* de Estados (APSI) (SWERLING, 1971; SIMÕES COSTA; LOURENÇO; VIEIRA, 2005; LOURENÇO, 2001), e medidas fasoriais. Este estágio é totalmente baseado no método MCC, cujas propriedades de filtragem associadas permitem que o estimador forneça estimativas isentas dos efeitos de quaisquer erros grosseiros, estejam eles presentes em medidas tradicionais ou em medidas fasoriais sincronizadas.

Os bons resultados obtidos por meio do estimador MCC permitem a construção de uma metodologia para rastrear medidas suspeitas de conter erros grosseiros dentro do subconjunto de medições do SCADA. Trata-se de uma análise sobre as informações *a priori* de estados que foram eliminadas pelo estimador MCC durante o processo de estimação, para permitir um diagnóstico direto sobre as estimativas incorretas provenientes do estimador convencional MQP. Desta forma, a abordagem adicional baseia-se na aplicação de testes de hipóteses sobre os resultados do estimador MCC para identificar possíveis medidas errôneas provenientes do sistema SCADA e não eliminadas em seu estágio de processamento de erros grosseiros. Com isto, além de prevenir estimativas errôneas pelo estimador MCC devido a medidas fasoriais



inconsistentes, é possível identificar erros grosseiros em medidas convencionais que produziram estimativas *a priori* inconsistentes com a real operação da rede elétrica.

A arquitetura híbrida de dois estágios de estimação apresentada nesta seção é similar à proposta em (SIMÕES COSTA; ALBUQUERQUE, 2011), porém, difere em dois aspectos fundamentais: primeiro, os estimadores utilizados em (SIMÕES COSTA; ALBUQUERQUE, 2011) são ambos baseados no algoritmo convencional MQP, com sua familiar sensibilidade à presença de erros grosseiros no conjunto de medidas, sendo suposto que ambos os conjuntos de dados são isentos de tais erros. A presente tese busca suprir esta lacuna, mediante o emprego de um o estimador de estados baseado no critério MCC no segundo estágio de estimação, com o objetivo de melhorar a robustez do estimador híbrido face à ocorrência de medidas grosseiras. Em segundo lugar, a possibilidade de rastrear erros grosseiros no subconjunto de medidas SCADA dota a metodologia proposta de uma funcionalidade adicional, tornando-a capaz de lidar com situações mais realistas. O método de identificação de medidas convencionais será abordado nas seções seguintes.

A estrutura do estimador híbrido é apresentada na Figura 5.1. O primeiro estágio de estimação é o estimador baseado no sistema SCADA, resolvido de acordo com o método tradicional MQP. Nesta etapa, nenhuma restrição é imposta. A saída deste módulo de estimação consiste no vetor de estados estimados baseado no sistema SCADA,  $\hat{\mathbf{x}}_s$ , e a correspondente matriz de covariância dos erros de estimação,  $\Sigma_s$ , calculada conforme a Equação (2.23). O vetor  $\hat{\mathbf{x}}_s$  e os elementos da diagonal de  $\Sigma_s$  são então tratados, respectivamente, como informações *a priori* de estado e suas variâncias correspondentes (PICALLO *et al.*, 2018), no segundo módulo de estimação, no qual são processadas as medidas fasoriais.

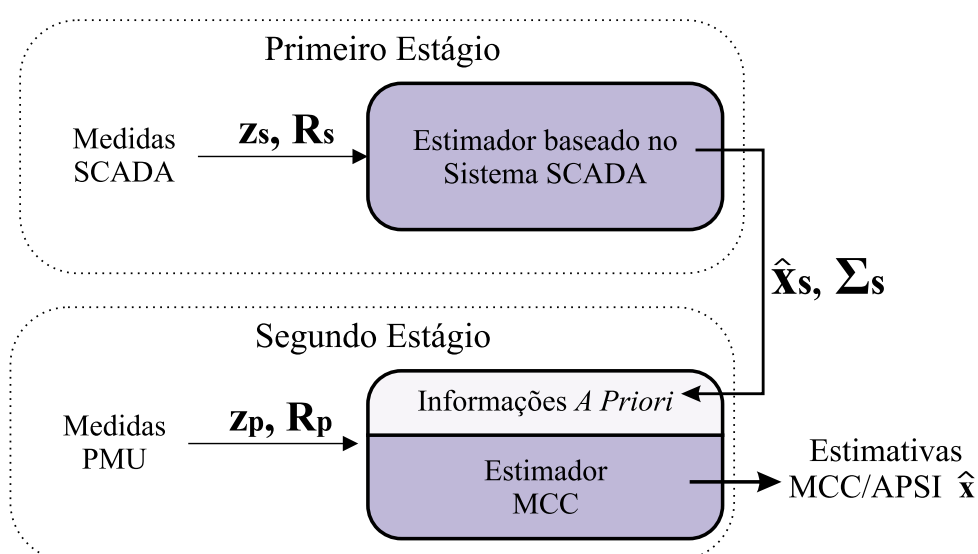


Figura 5.1 – Arquitetura para o Estimador MCC/APSI

O segundo estágio mostrado na Figura 5.1 é o Estimador MCC de Estados

com capacidade de processar informações *a priori* (MCC/APSI). Vê-se na figura que medidas processadas por este estimador são restritas àquelas obtidas pelo Sistema de Medição Fasorial Sincronizada, e as estimativas baseadas no sistema SCADA são incluídas como informações *a priori*.

Algumas observações devem ser feitas sobre a arquitetura proposta de dois estágios:

- (i) É assumida a observabilidade da rede elétrica com respeito às medidas SCADA, porém não é necessário que o sistema seja totalmente observável considerando somente as medidas fasoriais. Esta condição de relaxamento sobre a observabilidade com relação às medidas PMU é justificada pelo fato de que as medidas SCADA já asseguram a observabilidade da rede elétrica. Isto se torna particularmente atrativo uma vez que, na maioria dos sistemas de potência, a penetração de PMUs ainda é limitada;
- (ii) A existência de PMUs instaladas em uma parte da rede elétrica melhora os resultados sobre as estimativas locais dos estados, pois sabe-se que a exatidão de tais medidas tende a ser melhor do que das medidas SCADA;
- (iii) O elevado grau de redundância nas regiões da rede elétrica que contam com a disponibilidade de medidas fasoriais melhora as propriedades de filtragem do Estimador MCC/APSI;
- (iv) As dificuldades expressas pelas superiores taxas de amostragem das medidas PMU com relação ao sistema SCADA podem ser contornadas através de metodologias especializadas capazes de lidar com a diferença das taxas de amostragem entre os dois sensores (ZHANG *et al.*, 2013; ZHAO; WANG *et al.*, 2018). Tais metodologias tornam possível a execução de um processo de estimação de estados baseado em um conjunto de medidas composto por dados dos sistemas SCADA e PMU que produz estimativas que melhor descrevem a atual condição de operação do sistema elétrico. Entretanto, neste trabalho são considerados conjuntos de medidas SCADA e PMU cujas quantidades de medidas retratam o mesmo ponto de operação do sistema, e não possuem diferença temporal entre os vetores obtidos para os dois tipos de sensores;
- (v) A perda ocasional de medidas PMU não compromete a capacidade do estimador em dois estágios proposto em fornecer resultados válidos. No pior cenário, é garantida a solução obtida somente pelas medidas convencionais.

As características do modelo do Estimador MCC/APSI, assim como do algoritmo de solução, são descritas na seção seguinte.

### 5.3 MODELO MCC DE INFORMAÇÕES DE ESTADOS A PRIORI

As informações de estados *a priori* (APSI) têm sido empregadas com sucesso quando aplicadas em conexão com as abordagens MQP para resolver o problema EESP (DO COUTTO FILHO; STACCHINI DE SOUZA, 2009; SIMÕES COSTA; LOURENÇO; VIEIRA, 2005). O vetor informado, usualmente denotado por  $\bar{\mathbf{x}}$ , consiste de informações sobre às variáveis de estado que podem de alguma forma contribuir para reforçar a observabilidade do sistema ou para melhorar a qualidade do processo de estimação. Uma vez que o conjunto APSI é formado por variáveis aleatórias, a matriz de covariância  $\Sigma_0$  é atribuída ao vetor  $\bar{\mathbf{x}}$  com o objetivo de quantificar o nível de confiança dos dados *a priori*.

As propriedades do critério de máxima correntropia, que são aplicadas ao conjunto de medidas, podem ser estendidas para incluir as informações *a priori* ao estimador MCC de estados da Equação (3.19). Desta forma, ao maximizar a correntropia entre as medidas e as quantidades estimadas para as medidas, o estimador proposto procura adicionalmente maximizar a correntropia entre  $\hat{\mathbf{x}}$  e  $\bar{\mathbf{x}}$ . Para levar em consideração os distintos níveis de confiança sobre o vetor  $\bar{\mathbf{x}}$ , os valores inversos dos elementos da diagonal da matriz  $\Sigma_0$  são utilizados como pesos. Portanto, o problema do Estimador MCC em (3.19) pode ser estendido para incluir dados APSI através da adição de um termo na função-objetivo:

$$\max_{\hat{\mathbf{x}}} J_{MCC/APSI} = \sum_{i=1}^m R_{ii}^{-1} e^{-\frac{(z_i - h_i(\hat{\mathbf{x}}))^2}{2\sigma^2_i}} + \sum_{j=1}^n \Sigma_{jj}^{-1} e^{-\frac{(\bar{x}_j - \hat{x}_j)^2}{2\bar{\sigma}_j^2}} \quad (5.1)$$

onde  $\bar{\sigma}_j$  é a largura da janela de Parzen relacionada à informação *a priori* de estado  $\bar{x}_j$ .

Aplicando as condições de otimalidade ao problema da Equação (5.1) do mesmo modo como é feito para resolver (3.19), é possível mostrar que a solução do estimador MCC aumentado pode ser obtida através da resolução do seguinte sistema linear a cada iteração:

$$\left[ \mathbf{H}^T \mathbf{W} \mathbf{H} + \mathbf{V} \right] \Delta \mathbf{x} = \mathbf{H}^T \mathbf{W} \Delta \tilde{\mathbf{z}} + \mathbf{V} \Delta \tilde{\mathbf{x}} \quad (5.2)$$

em que:

$$\begin{aligned} \mathbf{V} &= \mathbf{L}[\mathbf{I} - \mathbf{M}_W] & ; & \quad M_W(j, j) = (\bar{x}_j - \hat{x}_j)^2 / \bar{\sigma}_j^2; \\ \Delta \tilde{\mathbf{x}} &= [\mathbf{I} - \mathbf{M}_W]^{-1} \Delta \bar{\mathbf{x}} & ; & \quad L_{jj} = \frac{\Sigma_{jj}^{-1}}{\bar{\sigma}_j^2} e^{-(\bar{x}_j - \hat{x}_j)^2 / 2\bar{\sigma}_j^2}. \end{aligned} \quad (5.3)$$

Nas equações acima,  $\Delta \bar{\mathbf{x}} = (\bar{\mathbf{x}} - \mathbf{x}^k)$ . As matrizes diagonais  $\mathbf{W}$ ,  $\mathbf{D}$ ,  $\mathbf{R}_W$  e o vetor  $\Delta \tilde{\mathbf{z}}$  são determinadas, respectivamente, pelas equações (3.22), (3.25), (3.27) e (3.28), e  $\mathbf{I}$  é a matriz identidade com dimensões apropriadas.

O problema resolvido pela Equação (5.2) é denotado como Estimador MCC/APSI de Estados. Desconsiderando as correlações entre os elementos de  $\Delta \bar{\mathbf{x}}$ , a matriz  $\Sigma_0$

reduz-se a uma matriz diagonal, cuja  $j$ -ésima entrada, descrita por  $\Sigma_0(j, j)$ , é a variância da informação *a priori* de estado  $\bar{x}_j$  (SWERLING, 1971; SIMÕES COSTA; LOURENÇO; VIEIRA, 2005; PICALLO *et al.*, 2018).

A inclusão de APSI sob o modelo MCC permite que o mesmo tratamento dado às medidas seja empregado às informações *a priori*. Portanto, na execução deste estimador proposto, dados compatíveis com a atual condição operacional são processados para melhorar a qualidade das estimativas, enquanto *outliers* são automaticamente rejeitados, seja qual for o tipo de dado, isto é, medida ou APSI.

A Equação (5.2) é similar à versão estendida da equação normal do estimador MQP convencional (SIMÕES COSTA; ALBUQUERQUE, 2011; DO COUTTO FILHO; STACCHINI DE SOUZA, 2009), a qual é reconhecidamente susceptível a mal-condicionamento numérico (HOLTEN *et al.*, 1988; WU, 1990). Nesta aplicação em particular, este problema pode ser potencialmente aumentado pelo fato de que todos os pesos para os dados em processamento são dinamicamente atualizados ao longo das iterações. Para prevenir tais dificuldades, são aplicadas as técnicas ortogonais para resolver o problema de estimação MCC/APSI, no lugar de resolver explicitamente a Equação (5.2). Detalhes da aplicação do algoritmo ortogonal considerando APSI são descritas a seguir.

### 5.3.1 Processamento de APSI por Algoritmo Ortogonal

A inclusão de informações de estados *a priori* parte dos procedimentos descritos sobre as rotações elementares das rotações rápidas de Givens (SIMÕES COSTA; LOURENÇO; VIEIRA, 2005) em função das propriedades de correntropia, relatadas na Capítulo 4, Seção 4.4. De acordo com os fatores de ponderação associados às medidas, determinados a partir do modelo MCC, é relevante interpretar o valor do peso  $t$  da matriz diagonal  $\mathbf{T}$ . Este valor está associado às linhas da matriz triangular superior unitária  $\mathbf{U}$ , o que sugere um peso, também em termos das propriedades de correntropia, relacionado aos estados do problema, pois conforme a Equação (4.8), nota-se que a quantidade de pesos  $t$  é a mesma de variáveis de estado. Com isto, os valores iniciais de  $t_i$  devem ser atribuídos aos estados antes do processamento de qualquer medida. Em outras palavras,  $t_i$  é um fator de ponderação que empresta certo grau relevância dentro do processo de otimização a uma informação *a priori* disponível para a variável de estado  $x_i$ .

A determinação do grau de relevância é definido com base nos conceitos de distância *CIM* e similaridade generalizada (ou correntropia) entre as variáveis de estado estimadas e as informações *a priori* existentes sobre elas, detalhadas e modeladas no Capítulo 3, Seção 3.2. Portanto, assim como no processamento das medidas, a similaridade é computada dentro de um *kernel* Gaussiano, com o objetivo de extrair a máxima quantidade de informações sobre os dados *a priori*. Desta forma, a matriz

inicial  $\mathbf{T}^0$ , e conseqüentemente os valores de  $t^0$ , tem por base as correspondentes entradas da matriz  $\mathbf{V}$  calculada de acordo com as Equações (5.3), e portanto, isto leva à conclusão que:

$$t_j^0 = V_{jj} = L_{jj} [1 - M_{W, jj}] \quad (5.4)$$

onde  $L_{jj}$  e  $M_{W, jj}$  são pesos estabelecidos no processo otimização e definidos nas equações matriciais em (5.3).

Dessa maneira, a informação prévia sobre os estados pode ser facilmente atribuída, sem custo computacional, no processo das rotações rápidas de Givens inicializando o elemento extra em  $u_{n+1}$  da Equação (4.10) como  $\Delta\tilde{x}_j = \Delta\bar{x}_j / (1 - M_{W, jj})$ , e  $t_j = V_{jj}$  como mostrado na Equação (5.4). Considerando agora que o processo de maximização da correntropia deve ser inicializado com uma largura do *kernel* Gaussiano suficientemente grande para abranger todos os erros aleatórios (o que corresponde em atribuir a norma  $L_2$  à medida de similaridade entre os vetores) então os fatores  $M_{W, jj}$  tendem a valores próximos de zero conforme sua definição na Equação (5.3). Portanto considera-se que no início do processo de estimação de estados tem-se que  $\Delta\tilde{x}_j \cong \Delta\bar{x}_j$ . Logo, realizando uma analogia com a Equação (4.9), a inicialização é dada por:

$$\mathbf{U}^0 \mathbf{x}^0 \cong \bar{\mathbf{x}} \quad (5.5)$$

em que  $\mathbf{x}^0$  é o vetor inicial para os estados, o vetor  $\bar{\mathbf{x}}$  está relacionado com os valores relacionados às informações *a priori* de estado, e a matriz  $\mathbf{U}^0$  é inicializada como uma matriz diagonal unitária ( $u_{jj}^0 = 1, 0$ ) (GENTLEMAN, 1973; SIMÕES COSTA; LOURENÇO; VIEIRA, 2005).

Durante o processo de otimização, a presença de informações *a priori* que não refletem corretamente estimativas válidas para os respectivos estados geram erros que serão atribuídos às normas  $L_1$  ou  $L_0$  através das propriedades da correntropia, com impacto direto sobre a matriz  $\mathbf{V}$ , e logo em  $\mathbf{T}^0$ . Enfatiza-se que a matriz  $\mathbf{V}$ , assim como  $\mathbf{W}$ , deve ser manter definida positiva. Caso se verifique um peso  $V_{jj} \leq 0$  para uma informação *a priori*  $\bar{x}_j$ , isto equivale a dizer que o dado  $\bar{x}_j$  porta-se como um “erro grosseiro” perante seu estado estimado  $\hat{x}_j$ . Desta forma, esta informação *a priori* deve ser excluída do processo de estimação.

Similarmente ao caso do processamento de medidas identificadas com erros grosseiros, que não precisam ser rotacionadas pelo algoritmo das rotações rápidas de Givens, a exclusão da APSI  $\bar{x}_j$  é feita a partir da inicialização do seu respectivo peso como  $t_j^0 = 0$  na matriz  $\mathbf{T}^0$ , enquanto na matriz diagonal unitária  $\mathbf{U}^0$  faz-se  $u_{jj}^0 = 1, 0$ . Isto deve ser interpretado como a inexistência de conhecimento prévio sobre o valor inicial para o estado  $x_j$ , ou seja, o processo de estimação de estados torna-se indiferente ao valor de  $\bar{x}_j$ .

A técnica descrita neste trabalho para a inclusão das informações de estado *a priori*, no que diz respeito a sua modelagem adicionada ao Estimador MCC, assim

como a possibilidade da inclusão nas rotações rápidas de Givens sem custo computacional adicional, são vistas como uma forma atrativa de processar dados de diferentes naturezas pelo estimador de estados. Neste aspecto, o segundo estágio da arquitetura de estimação híbrida é composto por esta ferramenta, que permite processar simultaneamente medidas obtidas de dispositivos PMU e APSI, como resultado do primeiro módulo MQP de estimação.

#### 5.4 PROCESSAMENTO DE *OUTLIERS* VIA ESTIMADOR HÍBRIDO

A técnica das janelas de Parzen associada ao Estimador MCC é também aplicada para suprimir automaticamente os efeitos de possíveis *outliers* presentes em APSI. Para as medidas PMU, a atualização das larguras dos *kernels* Gaussianos é realizada conforme detalhada no Capítulo 4, Seção 4.6, com a qual é possível eliminar simples ou múltiplos erros grosseiros. Com relação às informações *a priori*, dados errôneos sobre as variáveis de estado são produzidas por erros grosseiros presentes no sistema SCADA e não removidos no primeiro estágio de estimação. Consequentemente, ocorre a situação em que a presença de um único erro grosseiro pode contaminar não somente um estado, mas um conjunto de estimativas fornecidas pelo estimador MQP.

A questão abordada acima revela que erros grosseiros não eliminados no primeiro estágio de estimação (*ver figura 5.1*) são mais severos para as informações *a priori* devido ao efeito de espalhamento do erro de alta magnitude. Diferentemente da estratégia de ajuste aplicada às medidas fasoriais, a atualização dos *kernels* Gaussianos para APSI é baseada no valor do máximo erro absoluto para cada classe de variável de estado. Isto leva à distintas larguras das janelas de Parzen aplicadas às magnitudes de tensão e a ângulos de tensão nodal, conforme as seguintes equações:

$$\begin{aligned}\bar{\sigma}_{\theta}^{(k+1)} &= \max_i |\bar{\theta}_i - \hat{\theta}_i|, \quad i \in \{1, \dots, N\} \setminus \mathcal{S}_{\theta}^k \\ \bar{\sigma}_V^{(k+1)} &= \max_i |\bar{V}_i - \hat{V}_i|, \quad i \in \{1, \dots, N\} \setminus \mathcal{S}_V^k\end{aligned}\tag{5.6}$$

onde  $\mathcal{S}_{\theta}$  e  $\mathcal{S}_V$  são subconjuntos para índices de *outliers* relacionados à informações *a priori* de ângulo e magnitude de tensão, respectivamente, atualizados a cada atual iteração  $k$ . Ambos os subconjuntos são inicializados como o conjunto vazio.

De acordo com a aplicação das regras de atualização das janelas de Parzen por meio das Equações (4.15), (4.16) e (5.6), o Estimador MCC/APSI produz, como resultado, resíduos tanto para medidas PMUs quanto para variáveis *a priori* de estado. Portanto, a identificação de *outliers* recai na comparação direta destes resíduos com as correspondentes larguras das janelas de Parzen. Desta forma, se o valor absoluto do resíduo for maior que a respectiva largura do *kernel* Gaussiano, eles são tratados como *outliers*, sejam eles ocorridos no conjunto de medidas PMU ou das informações

*a priori* de estado. Caso contrário, estes dados são considerados como informações válidas.

## 5.5 RASTREAMENTO DE ERROS GROSSEIROS EM MEDIDAS CONVENCIONAIS

Embora as metodologias de processamento de erros grosseiros para os estimadores de estados convencionais sejam consideradas eficientes, seus desempenhos dependem fortemente de hipóteses de boa redundância das medidas disponíveis ao estimador (MONTICELLI; GARCIA, 1983; ZHONG; ABUR, 2005; TOYOSHIMA *et al.*, 2012; CUTSEM; RIBBENS-PAVELLA; MILI, 1984). Infelizmente, entretanto, podem ocorrer circunstâncias onde a redundância das medidas em partes da rede elétrica é baixa, e não assegura a correta execução do estágio de detecção e identificação de erros grosseiros. Considerando a proposta de arquitetura de estimação híbrida deste capítulo, a possibilidade de erros grosseiros indevidamente não eliminados no primeiro nível de estimação produz erros sobre as informações *a priori* de estado, que são levadas ao segundo estágio. Após o processamento simultâneo de tais informações com as medidas PMUs, espera-se uma solução que esteja livre da influência de qualquer erro grosseiro. Portanto, esta seção apresenta uma metodologia para identificar erros grosseiros em medidas convencionais a partir dos resultados do Estimador MCC/APSI.

### 5.5.1 Símbolos e Nomenclatura Específica

Para delinear o método proposto, uma nomenclatura específica é definida para os principais vetores e matrizes empregados no processo de rastreamento. As medidas SCADA e as estimativas sobre os estados fornecidas pelo estimador MQP são denotadas aplicando o subscrito  $S$ , enquanto as quantidades computadas utilizando o resultado do estimador MCC/APSI ( $\hat{\mathbf{x}}_{MCC}$ ) são indicadas pelo subscrito  $MCC$ . O primeiro estágio de estimação fornece valores estimados para quantidades medidas:

$$\hat{\mathbf{z}}_{SS} = \mathbf{h}_S(\hat{\mathbf{x}}_S). \quad (5.7)$$

Adicionalmente, com as estimativas obtidas no segundo módulo de estimação, as equações não-lineares das medidas convencionais podem ser avaliadas com respeito ao vetor de estados estimados  $\hat{\mathbf{x}}_{MCC}$ , de acordo com:

$$\hat{\mathbf{z}}_{SMCC} = \mathbf{h}_S(\hat{\mathbf{x}}_{MCC}). \quad (5.8)$$

Os resíduos das medidas correspondentes relacionadas às Equações (5.7) e (5.8) são respectivamente:

$$\mathbf{r}_{SS} = \mathbf{z}_S - \hat{\mathbf{z}}_{SS} \quad (5.9)$$

$$\mathbf{r}_{SMCC} = \mathbf{z}_S - \hat{\mathbf{z}}_{SMCC} \quad (5.10)$$

cujas respectivas matrizes de covariância são dadas por:

$$\mathbf{\Omega}_{SS} = \mathbf{R}_S - \mathbf{H}_{SS} \mathbf{\Sigma}_{SS} \mathbf{H}_{SS}^T \quad (5.11)$$

$$\mathbf{\Omega}_{SMCC} = \mathbf{R}_S - \mathbf{H}_{SMCC} \mathbf{\Sigma}_{SMCC} \mathbf{H}_{SMCC}^T \quad (5.12)$$

onde as matrizes Jacobianas são  $\mathbf{H}_{SS} = \mathbf{H}_{SMCC} = \partial \mathbf{h}_S / \partial \mathbf{x}$ , porém computadas nos pontos  $\mathbf{x} = \hat{\mathbf{x}}_S$  e  $\mathbf{x} = \hat{\mathbf{x}}_{MCC}$ , respectivamente; e  $\mathbf{\Sigma}_{SS} = (\mathbf{H}_{SS}^T \mathbf{R}_S^{-1} \mathbf{H}_{SS})^{-1}$  e  $\mathbf{\Sigma}_{SMCC} = (\mathbf{H}_{SMCC}^T \mathbf{R}_S^{-1} \mathbf{H}_{SMCC})^{-1}$ .

Finalmente, os elementos dos vetores de resíduos nas Equações (5.9) e (5.10) são submetidos à seguinte normalização:

$$r_{SS}^N(i) = \frac{|r_{SS}(i)|}{\sqrt{\Omega_{SS}(i,i)}} \quad (5.13)$$

$$r_{SMCC}^N(i) = \frac{|r_{SMCC}(i)|}{\sqrt{\Omega_{SMCC}(i,i)}} \quad (5.14)$$

A metodologia descrita acima pode ser entendida como um artifício para rastreamento de erros grosseiros a partir de estimativas fornecidas por diferentes conjuntos de medidas, como os métodos detalhados em (DO COUTTO FILHO; STACCHINI DE SOUZA; GUIMARAENS, 2014; GUIMARAENS, 2015; GONÇALVES, 2016). O processo de detecção e identificação de erros grosseiros relatados nestes trabalhos faz o uso dois estimadores baseados em modelos convencionais de estimação para processar medidas SCADA e fasoriais de forma independente. Adicionalmente, a fusão de estimativas (SIMÕES COSTA; ALBUQUERQUE; BEZ, 2013) é empregada para produzir um vetor de estados estimados sobre o critério de mínima variância. Alternativamente, a abordagem descrita para compor as equações (5.13) e (5.14) difere dos trabalhos acima citados em dois aspectos importantes: primeiro que é estabelecida a dependência entre os estimadores de estados, uma vez que segundo módulo de estimação processa dados resultantes do estimador baseado em medidas SCADA como informação *a priori* de estados; e a segunda diferença é atribuída pela utilização do critério MCC no segundo módulo de estimação, que dispõe de características de resiliência face à presença de *outliers*.

### 5.5.2 Filtragem de Informações *A Priori* de Estado

Em caso de informação *a priori* contaminada por erro grosseiro, é de se esperar que segundo módulo de estimação forneça, como resultado, a indicação de inconsistência entre tais informações com respeito às estimativas dadas pelo processamento conjunto de medidas fasoriais e APSI. A capacidade de eliminação desses dados é possível através da aplicação das regras estabelecidas na Seção 5.4 sobre as janelas de Parzen. Desta forma, ao final da execução da rotina do estimador MCC/APSI, uma



ou mais variáveis *a priori* de estado podem ser automaticamente rejeitadas durante o processo iterativo se erros grosseiros estão presentes no subconjunto de medidas convencionais. Conseqüentemente, todas as medidas SCADA associadas a estas variáveis *a priori* de estado que foram eliminadas são então tomadas como suspeitas de conter erros grosseiros. A hipótese da construção de um grupo de medidas suspeitas tem por base os efeitos do espalhamento dos erros grosseiros presentes em medidas convencionais sobre APSI, que podem afetar não apenas as medidas contaminadas, mas também as medidas válidas (MONTICELLI, 1999). O processo de identificação de erros grosseiros em medidas SCADA é descrito a seguir.

### 5.5.3 Identificação de Erros Grosseiros em Medidas SCADA

A partir da disponibilidade do conjunto de medidas SCADA suspeitas de conter erros grosseiro, e denotado por  $\mathcal{S}_{SMCC}$ , a identificação das medidas errôneas pode ser realizada com base em um estudo sobre os resíduos normalizados das equações (5.13) e (5.14). É evidente que a normalização em (5.13) é o tradicional teste do máximo resíduo normalizado (LNRT) (MONTICELLI, 1999; KOGLIN *et al.*, 1990), como descrito no Capítulo 2, e portanto é empregado nesta seção para comparar com a metodologia proposta.

A identificação da medida SCADA errônea recai no seguinte teste de hipótese: se  $r_{SMCC}^N(i) > \lambda$ , onde  $\lambda$  é um limiar para um certo nível de significância, então a medida  $z_{S,i}$  é uma medida SCADA contaminada por erro grosseiro (GONÇALVES, 2016; DO COUTTO FILHO; STACCHINI DE SOUZA; GUIMARAENS, 2014). Considerando que somente as medidas presentes no conjunto  $\mathcal{S}_{SMCC}$  são submetidas ao teste de validação, espera-se, como resultado, que as quantidades expressas nos resíduos normalizados em  $r_{SMCC}^N$  sejam capazes de, simultaneamente, detectar e identificar os erros. Adicionalmente, os resultados da aplicação do teste de hipóteses ao vetor  $r_{SMCC}^N$  podem ser relacionados aos resultados da aplicação sobre o vetor  $r_{SS}^N$ , e portanto três possíveis resultados podem ser destacados para o apropriado diagnóstico de erros grosseiros através do cruzamento dos resultados do estimador MCC/APSI e resíduos de medidas convencionais:

1. Se ambos os testes de hipóteses violam o limiar pré-especificado, isto indica que há ocorrência de erros grosseiros no subconjunto de medidas SCADA. Neste caso, o resultado também indica que o processamento de erros grosseiros no primeiro estágio de estimação está desativado, pois os efeitos dos erros grosseiros são repassados às informações *a priori* de estado, e que evidentemente poderiam ser eliminados no primeiro nível de estimação. Considerando que a área é monitorada por medidas fasoriais sincronizadas, um ou múltiplos resíduos em  $r_{SMCC}^N$  que excedem o valor do limiar  $\lambda$  podem ser prontamente identificados

como erros grosseiros. A proposta de identificação implementada sobre  $\mathbf{r}_{SMCC}^N$  se torna atrativa pelo fato de que a identificação de todas as medidas SCADA errôneas pode ser realizada de uma só vez, ao invés de ciclos de execução do estimador MQP seguido do subsequente estágio de processamento de erros grosseiros;

2. Se somente o teste  $\mathbf{r}_{SMCC}^N$  aponta violação de quantidades de resíduos normalizados, isto indica que o subconjunto suspeito de medidas SCADA está contaminado por erros grosseiros e que a redundância dada pelas medidas convencionais sobre a rede elétrica não fornece condições para o apropriado desempenho do estágio de processamento de erros grosseiros. As propriedades de resiliência características do estimador MCC/APSI fazem com que sejam fornecidas estimativas livres de erros grosseiros, e portanto os valores de  $\hat{\mathbf{z}}_{SMCC}$  são considerados suficientemente confiáveis para validar suas respectivas quantidades medidas. Desta forma, a identificação de medidas SCADA errôneas pode ser realizada usando somente o teste do resíduo normalizado sobre  $\mathbf{r}_{SMCC}^N$ ;
3. Se ambos os testes de resíduo normalizado são negativos, isto indica que as medidas SCADA estão isentas de erros grosseiros.

#### 5.5.4 Observações

Os seguintes comentários adicionais aplicam-se ao método de identificação proposto:

- Pode-se notar que o teste de hipóteses aplicados ao vetor de resíduos normalizados  $\mathbf{r}_{SMCC}^N$  é suficiente para executar a identificação de erros grosseiros sobre o subconjunto de medidas SCADA, pois fornece informações confiáveis para validar as medidas. Por outro lado, a ocorrência de um resultado negativo do teste de hipóteses sobre o vetor  $\mathbf{r}_{SS}^N$  permite identificar regiões do sistema onde a redundância de medidas é baixa, o que prova a necessidade de uma maior investigação objetivando a melhoria do plano de medição naquela região da rede elétrica;
- Barras não-observáveis por medidas PMU possuem suas correspondentes estimativas MCC/APSI equivalentes às do estimador MQP baseado no sistema SCADA. Consequentemente, os resíduos entre as estimativas *a priori* de estado e os correspondentes valores de estados estimados para estas barras são nulos, o que inviabiliza o uso do método para identificar erros grosseiros nas medidas SCADA relacionadas a estas variáveis de estado não-observáveis por medidas fasoriais sincronizadas;

- Um caso particular envolve possíveis erros grosseiros em medidas de potência (injeções nas barras e fluxos de potência nos ramos) em barras que são observáveis por medidas PMU, mas sem a direta medição através de dispositivos PMUs instalados nestes barramentos. Considerando-se uma específica barra  $k$  nestas condições, com uma ou mais barras adjacentes não observáveis por PMUs, as medidas SCADA localizadas na barra  $k$  não podem ser identificadas através do teste de hipóteses sobre o vetor dos resíduos normalizados  $r_{SMCC}^N$ . Isto ocorre devido ao fato de que as correspondentes equações de medidas dependem também de variáveis de estado que são não-observáveis por medidas PMU.

## 5.6 CONCLUSÃO

Neste capítulo, é desenvolvida uma implementação híbrida baseada no critério de máxima correntropia (MCC), estendida para uma arquitetura de estimação de estados em dois estágios capaz de processar tanto medidas convencionais quanto medidas fasoriais sincronizadas. A arquitetura do estimador robusto tem por base um estimador convencional no primeiro estágio, que processa medidas SCADA, e um segundo estágio composto por um estimador MCC, que processa medidas PMU porém com capacidade de processar informações de estado *a priori* (APSI). Esta última funcionalidade permite integrar os resultados de ambos estimadores, fornecendo um aperfeiçoamento para as estimativas convencionais a partir do processamento dos dados de PMUs disponíveis.

O benefício de associar o conceito de correntropia à função-objetivo estendida do estimador híbrido MCC é a facilidade de suprimir *outliers* nas informações de estados *a priori*, da mesma forma como ocorre nas medidas fasoriais sincronizadas. Desta forma espera-se que a aplicação de tais propriedades de rejeição possam produzir estimativas para as variáveis de estados que estejam livres de erros grosseiros, tendo eles contaminado medidas SCADA ou PMU. Outra propriedade particularmente desejável é que a observabilidade da rede elétrica com respeito às medidas PMU não é exigida, desde que a observabilidade da rede elétrica seja garantida pelas medidas SCADA.

Um procedimento extra realizado a partir do resultado do estimador híbrido MCC é a identificação de erros grosseiros no subconjunto de medidas SCADA que gera as informações *a priori* para o estimador do segundo estágio. Este rastreamento das medidas SCADA errôneas é viabilizado mediante a combinação dos resultados das estimativas MCC/APSI aplicadas às equações de medidas convencionais, de forma a produzir diferentes resíduos estimados para as medidas. Desta forma, é possível aplicar teste de hipóteses sobre as medidas convencionais suspeitas e identificar qual ou quais delas estão contaminadas por erros grosseiros.

Para avaliar o desempenho do método, o algoritmo proposto é aplicado a um sis-

tema de pequeno porte para ilustrar as principais características do estimador, como o sistema-teste do IEEE de 14-barras, e à redes de maior porte e mais realísticas, como os sistemas-teste do IEEE de 57 e 118 barras, considerando diferentes condições de operação destes sistemas. Os resultados e discussões correspondentes são apresentados no Capítulo 6.

## 6 RESULTADOS DE SIMULAÇÃO

### 6.1 INTRODUÇÃO

Este capítulo é dedicado à apresentação dos resultados obtidos com a aplicação dos métodos de estimação de estados abordados nesta tese de doutorado. Na primeira parte, é avaliado o desempenho do algoritmo ortogonal de estimação MCC aplicando-o a sistemas de porte superior ao do exemplo ilustrativo do Capítulo 4. A seguir, são apresentados os resultados do estudo sobre o estimador híbrido, exibindo as principais características de resiliência do estimador.

O capítulo é organizado da seguinte forma: a Seção 5.2 aborda algumas considerações sobre os aspectos computacionais e da metodologia de simulações; a Seção 5.3 apresenta os resultados da aplicação do método do estimador ortogonal MCC. Resultados numéricos para a avaliação do desempenho do estimador híbrido MCC/APSI são apresentados na Seção 5.4. E uma análise geral dos resultados é discutida na Seção 5.5.

### 6.2 AMBIENTE DE SIMULAÇÃO E CONSIDERAÇÕES COMPUTACIONAIS

Um ambiente computacional foi desenvolvido na linguagem MATLAB para o desenvolvimento de todas as etapas do trabalho proposto. Anteriormente à aplicação do método de estimação de estados, foi desenvolvida uma série de casos com base nos sistemas-teste do IEEE de 14, 30, 57 e 118 barras, o que inclui:

- a) A construção de 10.000 cenários baseados em uma curva de carga proposta, cujos níveis de carregamento estão distribuídos em intervalos horários, classificando-os em patamares de demanda de carga leve, média e pesada. Desta forma, o sistema é submetido a um carregamento dentro da faixa de 70% a 100% do carregamento total;
- b) As simulações são diferenciadas com variação sobre os valores das cargas presentes em cada barra, realizada a partir da adição de um ruído Gaussiano, com um desvio-padrão de 3% do valor da carga;
- c) São realizados sorteios que culminam em diversas condições operativas de geração, baseados nas probabilidades de manutenção especificadas a cada unidade geradora e nos intervalos horários da curva de carga. Assim, realizam-se despachos econômicos para determinar a geração das unidades que estão em operação;
- d) Para cada cenário estipulado, é realizado o cálculo do fluxo de potência, que fornece os valores “verdadeiros” das variáveis de estado e dos parâmetros dos

sistemas-teste;

- e) Todas as simulações são realizadas usando uma configuração de CPU de 3,10 GHz, 8,0 GB de RAM Intel Core i5-4440, linguagem de programação Matlab e o modelo não linear completo para todos os sistemas-teste.

Os dados originais da rede elétrica, assim como os resultados de um fluxo de carga foram obtidos de (WASHINGTON, 2015).

Com relação aos planos de medição compostos pelas medidas que são processadas pelo estimador de estados e os parâmetros de inicialização, tem-se que:

- a) O plano de medição estipulado para medidas SCADA deve garantir a observabilidade da rede elétrica, embora possam existir medidas críticas e/ou conjunto de medidas críticas. Sabe-se que estas medidas afetam o desempenho de qualquer estimador de estados que processe erros grosseiros, e portanto é imprescindível o conhecimento da presença delas no plano de medição. Para tal, o plano de medição é submetido ao aplicativo *Plamed* (SIMÕES COSTA; PIAZZA; MANDEL, 1990; CIPRIANI; SIMÕES COSTA, 2010), desenvolvido em ambiente *FORTRAN*, que retorna informações sobre o plano de medição, concluindo se este está ou não isento das características citadas;
- b) As medidas são geradas pela superposição de erros aleatórios Gaussianos a valores das variáveis mensuráveis obtidos pelo fluxo de potência convergido;
- c) As variâncias das medidas processadas pelo estimador de estados são computadas da seguinte forma: considerando  $\mathcal{E}_i$  a exatidão assumida para o medidor  $i$ , as variâncias são computadas como

$$R_{ij} = (\mathcal{E}_i \cdot z_i)^2 + \mathcal{E}_i^2 \quad (6.1)$$

conforme prática corrente, proposta em (DOPAZO; KLITIN; VANSLYCK, 1972). Assume-se também que a exatidão  $\mathcal{E}$  das medidas SCADA é de  $3 \times 10^{-3}$  p.u. e  $2 \times 10^{-2}$  p.u. para magnitude de tensão e de potência, respectivamente, enquanto que para as medidas PMU a exatidão é de  $1 \times 10^{-3}$  p.u.;

- d) Assume-se a partida plana para os valores iniciais das variáveis de estado do processo iterativo, isto é, 1,0 p.u. para as magnitudes de tensão e 0,0 rad para os ângulos nas barras.

Para averiguar a efetividade dos métodos de estimação de estados, os sistemas-teste utilizados são submetidos a uma série de simulações, o que inclui a verificação do desempenho do algoritmo com e sem a presença de medidas espúrias. Quando pelo menos uma das medidas disponíveis ao estimador de estados possui erro grosseiro, o valor da magnitude deste erro encontra-se na faixa de 5 a 30 desvios-padrão. O

número de medidas com erros grosseiros varia de 1 a 5 medidas aleatórias geradas por sorteio.

Os resultados sobre a verificação da eficiência de identificação de erros grosseiros são avaliados a partir da classificação das simulações computacionais como *sucesso* ou *falha*. Nesta perspectiva, entende-se por *sucesso* a propriedade do algoritmo incluir todas as medidas simuladas com erros grosseiros no conjunto de medidas rejeitadas pelo estimador. Caso isto não ocorra, considera-se que houve *falha* no processamento de erro grosseiro. Enfatiza-se que o teste realizado é extremamente amplo, o que gera baixa probabilidade de um grande número de erros grosseiros afetarem somente um conjunto de medidas locais nas simulações realizadas. Além disso, a aleatoriedade utilizada para o sorteio dos conjuntos de medidas espúrias estabelece uma grande diversificação na formação destes conjuntos. Conseqüentemente, este pode incluir tanto erros grosseiros múltiplos em medidas correlacionadas como não-correlacionadas.

### 6.2.1 Índices de Desempenho do Estimador

Com o objetivo de avaliar a qualidade dos resultados do estimador de estados com base no critério MCC, neste trabalho é aplicado uma métrica para avaliar os erros das estimativas de ângulos e magnitudes de tensão em cada barra. A métrica é definida com base em (KEMA, 2006) computando, a partir das tensões nodais, um erro vetorial médio total de uma estimativa. Este erro é determinado com base nos erros absolutos das estimativas dos estados em comparação com o estudo prévio de fluxo de potência que fornece os valores “verdadeiros”. Logo, a métrica é dada por:

$$M_V = \|\vec{V}^{erro}\|_2 = \left( \frac{1}{N} \sum_{i=1}^N |\vec{V}_i^{estimado} - \vec{V}_i^{verdadeiro}|^2 \right)^{\frac{1}{2}} \quad (6.2)$$

em que:

$\vec{V}_i^{estimado}$  : contém os valores de magnitude de tensão e ângulo estimados na  $i$ -ésima barra;

$\vec{V}_i^{verdadeiro}$  : contém os valores de magnitude de tensão e ângulo na  $i$ -ésima barra obtidos do fluxo de potência convergido.

A métrica apresentada mede o desempenho de estimadores de estados cujas estimativas são fornecidas a partir de medidas com erros aleatórios (ruído). Desta forma, é desejável que a métrica retorne valores baixos, o que significa que as quantidades estimadas estão próximas dos seus respectivos valores considerados verdadeiros, mesmo quando o estimador é processado na presença de medidas portadoras de erros grosseiros.

Uma característica particular dos Estimador de estados baseados no critério MCC a ser verificada é a sua resiliência, definida como a capacidade do algoritmo de estimação de estados desempenhar sua função próxima do ideal, mesmo na presença de erros grosseiros. Desta forma, é de grande importância que o estimador realize a apropriada detecção, identificação e eliminação de medidas errôneas.

Neste sentido, o teste que tem por finalidade a verificação da resiliência é a simulação de  $n_{EG}$  medidas disponíveis no plano de medição contaminadas por erros grosseiros na forma  $\pm a\sqrt{R_{ij}}$ , em que  $a$  é um número inteiro<sup>1</sup> e  $\sqrt{R_{ij}}$  é o desvio-padrão assumido pelo erro da medida  $i$ . Deste modo, o desempenho esperado do algoritmo é a capacidade de identificar corretamente todas as  $n_{EG}$  medidas errôneas, sendo elas incluídas ao conjunto de medidas rejeitadas pelo estimador.

### 6.3 RESULTADOS PARA O ESTIMADOR ORTOGONAL MCC

Os resultados numéricos que seguem nesta seção correspondem à aplicação do estimador MCC+G3M a 4 sistemas-teste do IEEE. A Tabela 6.1 apresenta as quantidades que são medidas nas redes elétricas, discriminando o número de medidas pelo seu tipo, além do correspondente índice de redundância global para cada um dos sistemas-teste.

Tabela 6.1 – Número de medidas para cada sistema-teste do IEEE.

<i>Sistema IEEE</i>	<i>P/Q</i>	<i> V </i>	<i>p<sub>ij</sub>/q<sub>ij</sub></i>	<i>Total</i>	<i>Redundância</i>
<b>14 barras</b>	20	10	50	80	<b>2,96</b>
<b>30 barras</b>	32	8	102	142	<b>2,41</b>
<b>57 barras</b>	78	42	228	348	<b>3,08</b>
<b>118 barras</b>	204	117	452	773	<b>3,29</b>

#### 6.3.1 Resultados para o Sistema-teste do IEEE de 14 barras

Nesta subseção são apresentados resultados para o sistema-teste do IEEE de 14 barras, com o propósito tutorial de ilustrar uma aplicação típica do estimador MCC+G3M proposto. Aproveitando a baixa dimensão do sistema-teste, dá-se ênfase ao detalhamento do processo de reponderação das medidas para rejeitar erros grosseiros. Para tal, um único caso envolvendo um erro grosseiro simples é considerado. O sistema-teste e o respectivo plano de medição são mostrados na Figura 6.1.

Nesta primeira simulação, a medida de injeção de potência  $P_4$  é simulada com erro grosseiro, cuja magnitude do erro equivale a 10 desvios-padrão da medida. Para este estudo de caso, somente medidas de potência ativa e reativa (injeções nas barras e fluxos nos ramos) que estão relacionadas à barra 4 serão apresentadas de forma a

<sup>1</sup> Neste trabalho, utilizam-se valores de  $a \geq 5$ .



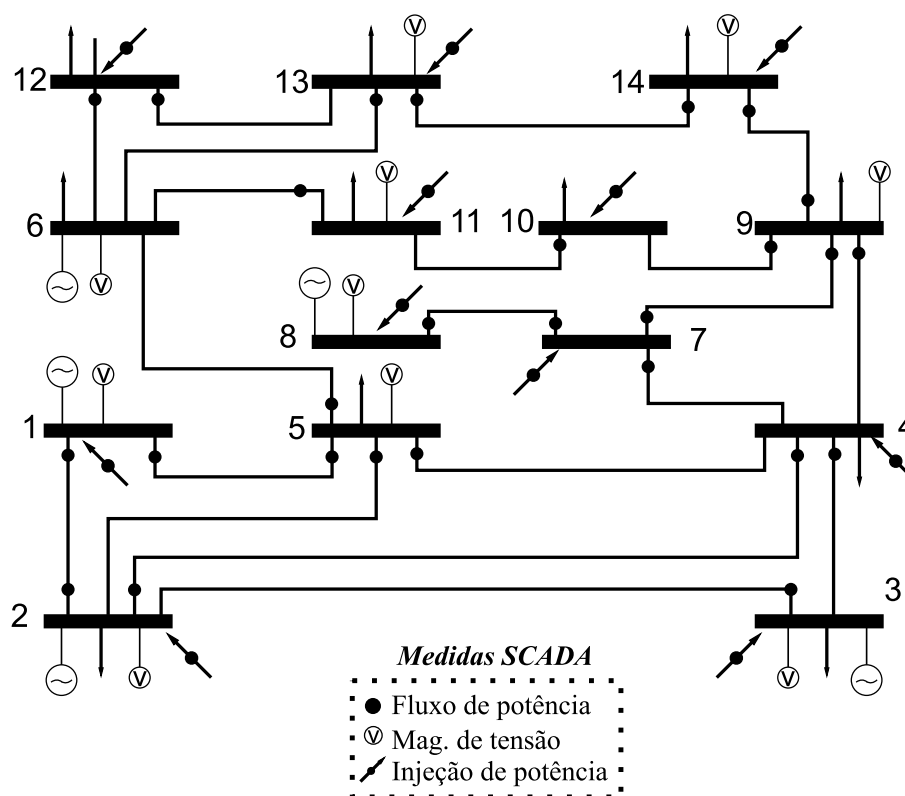


Figura 6.1 – Sistema-teste do IEEE de 14 barras e plano de medição.

avaliar as propriedades de resiliência do estimador MCC+G3M de estados. A Tabela 6.2 apresenta os valores reais, as medidas e os respectivos valores estimados para as quantidades medidas nas colunas 2 a 4, enquanto os correspondentes resíduos de estimação são dados na última coluna. Com base nos resultados desta execução do algoritmo ortogonal do estimador MCC, é possível verificar conforme, destacado na tabela em negrito, que o erro na medida  $P_4$  é automaticamente suprimido ao final do processo de estimação. Os valores dos resíduos também indicam que as demais quantidades estimadas estão próximas aos seus valores reais correspondentes.

Para demonstrar os benefícios do método ortogonal, são apresentados resultados relacionados aos fatores de ponderação das medidas. A solução livre do erro grosseiro é obtida após 2 iterações do *laço externo*, sendo que em cada uma delas foram realizadas 3 e 4 iterações o *laço interno* para a convergência, respectivamente. Conforme descrito no Capítulo 4, grandes valores para a largura dos *kernels* Gaussianos são atribuídos para a primeira iteração do processo de estimação, e posteriormente, de acordo com os ajustes subsequentes, a rejeição do erro grosseiro é atingida na segunda iteração do *laço externo*. A Figura 6.2 refere-se aos resultados obtidos ao final da segunda iteração do *laço externo* e mostra a evolução dos pesos das medidas ao longo das iterações do *laço interno*. Todas as medidas apresentadas na Tabela 6.2 tem seus pesos correspondentes mostrados nas Figuras 6.2a (fluxos nos ramos) e 6.2b (injeções de potência). O ponto inicial na “iteração” 0 em ambas

Tabela 6.2 – Resultados da estimação de estados para o sistema-teste do IEEE de 14 barras.

<i>Medida</i>	<i>Valor Real</i>	<i>Valor Medido</i>	<i>Valor Estimado</i>	<i>Resíduo</i>
$p_{2-4}$	0,4728	0,4594	0,4816	-0,0223
$q_{2-4}$	0,0046	0,0050	0,0047	0,0003
$p_{4-3}$	-0,4588	-0,4646	-0,4654	0,0008
$q_{4-3}$	0,2457	0,2467	0,2488	-0,0021
$p_{5-4}$	0,2371	0,2428	0,2430	-0,0002
$q_{5-4}$	0,1321	0,1350	0,1352	-0,0002
$p_{7-4}$	-0,2958	-0,2894	-0,2909	0,0015
$q_{7-4}$	0,1004	0,0997	0,1002	-0,0005
$p_{9-4}$	-0,2005	-0,2040	-0,2010	-0,0030
$q_{9-4}$	0,0056	0,0078	0,0066	0,0012
$P_2$	0,2284	0,2302	0,2300	0,0002
$Q_2$	0,0675	0,0693	0,0692	0,0001
$P_3$	0,5160	0,4974	0,5219	-0,0246
$Q_3$	-0,4232	-0,4366	-0,4268	-0,0097
<b><math>P_4</math></b>	<b>-0,6594</b>	<b>-0,5260</b>	<b>-0,6847</b>	<b>0,1587</b>
$Q_4$	0,0468	0,0467	0,0466	0,0001

as figuras representam os pesos nas medidas computadas ao final da primeira iteração do *laço externo*. Os sub-gráficos ampliados no lado esquerdo mostram que tais pesos são estritamente positivos, indicando que nenhuma medida é rejeitada até aquele momento. Pode-se notar também que os pesos das medidas envolvidas nas subsequentes iterações do algoritmo G3M diferem bastante uns dos outros. Devida à grande diferença de ordem numérica entre os valores dos pesos, são representados somente os pesos das medidas indicadas no lado direito dos sub-gráficos, para tornar melhor a visualização no gráfico. A área destacada em cinza abaixo do eixo horizontal evidencia situações em que são computados e atribuídos valores de pesos menores que zero para algumas medidas. Enquanto esta condição persistir para uma medida, o seu processamento desta é “saltado”, isto é, a medida é ignorada durante as iterações do algoritmo G3M. A Figura 6.2a mostra que todos os pesos para as medidas de fluxo de potência tornam-se positivos no final da convergência, mesmo com o fato de que, na iteração 1, os pesos atribuídos para às  $p_{5-4}$  e  $p_{7-4}$  são negativos. Isto é devido aos efeitos causados pelo espalhamento do erro grosseiro da medida  $P_4$ , que é removida nas iterações do algoritmo G3M conforme ilustrado na Figura 6.2b. Como as medidas de fluxo de potência acima mencionadas não foram totalmente descartadas ao longo do processo de estimação, as mesmas são reprocessadas no momento em que seus respectivos pesos tornam-se novamente positivos. Portanto, a remoção da medida  $P_4$  finalmente assegura estimativas livres de erros grosseiros para as variáveis de estado, e conseqüentemente para as quantidades medidas, como confirmado nos resultados




Figura 6.2 – Pesos das medidas ao longo das iterações do algoritmo G3M (a) medidas de fluxo de potência nos ramos e (b) medidas de injeção de potência nas barras

da Tabela 6.2.

De acordo com o experimento realizado a partir deste sistema-teste, verifica-se que os valores dos pesos das medidas se comportam da seguinte forma: na convergência, o menor valor obtido é  $5,7 \times 10^4$ , enquanto o valor máximo é de  $4,7 \times 10^9$ . Tendo em vista a diferença entre estes dois valores, confirma-se a importância da aplicação de técnicas numericamente robustas de resolução ao problema de estimação MCC de estados.

### 6.3.2 Resultados para o Sistema-teste do IEEE de 57 barras

A presente subseção descreve a aplicação do estimador MCC ao sistema-teste do IEEE de 57 barras com o objetivo de analisar a resiliência da metodologia proposta quando múltiplos erros grosseiros fortemente correlacionados são processados. É co-

nhecido o fato de que estas condições configuram um severo desafio ao tradicional método de identificação de erros grosseiros baseado no teste do máximo resíduo normalizado (referido aqui como LNRT, da sigla em Inglês) cujo desempenho varia de acordo com o tipo de erro grosseiro e sua configuração (ABUR; GOMEZ EXPOSITO, 2004). Para permitir uma comparação justa, o estimador de estados MQP é equipado com o estágio de processamento de erros grosseiros baseado no LNRT. Dessa maneira, a capacidade de rejeição de erros grosseiros em ambos os estimadores de estados MQP+LNRT e MCC+G3M são comparados utilizando quatro estudos de caso, cujos resultados são avaliados em termos da qualidade dos valores estimados para as quantidades medidas e pela apropriada eliminação das medidas errôneas. Adicionalmente, é analisado o desempenho da rejeição de erros grosseiros múltiplos e interativos, considerando diferentes magnitudes. Baseado na metodologia descrita em (SIMÕES COSTA; PIAZZA; MANDEL, 1990) para o projeto do plano de medição do sistema em estudo, a simulação é realizada sem a presença de medidas críticas ou conjunto crítico de medidas.

A seguir, descrevem-se os quatro pares de medidas errôneas simuladas, cujos erros são interativos:  $\{q_{8-9}, Q_9\}$  (*Caso 1*),  $\{p_{13-14}, P_{14}\}$  (*Caso 2*),  $\{q_{1-2}, Q_2\}$  (*Caso 3*) e  $\{p_{49-50}, P_{50}\}$  (*Caso 4*). Estes pares são escolhidos com base na matriz de sensibilidade dos resíduos, de modo a ilustrar as limitações do método LNRT (ABUR; GOMEZ EXPOSITO, 2004) e a propriedade de resiliência da abordagem MCC+G3M para rejeitar erros grosseiros. Os pares de fluxos potência nos ramos e injeção de potência nos casos 1, 2 e 4 são erros grosseiros interativos, porém não-conformes. Já o *Caso 3* é um exemplo severo de erros grosseiros múltiplos e conformes. As magnitudes dos erros grosseiros variam em 5, 7, 10, 15, 20, 25 e 30 desvios-padrão da correspondente medida, para a mesma condição de operação do sistema-teste do IEEE de 57 barras.

A Figura 6.3 apresenta os resultados obtidos após a convergência de ambos os estimadores de estados envolvendo os casos 1 a 4, considerando as diferentes magnitudes de erros grosseiros. A figura exhibe os erros absolutos entre os valores estimados para as quantidades medidas e seus respectivos valores reais fornecidos pela rotina de fluxo de carga, sendo os resultados expressos como múltiplos de desvios-padrão das medidas. Na convergência, espera-se que tais erros ponderados fiquem reduzidos a valores relativamente pequenos (tipicamente menores do que 3 desvios-padrão), uma vez que a contaminação deve ser supostamente mitigada de forma apropriada pelo processamento de erros grosseiros. Na figura, as medidas errôneas são indicadas acima das barras correspondentes para a magnitude dos erros ponderados de cada par, cujos valores são obtidos após convergência dos estimadores de estados MQP+LNRT (barras azuis) e MCC+G3M (barras amarelas). Devido à ocorrência de elevadas magnitudes de erros obtidos para o estimador de estados MQP+LNRT em determinadas simulações, algumas barras são sub-escaloadas e seus respectivos

valores de erros são indicados próximos às barras correspondentes.

Embora cada estudo de caso apresente comportamento distinto, é claramente possível concluir, de modo geral, que o estimador MCC+G3M proposto fornece estimativas mais exatas que o estimador convencional MQP+LNRT. Um aspecto que pode ser notado é que o estimador robusto baseado em correntropia garante valores de erros abaixo de 3 desvios-padrão para as quantidades medidas em todas as simulações. Em outras palavras, os resultados do estimador MCC ortogonal são próximos aos valores reais.

A partir da Figura 6.3 pode-se também concluir que o estimador MQP+LNRT encontra dificuldades nos quatro estudos de casos quando a magnitude do erro grosseiro reduz-se à faixa próxima a 5 desvios-padrão da medida. Nestas simulações, o estimador convencional identifica somente uma medida errônea do par de erros grosseiros, enquanto o estimador MCC+G3M fornece boas estimativas para os valores das quantidades medidas. Verifica-se portanto que, sob condições idênticas de simulação para ambos estimadores, o método proposto é o único capaz de eliminar os efeitos dos erros grosseiros em todos os casos.

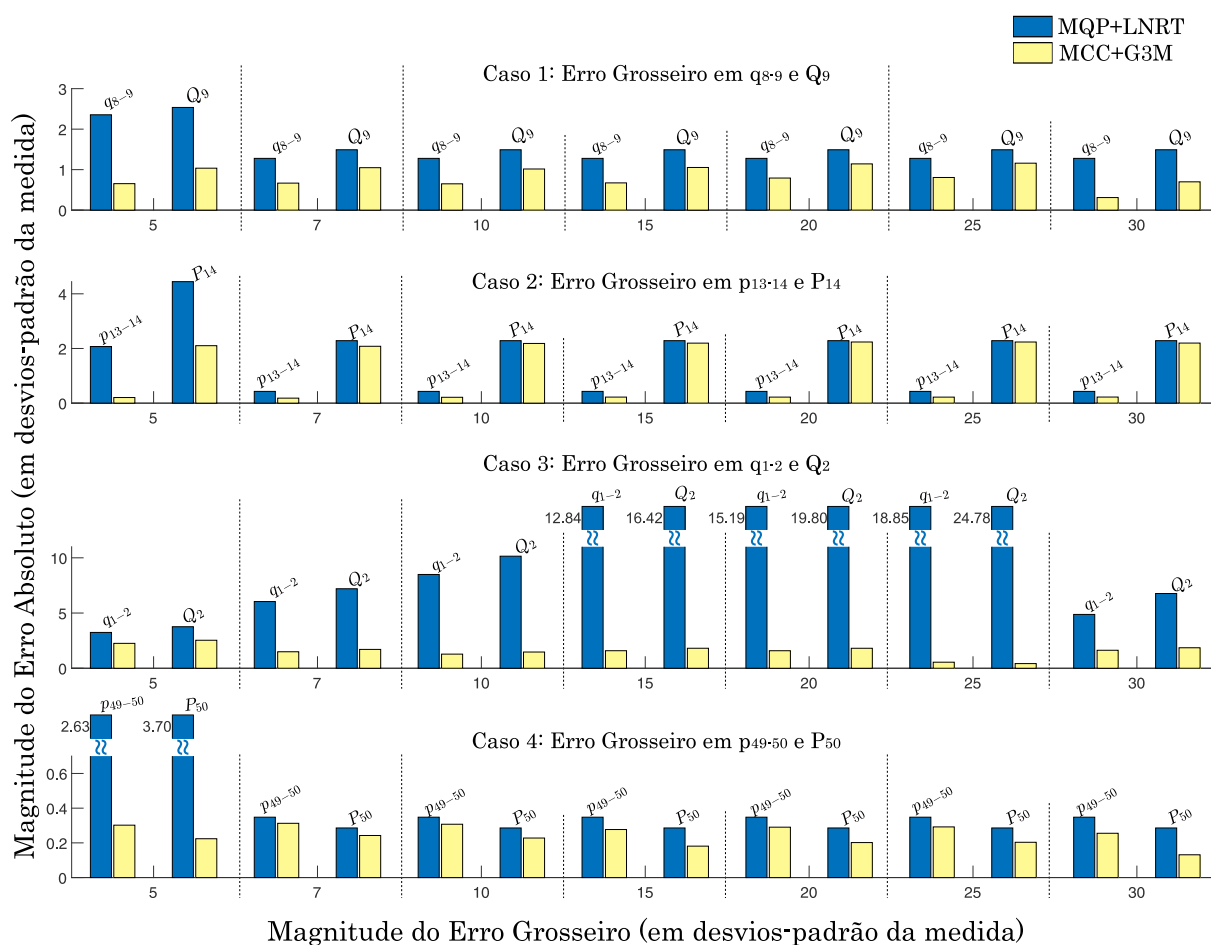


Figura 6.3 – Erros absolutos ponderados para as medidas nos 4 estudos de casos com diferentes erros grosseiros interativos

Os resultados obtidos para o *Caso 3* são aqui destacados, uma vez que considera erros grosseiros múltiplos e conformes. Observa-se que, neste caso, estimativas incorretas são produzidas pelo estimador MQP+LNRT em diversas simulações, enquanto que bons resultados, caracterizados por pequenos erros de estimação, são sucessivamente obtidos com o uso do estimador MCC+G3M. Sobre esta severa configuração de erros grosseiros, o caso mais contrastante ocorre para a magnitude do erro igual a 25 desvios-padrão das medidas, já que o estimador convencional fornece estimativas finais contaminadas com inaceitáveis magnitudes de erro de 18,9 e 24,8 para as quantidades  $q_{1-2}$  e  $Q_2$ , respectivamente. Por outro lado, o estimador MCC ortogonal assegura estimativas para as mesmas quantidades com pequenas magnitudes de erro na ordem de 0,55 e 0,42, expressos em números de desvios-padrão das respectivas medidas, garantindo assim a total eliminação dos efeitos do par de medidas errôneas. Pode-se verificar também que, de acordo com o aumento do valor da magnitude do erro grosseiro, ocorre uma melhora dos resultados obtidos pelo estimador MQP+LNRT, como visto neste estudo de caso para valores acima de 30 desvios-padrão das correspondentes medidas. Este desempenho é esperado, pois quando erros grosseiros múltiplos e conformes com elevados valores de magnitude dos erros estão presentes no conjuntos de medidas, estes podem ser identificados por métodos clássicos de processamento de medidas espúrias (ZHAO, Junbo; MILI, Lamine, 2018b; ABUR; GOMEZ EXPOSITO, 2004).

Como forma de viabilizar uma análise adicional sobre a qualidade da estimação de estados fornecida por ambos estimadores MQP+LNRT e MCC+G3M na presença de múltiplos erros grosseiros interativos, a Tabela 6.3 fornece resultados numéricos correspondentes aos os estudos de caso da Figura 6.3 em que a medida é contaminada por erros grosseiros cujas magnitudes são de 5 e 30 desvio-padrão da medida. As colunas ③ e ④ da tabela mostram os valores reais das quantidades medidas e os seus correspondentes valores medidos, respectivamente. Os valores estimados para as quantidade medidas fornecidas pelo estimadores MQP+LNRT e MCC+G3M são apresentados, respectivamente, nas colunas ⑤ e ⑥, enquanto os erros absolutos entre os valores reais e estimados são fornecidos nas colunas ⑦ e ⑧. Os resultados da Tabela 6.3 revelam que ambos os estimadores fornecem boas estimativas para as quantidades medidas na presença de grandes magnitudes de erros interativos, embora o método proposto produza erros de estimação um tanto menores do que o MQP+LNRT. Para pequenos erros magnitude de 5 desvios-padrão, entretanto, pode-se notar que os erros obtidos pelo algoritmo ortogonal do estimador MCC de estados são sensivelmente menores em todos os casos quando comparados com o tradicional estimador MQP+LNRT. Os resultados indicam que este último comporta-se melhor para maiores magnitudes de erro grosseiro, porém de modo geral, fica evidente que a metodologia proposta consistentemente supera o método convencional, inde-

Tabela 6.3 – Resultado da estimação para o estimadores de estados MQP+LNRT e MCC+G3M para o sistema-teste do IEEE de 57 barras considerando 5 e 30 desvios-padrão de magnitude do erro grosseiro em múltiplas medidas

Mag. do Erro Grosseiro: 5 desvios-padrão da medida							
① Caso	② Medida	③ Valor real ( $z^0$ )	④ Valor medido ( $z$ )	Valor Estimado		Erro Absoluto	
				⑤ MQP+LNRT $\hat{z}_{MQP}$	⑥ MCC+G3M $\hat{z}_{MCC}$	⑦ $ z_i^0 - \hat{z}_{MQP,i} $	⑧ $ z_i^0 - \hat{z}_{MCC,i} $
1	$q_{8-9}$	1,691	1,867	1,608	1,668	0,083	0,023
	$Q_9$	-2,534	-2,276	-2,403	-2,480	0,131	0,054
2	$p_{13-14}$	0,338	0,398	0,313	0,340	0,025	0,002
	$P_{14}$	-0,064	-0,013	-0,019	-0,085	0,045	0,021
3	$q_{1-2}$	1,993	1,787	1,859	1,900	0,134	0,093
	$Q_2$	-1,823	-1,634	-1,681	-1,727	0,142	0,096
4	$p_{49-50}$	0,034	0,084	0,008	0,031	0,026	0,003
	$P_{50}$	-0,152	-0,099	-0,113	-0,149	0,039	0,003

Mag. do Erro Grosseiro: 30 desvios-padrão da medida							
① Caso	② Medida	③ Valor real ( $z^0$ )	④ Valor medido ( $z$ )	Valor Estimado		Erro Absoluto	
				⑤ MQP+LNRT $\hat{z}_{MQP}$	⑥ MCC+G3M $\hat{z}_{MCC}$	⑦ $ z_i^0 - \hat{z}_{MQP,i} $	⑧ $ z_i^0 - \hat{z}_{MCC,i} $
1	$q_{8-9}$	1,691	2,748	1,646	1,680	0,045	0,011
	$Q_9$	-2,534	-0,984	-2,457	-2,498	0,077	0,036
2	$p_{13-14}$	0,338	0,700	0,343	0,341	0,005	0,003
	$P_{14}$	-0,064	0,239	-0,087	-0,086	0,023	0,022
3	$q_{1-2}$	1,993	0,760	2,193	1,926	0,200	0,067
	$Q_2$	-1,823	-0,689	-2,079	-1,753	0,256	0,070
4	$p_{49-50}$	0,034	0,335	0,031	0,032	0,003	0,002
	$P_{50}$	-0,152	0,162	-0,149	-0,150	0,003	0,001

pendentemente da magnitude do erro. Tais resultados são também confirmados pelas magnitudes dos erros nos histogramas apresentados na Figura 6.3.

### 6.3.3 Avaliação da Resiliência a Erros Grosseiros e Desempenho Computacional

Nesta subseção, o desempenho do estimador proposto é avaliado através da realização de diversas simulações aplicadas em distintos sistemas-teste. Os resultados dos testes descritos a seguir fazem comparação entre os desempenhos do estimador MCC, resolvido através das rotações de Givens e os resultados do estimador MQP+LNRT, obtidos sobre as mesmas condições de simulação. A comparação é endereçada à avaliação de dois aspectos: (i) a capacidade de suprimir apropriadamente os efeitos de erros grosseiros, e (ii) esforço computacional necessário para obter

Tabela 6.4 – Eficiência dos Estimadores de Estados MQP+LNRT e MCC+G3M na ocorrência de 1 a 5 erros grosseiros para os sistemas-teste do IEEE

Sistema			N° de Erros Grosseiros					Eficiência
IEEE	Estimador		1	2	3	4	5	Total
<b>14 barras</b>	MQP+	Sucesso	100	100	95	92	93	<b>96,00%</b>
	LNRT	Falha	0	0	5	8	7	
	MCC+	Sucesso	100	100	95	93	94	<b>96,40%</b>
	G3M	Falha	0	0	5	7	6	
<b>30 barras</b>	MQP+	Sucesso	100	98	98	93	94	<b>96,60%</b>
	LNRT	Falha	0	2	2	7	6	
	MCC+	Sucesso	100	98	98	95	95	<b>97,20%</b>
	G3M	Falha	0	2	2	5	5	
<b>57 barras</b>	MQP+	Sucesso	98	99	93	97	94	<b>96,20%</b>
	LNRT	Falha	2	1	7	3	6	
	MCC+	Sucesso	98	98	96	96	95	<b>96,60%</b>
	G3M	Falha	2	2	4	4	5	
<b>118 barras</b>	MQP+	Sucesso	100	99	96	96	94	<b>97,00%</b>
	LNRT	Falha	0	1	4	4	6	
	MCC+	Sucesso	100	100	97	98	95	<b>98,00%</b>
	G3M	Falha	0	0	3	2	5	

estimativas livre de erros grosseiros. Diversos cenários com condições operacionais distintas são construídos usando quatro sistemas-teste do IEEE de 14, 30, 57 e 118 barras, conforme descrito na Seção 6.2. Até 5 erros grosseiros posicionados aleatoriamente são simulados simultaneamente em cada uma dessas redes, compreendendo 600 simulações distintas por sistema-teste, das quais 100 são livres de medidas errôneas e as 500 restantes incluem de 1 a 5 erros grosseiros. As magnitudes dos erros grosseiros inseridos estão entre 15 e 30 desvios-padrão da medida correspondente.

A eficiência da supressão de erros grosseiros de ambos os estimadores MCC+G3M e MQP+LNRT, para cada sistema-teste, é verificada na Tabela 6.4, que mostra o número de sucessos e falhas na detecção e remoção adequada dos efeitos dos erros grosseiros. Quanto aos esforços computacionais exigidos pelos estimadores MQP+LNRT e MCC+G3M, os tempos médios da CPU para as mesmas redes elétricas são mostrados na Figura 6.4. Para cada sistema, os tempos da CPU são normalizados em relação ao menor tempo de processamento obtido (que corresponde aos resultados do estimador MQP+LNRT na ausência de erros grosseiros) representados como ordenadas iguais a “1” em todas os os subgráficos da Figura 6.4.

Uma avaliação geral da capacidade de supressão de erros grosseiros do estimador MCC+G3M, conforme mostrado na Tabela 6.4, revela que o desempenho do método proposto é consistentemente superior, embora por pequenas margens, em comparação com o método MQP+LNRT. A taxa de sucesso do método MCC+G3M



é de cerca de 97,05% das 2.000 simulações na presença de erros grosseiros realizadas com os quatro sistemas-teste, contra 96,45% para o estimador convencional MQP+LNRT. Para as 400 simulações livres de erros grosseiros, os estimadores ortogonal MCC e MQP+LNRT apresentam bom desempenho, pois em todos os casos eles fornecem estimativas válidas sem a ocorrência de “falso positivo”.

Com relação aos casos com falha relatados na Tabela 6.4, surge a questão de saber se as estimativas correspondentes podem ser aceitáveis, apesar das falhas na detecção. Um caso específico foi selecionado como uma amostra dos casos de falha, no qual testes estatísticos podem ser realizados. O objetivo é obter algumas indicações sobre esta questão. Antes de prosseguir, um critério com base estatística deve ser definido para decidir se uma estimativa é aceitável ou não. O critério empregado nesta seção é baseado na matriz de covariância dos erros de estimação, dada por (HANDSCHIN *et al.*, 1975; MONTICELLI, 1999):

$$\Sigma_{\mathbf{x}} = E\{(\hat{\mathbf{x}} - \mathbf{x})(\hat{\mathbf{x}} - \mathbf{x})^T\} = (\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1} \quad (6.3)$$

Sob a suposição de que nenhum erro grosseiro está presente e considerando uma probabilidade fixa de alarme falso, os limiares podem ser determinados para cada variável de estado. Adotamos uma probabilidade de alarme falso de 0,3%, que corresponde a três desvios-padrão de erro sobre a estimativa. Portanto, o limiar para a estimativa de estado  $i$  é definido como:

$$\tau_i^{estado} = 3\sqrt{\Sigma_{x,ii}} \quad (6.4)$$

O caso selecionado da Tabela 6.4 está relacionado ao sistema-teste de 14 barras, no qual foram identificadas 5 falhas. Para cada um desses casos com falha, são realizados testes estatísticos que consistem basicamente na comparação dos erros absolutos das estimativas relacionados aos seus valores reais correspondentes aos limites individuais calculados como na Equação (6.4). Os testes positivos equivalem à rejeição do resultado quando pelo menos um erro absoluto excede o limiar correspondente. Um dos 5 casos com falha está detalhado na Tabela 6.5 a seguir. Como pode-se verificar, seis erros destacados em negrito (5 de magnitude de tensão e 1 de ângulo de fase) violam o limiar correspondente. Nos quatro casos restantes, o número de violações variam, mas em todos eles ocorre pelo menos uma violação. Isso indica que, para o critério de aceitação adotado, todos os cinco casos são corretamente rotulados como inaceitáveis.

Os planos de medição aplicados aos sistemas-teste acima conduzem a simulações em que não há ocorrência de medidas críticas e conjuntos críticos de medidas. Da mesma forma, em princípio os parâmetros das redes elétricas consideradas não implicam na ocorrência de pontos de alavancamento (que poderiam surgir em conexão com ramos de baixa impedância, por exemplo). Sabe-se que estes tipos peculiares de medidas podem afetar o desempenho de estimadores tradicionais (ABUR; GOMEZ

Tabela 6.5 – Desempenho do Estimador MCC+G3M na Ocorrência de Falha para o Sistema-teste do IEEE de 14 Barras Considerando a Presença de 3 Erros Grosseiros

Falha em Estudo de Caso - IEEE 14 Barras				
Barra	$ \hat{V}_{MCC} - V_{\text{fluxo carga}} $	$\tau^{\text{estado}}$	$ \hat{\theta}_{MCC} - \theta_{\text{fluxo carga}} $	$\tau^{\text{estado}}$
1	0,006	0,010	-	-
2	0,006	0,010	0,001	0,002
3	0,005	0,011	0,001	0,004
4	0,004	0,010	0,002	0,004
5	0,005	0,010	0,000	0,004
6	0,006	0,010	0,008	0,010
7	<b>0,018</b>	<b>0,011</b>	0,002	0,009
8	<b>0,017</b>	<b>0,011</b>	0,005	0,009
9	<b>0,017</b>	<b>0,011</b>	0,003	0,009
10	<b>0,016</b>	<b>0,011</b>	0,004	0,010
11	0,011	0,010	0,006	0,010
12	0,002	0,011	0,007	0,011
13	0,001	0,010	0,011	0,011
14	<b>0,020</b>	<b>0,011</b>	<b>0,023</b>	<b>0,011</b>

EXPOSITO, 2004). No caso de medidas críticas e de medidas associadas a pontos de alavancamento, se afetadas por erros grosseiros, tais dados não poderão ser identificados por métodos convencionais, baseados na formulação dos mínimos quadrados ponderados (ABUR; GOMEZ EXPOSITO, 2004; MONTICELLI, 1999). Embora a identificação de *outliers* na abordagem MCC+G3M também seja realizada mediante rastreamento dos resíduos de estimação, é importante ressaltar que a sensibilidade do método proposto à ocorrência de erros grosseiros em medidas críticas ou em pontos de alavancamento não é objeto de investigação específica neste trabalho.

Voltando-se novamente a atenção para os desempenhos computacionais requisitados pelos estimadores de estado, os gráficos na Figura 6.4 mostram, conforme o esperado, que o tempo de processamento da CPU aumenta com o número de erros grosseiros presentes no conjunto de medidas. Para o estimador MQP+LNRT, o tempo de processamento aumenta linearmente com o número de erros grosseiros, pois esse estimador requer a reinicialização sempre que uma medida errônea é removida. Por outro lado, o estimador MCC+G3M pode lidar com vários erros grosseiros simultaneamente e é capaz de eliminar seus efeitos conjuntos ao cabo de algumas poucas iterações. Isso leva a uma taxa de variação do esforço computacional que decresce à medida que o número de erros grosseiros aumenta, como fica evidente na Figura 6.4. As sub-figuras levam à conclusão de que o ponto de equilíbrio de desempenho após o qual o estimador MCC+G3M supera o método MQP+LNRT ocorre geralmente na presença de dois erros grosseiros. A figura também mostra que os tempos de CPU para o algoritmo ortogonal do estimador MCC permanecem relativamente próximos dos tem-

pos de processamento exigidos pelo estimador MQP+LNRT, mesmo para nenhuma ou apenas uma ocorrência de erro grosseiro.

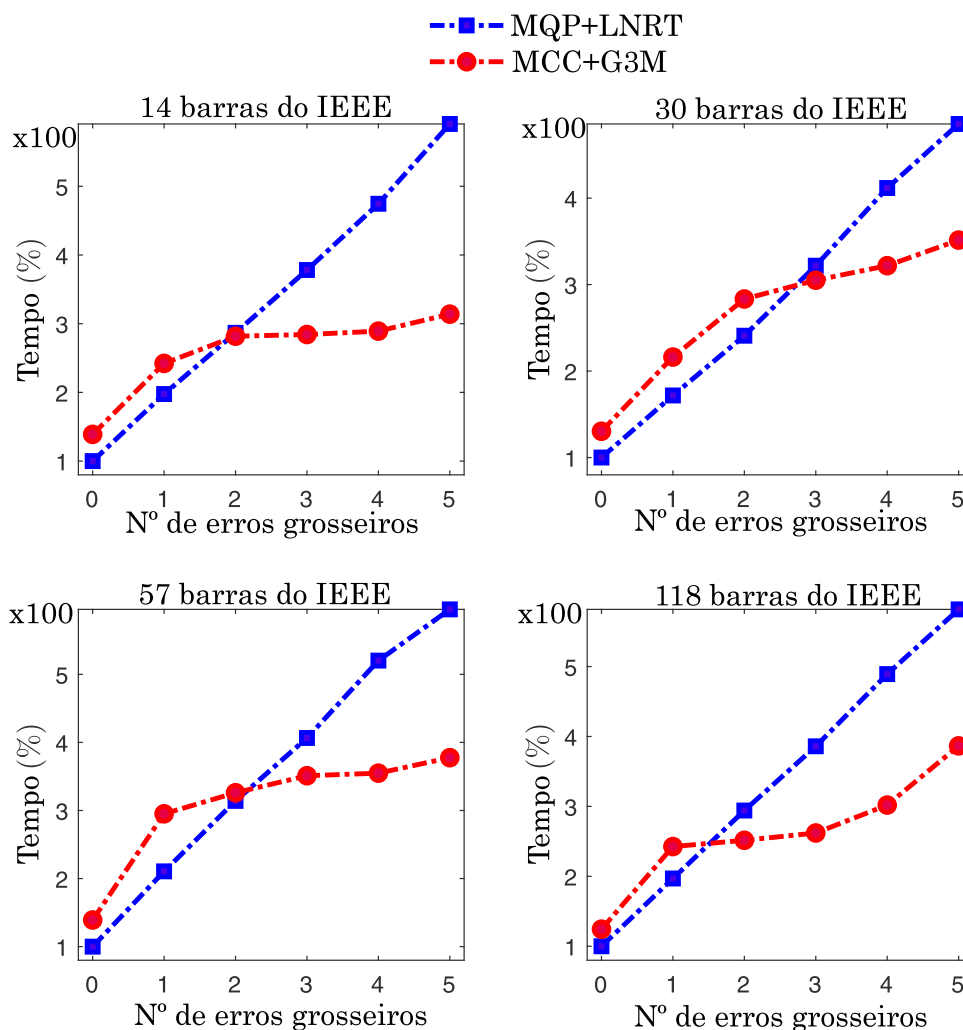


Figura 6.4 – Valores de tempos médios de processamento (em %) para os estimadores MQP+LNRT e MCC+G3M em distintos cenários simulados

Como uma avaliação geral do desempenho, considerando tanto a capacidade de supressão de erros grosseiros quanto o esforço computacional, é possível concluir que o método MCC+G3M supera claramente a abordagem convencional. Para além do fato de que suas taxas de sucesso são consistentemente superiores às do estimador MQP+LNRT, a diferença de tempos de processamento da CPU em favor do método proposto se torna bastante significativa para casos realistas com erros grosseiros múltiplos.

Também é interessante analisar o número de iterações realizadas pelo método MCC+G3M proposto, conforme resumido na Tabela 6.6. A tabela descreve os valores médios para o *laço externo*, que está diretamente relacionado ao processo de atualização das janelas Parzen, e o *laço interno*, que corresponde ao algoritmo de solução G3M. A taxa de convergência do estimador MCC+G3M é de duas a quatro iterações, independentemente do tamanho do sistema-teste e do número de ocorrências de er-

Tabela 6.6 – Valores médios para o número de iterações do *laço externo* e do algoritmo G3M para cada sistema-teste na presença ou não de erros grosseiros

<i>Sistema</i>		<b>Nº de Erros Grosseiros</b>					
		0	1	2	3	4	5
<b>14 barras</b>	<i>Laço Externo</i>	1,00	2,18	2,19	2,70	2,29	2,47
	<i>G3M</i>	3,01	2,98	3,18	3,27	3,65	3,53
<b>30 barras</b>	<i>Laço Externo</i>	1,00	2,23	2,14	2,37	2,18	2,27
	<i>G3M</i>	2,90	2,85	3,17	3,33	3,32	3,57
<b>57 barras</b>	<i>Laço Externo</i>	1,00	2,26	2,36	2,41	2,64	2,49
	<i>G3M</i>	3,00	2,77	2,93	3,12	3,24	3,26
<b>118 barras</b>	<i>Laço Externo</i>	1,00	2,29	3,15	2,57	2,93	3,54
	<i>G3M</i>	2,97	2,47	2,72	2,95	3,00	3,06

ros grosseiros. Quando medidas errôneas estão ausentes dos conjuntos de medidas, geralmente é necessária uma única iteração. Para o *laço interno*, o algoritmo G3M realiza de duas a três iterações, seja na ausência ou na presença de erros grosseiros.

#### 6.4 RESULTADOS PARA ESTIMAÇÃO HÍBRIDA MCC/APSI DE ESTADOS

Nesta seção é verificado o desempenho do estimador híbrido MCC/APSI de estados, proposto no Capítulo 5, com base em diversos testes realizados a partir dos sistemas-teste do IEEE de 14, 30, 57 e 118 barras. São monitoradas pelo sistema SCADA as injeções de potência ativa e reativa nos barramentos e fluxos nos ramos da rede elétrica, bem como as magnitudes de tensão. Quanto às medidas fasoriais sincronizadas, são considerados os fasores de tensão nas barras e correntes nos ramos (em coordenadas retangulares com os valores reais e imaginários) incidentes nas barras onde as PMUs estão instaladas.

Simulações específicas considerando o número de erros grosseiros, bem como onde elas ocorrem, são especificadas e discutidas a seguir:

- *Caso base*, para os quais as medidas dos sistemas SCADA e PMU estão livres de erros grosseiros, de modo que a solução do estimador MQP produz estimativas confiáveis para serem tratadas como informações de estado *a priori* no segundo estágio;
- *Caso EG-SCADA*, onde medidas convencionais são contaminadas por erros grosseiros e, como consequência, parte das informações de estado *a priori* transferidas para o estimador MCC/APSI são errôneas;
- *Caso EG-SCADA&PMU*, no qual ambos os subconjuntos de medidas do SCADA e PMU estão contaminados com erros grosseiros.

Além disso, os estudos de caso são agrupados em dois tipos de planos de medição para as medidas, que fornecem diferentes condições de observabilidade para a rede elétrica, e são caracterizadas da seguinte maneira:

- *Condição A*: a rede elétrica é totalmente observável tanto por medidas de SCADA quanto por medidas PMU;
- *Condição B*: a rede elétrica é observável por medidas SCADA, mas o número de medidas fasoriais sincronizadas instaladas no sistema é insuficiente para garantir a observabilidade por medidas PMU.

#### 6.4.1 Resultados Ilustrativos para o Sistema-teste do IEEE de 14 Barras

Os resultados relatados nesta subseção são referentes à aplicação do estimador MCC/APSI ao sistema-teste do IEEE de 14 barras. A Tabela 6.7 detalha os planos de medição com respeito aos sistemas SCADA e PMU para as *condições A e B*. Na tabela, a localização de todos os medidores é especificada utilizando-se os índices de barramento. Alguns ramos da rede elétrica possuem fluxos de corrente monitorados por PMUs em ambas as extremidades, o que é indicado pelo índice “(2)”. A configuração de medidas SCADA da Tabela 6.7 é empregada nas condições de observabilidade *A e B*. Outro fator importante a mencionar é que o plano de medição fornecido para as medidas convencionais apresenta algumas deficiências de redundância local e, como consequência, há o surgimento de conjuntos críticos de medidas. Como se sabe, tais quantidades, se contaminadas por erros grosseiros, são detectáveis mas não identificáveis. Os conjuntos críticos de medidas são confirmados com base na análise topológica de observabilidade e criticidade descrita em (SIMÕES COSTA; PIAZZA; MANDEL, 1990).

Tabela 6.7 – Planos de medição do sistema-teste do IEEE de 14 barras para ambos tipos de medidas SCADA e PMU para as condições de observabilidade *A e B*.

Tipo de medida	Mag. de tensão nas barras	Inj. de pot. nas barras	Fluxo de pot. nos ramos (de-para)
SCADA Condições A e B	1,2,3,6,9,11	2,3,4,5,6,8,11	2-1,1-5,3-2,4-2,5-4,7-4,9-4,11-6,12-6,7-8,7-9,10-9,14-9,10-11,12-13,13-6,13-14
PMU	Fasores de tensão	Fasores de corrente nos ramos	
	Condição A	1,3,5,6,7,10,14	1-2,1-5(2),3-2,3-4,5-2,5-4,5-6(2),6-11,6-12,6-13,7-4,7-8,7-9,10-9,10-11,14-9,14-13
Condição B	1,3,5,6	1-2,1-5(2),3-2,3-4,5-2,5-4,5-6(2),6-11,6-12,6-13	

## 6.4.1.1 Experimentos sob a condição A de Observabilidade

Os resultados para o *Caso base* são apresentados na Figura 6.5, que mostram os erros absolutos para as estimativas de ângulos e magnitudes de tensão em cada barramento com relação aos resultados do estudo do fluxo de carga para a rede elétrica. As linhas pontilhadas verticais nas duas figuras são usadas para facilitar a identificação de erros dos estimadores baseados nos métodos MQP e MCC/APSI em cada barramento. Considerando que a rede é totalmente observável por medidas fasoriais, os resultados claramente indicam que as estimativas fornecidas pelo estimador MCC/APSI são mais exatas em relação às estimativas dos estados baseadas no conjunto de medidas SCADA, que igualmente estão livres de erros grosseiros. Isto se deve à influência das medidas fasoriais sobre o resultado da estimação híbrida, já que seu nível de exatidão é superior ao das medidas convencionais.

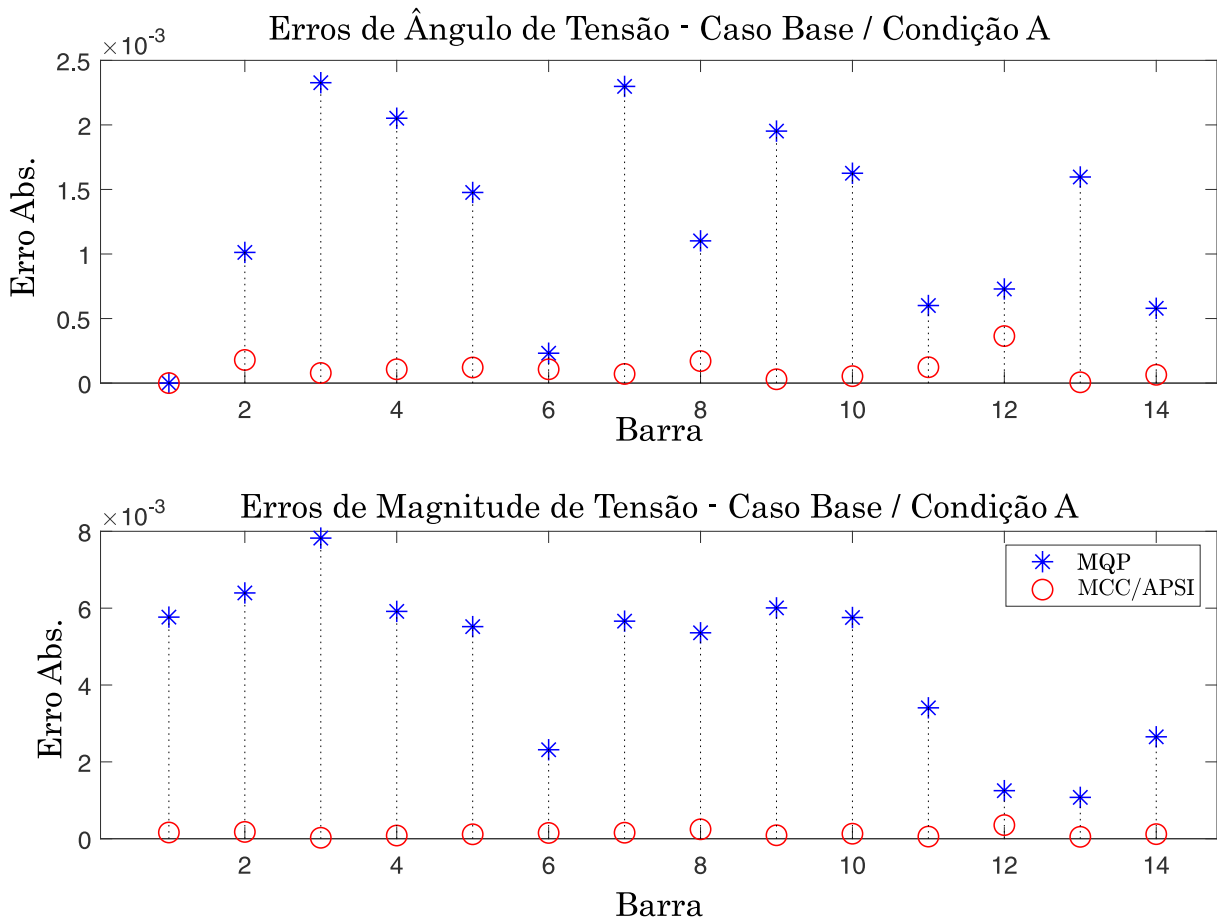


Figura 6.5 – Erros absolutos para as estimativas para ambos os estimadores MQP e MCC/APSI na ausência de erros grosseiros

Discute-se em seguida o caso *EG-SCADA*, que considera a situação na qual medidas errôneas indetectáveis são processadas pelo estimador baseado nas medidas SCADA no primeiro estágio da arquitetura de estimação descrita na Figura 5.1. As medidas portadoras de erros grosseiros são as componentes do par de fluxos de

potência ativo/reactivo  $p_{7-9}/q_{7-9}$  com magnitude dos erros igual a 10 desvios-padrão da medida. As medidas mencionadas formam, individualmente, pares críticos com as injeções de potências  $P_8$  e  $Q_8$ , respectivamente.

Conforme evidenciado pelos valores dos erros de estimação representados na Figura 6.6 (compare as escalas verticais com as da Fig. 6.5), os erros grosseiros afetam os resultados para as estimativas de estados do método MQP em praticamente todas as barras quando comparados aos resultados do *caso base* na Figura 6.5. Em contrapartida, durante a execução do estimador MCC/ASPI as variáveis *a priori* de estado para ângulos e magnitudes de tensão relacionadas às barras 9 e 10 são eliminadas por efeito das propriedades de rejeição de *outliers* do algoritmo MCC. As figuras 6.7 e 6.8 mostram que tais informações *a priori* são suprimidas na convergência do estimador mediante a redução drástica dos respectivos fatores de ponderação. Para facilitar a comparação, os pesos das medidas da PMU (eixo esquerdo e linha azul) e APSI (eixo direito e linha vermelha) são normalizados com relação ao peso da variável de estado do ângulo *a priori* do barramento 2 ( $\bar{\theta}_2$ ). Os resultados mostram que as estimativas inconsistentes do estimador SCADA são subponderadas (próximo a 0) em comparação com os pesos das medidas fasoriais sincronizadas, as quais produzem portanto um impacto significativamente maior no processo de otimização. Esses resultados são esperados e decorrem do fato de que os erros das informações *a priori* correspondentes tornam-se maiores que as larguras de suas próprias janelas de Parzen, sendo portanto rejeitadas pelo estimador baseado em correntropia.

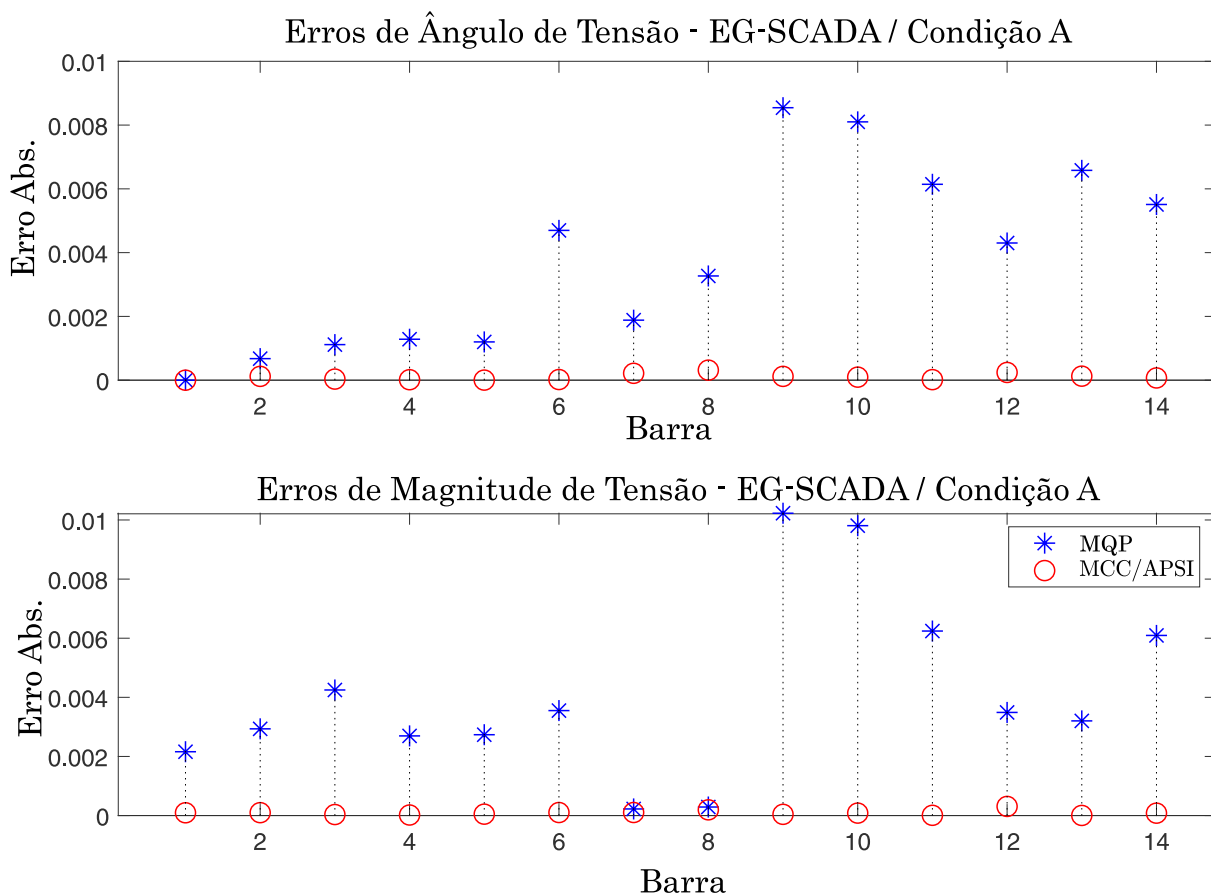


Figura 6.6 – Erros absolutos sobre as estimativas para o caso *EG-SCADA* sob a *Condição A*




Figura 6.7 – Pesos para ângulos de medidas PMUs e APSI de cada barramento na convergência (caso *EG-SCADA* - Condição A)






Figura 6.8 – Pesos para magnitudes de tensão de medidas PMUs e APSI de cada barramento na convergência (caso *EG-SCADA* - Condição A)

## 6.4.1.2 Experimentos sob a condição B de Observabilidade

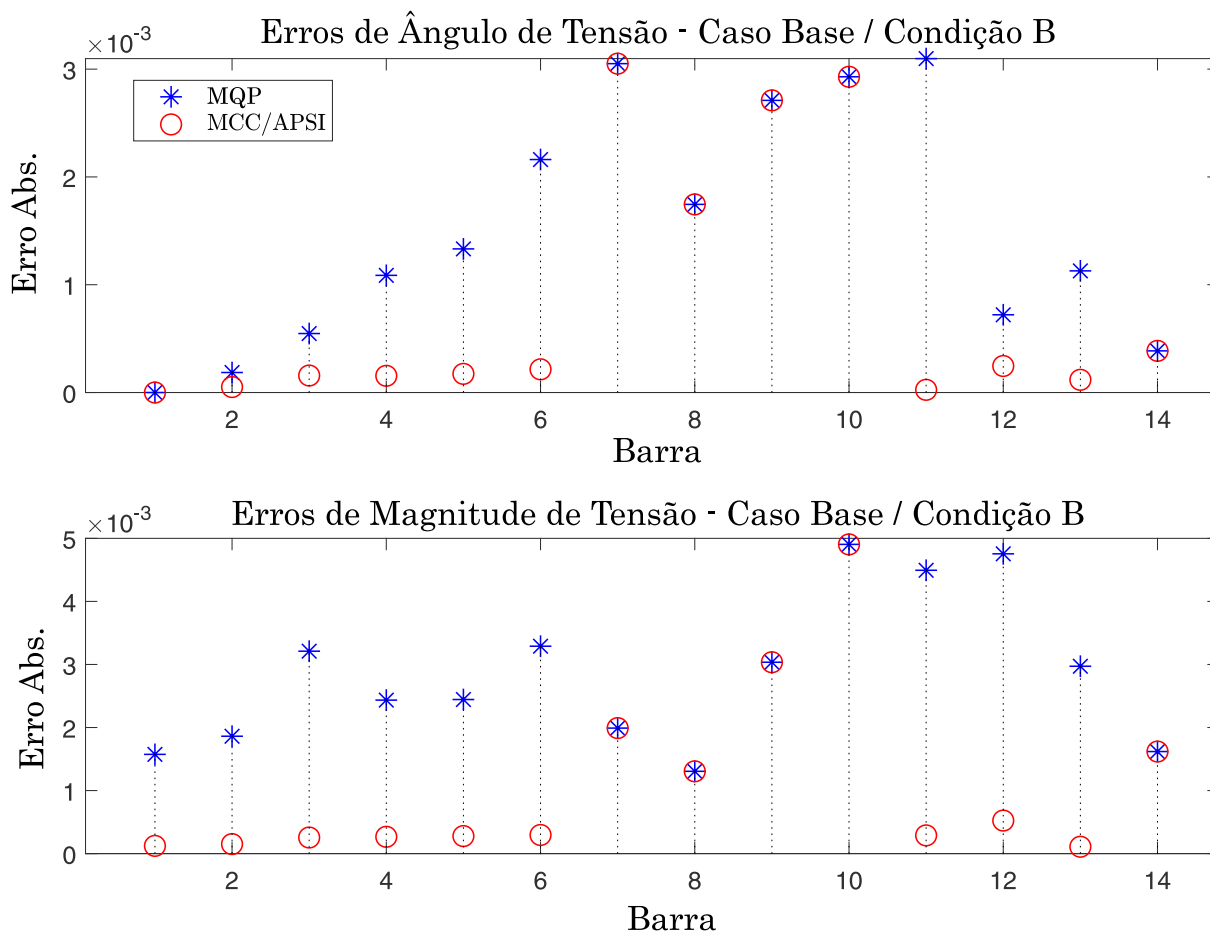


Figura 6.9 – Erros absolutos para as estimativas para ambos os estimadores MQP e MCC/APSI na ausência de erros grosseiros, *condição B*

Os três tipos de estudo de caso são agora simulados sob a condição de observabilidade *B*.

Primeiro, os resultados para *caso base* são mostrados na Figura 6.9, na qual pode ser facilmente visto que, através da metodologia proposta, as estimativas fornecidas para as variáveis de estado das barras não observáveis por PMUs coincidem com os resultados do estimador baseado nas medidas SCADA. Isso ocorre nos barramentos 7 a 10 e 14, onde as diferenças de erro nas estimativas produzidas pelos estimadores MQP e MCC/APSI são exatamente iguais a zero, pois estas barras não tem suas tensões monitoradas diretamente por medida PMU, nem tampouco possuem ramos incidentes cujas correntes são monitoradas por PMUs.

Sob a mesma condição de observabilidade, o caso *EG-SCADA* é simulado considerando um erro grosseiro de baixa magnitude, igual a 5 desvios-padrão, na medida convencional de magnitude de tensão da barra 11. Esta medida errônea afeta severamente os resultados do estimador MQP, como evidenciado na Figura 6.10, onde os erros absolutos para as estimativas em todas as barras são maiores que os erros

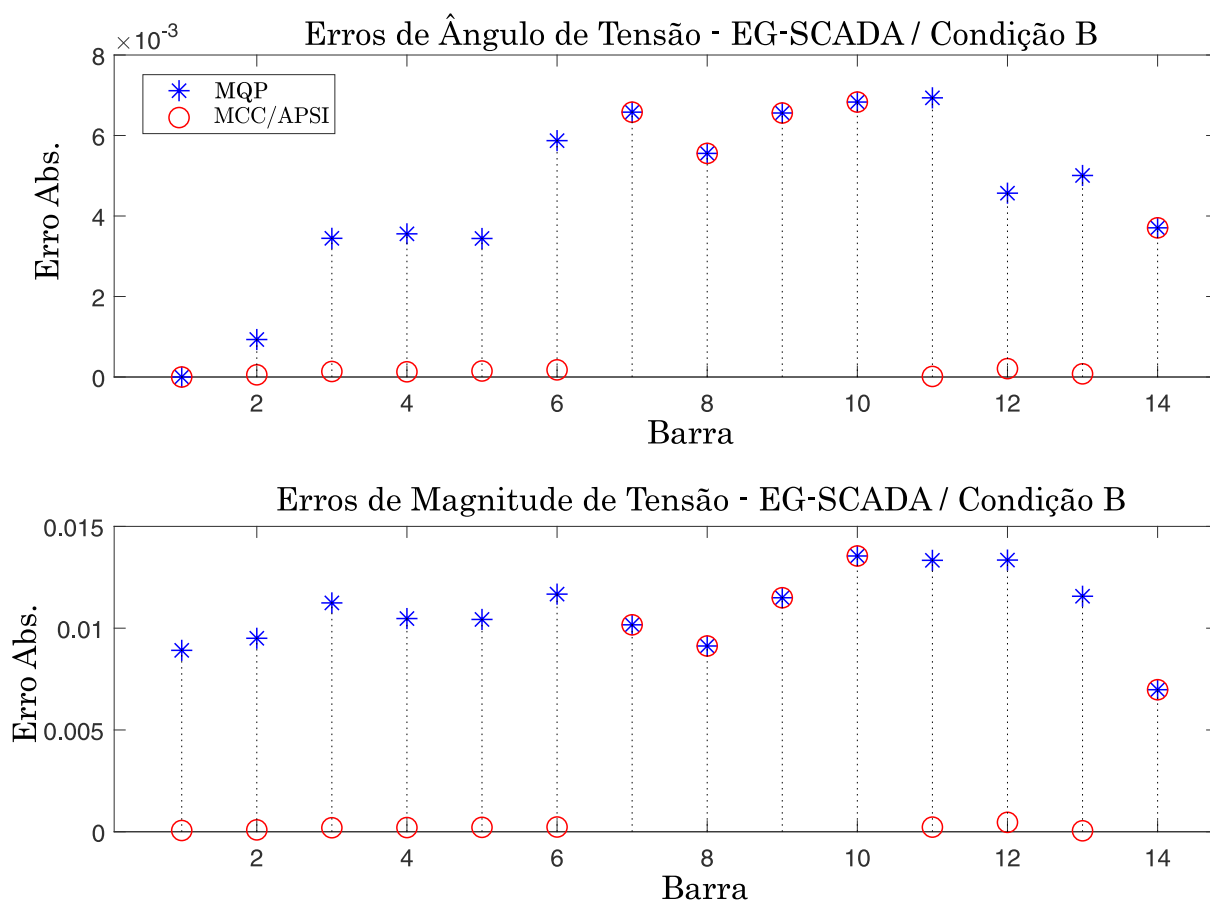


Figura 6.10 – Erros absolutos sobre as estimativas para o caso *EG-SCADA* sob a *Condição B*

do *caso base*. Quando tratadas como informação *a priori* pelo estimador MCC/APSI no segundo estágio, no entanto, essas estimativas baseadas no sistema SCADA são vistas como inconsistentes em relação às medidas fasoriais, que estão livres de erros grosseiros e, conseqüentemente, drasticamente subponderadas. As Figuras 6.11 e 6.12 mostram os pesos normalizados para medidas fasoriais sincronizadas e APSI, da mesma maneira já utilizada nas Figuras 6.7 e 6.8. Pode-se notar que algumas informações *a priori* dos barramentos 11 e 12 são eliminadas (ângulo da barra 11 e ângulos e magnitudes de tensão das barras 11 e 12), e pesos pequenos relativamente são obtidos para as magnitudes de tensão *a priori* nas barras que são observáveis por PMUs, como ocorre nas barras 1 a 6 e de 11 a 13. Por outro lado, as estimativas das barras não observáveis por PMUs têm seus erros não filtrados adequadamente (barras de 7 a 10 e barra 14), de modo que a solução (fornecida neste caso apenas pelo estimador MQP com base nas medidas SCADA) é ainda contaminada pelos efeitos do erro grosseiro em  $|V|_{11}$ .




Figura 6.11 – Pesos para ângulos de medidas PMUs e APSI de cada barramento na convergência (caso *EG-SCADA* - Condição B)




Figura 6.12 – Pesos para magnitudes de tensão de medidas PMUs e APSI de cada barramento na convergência (caso *EG-SCADA* - Condição B)

Finalmente, discute-se a seguir os resultados do caso *EG-SCADA&PMU*, obtidos através do estimador de estados MCC/APSI quando ocorrem erros grosseiros em ambos os subconjuntos de medidas SCADA e PMU. Nessa condição severa, as medidas convencionais e errôneas são as injeções de potência ativa e reativa no barramento 5, cuja tensão complexa é também monitorada diretamente por um dispositivo PMU. As magnitudes dos erros grosseiros das medidas SCADA de potência são iguais a 5 desvios-padrão das respectivas medidas. Quanto ao erro na medida fasorial, considera-se que a informação da medida de tensão complexa nodal da PMU no mesmo barramento 5 é perdida, de modo que o valor de leitura correspondente é arbitrariamente substituído por igual a 1,0 p.u. para a magnitude da tensão e zero radianos para o ângulo da tensão.

Como no caso *EG-SCADA*, as estimativas baseadas no estimador MQP são contaminadas pelos erros grosseiros. Entretanto, tais erros são eliminados pelo estimador MCC/APSI no segundo estágio do processo de estimação. Os pesos normalizados das medidas (de maneira semelhante ao caso *EG-SCADA*) são mostrados nas Figuras 6.13 e 6.14. Os pesos calculados para as medidas PMU  $V_5\angle\theta_5$  e para as variáveis de estados *a priori*  $\bar{V}_5\angle\bar{\theta}_5$  atingem valores próximos de zero na convergência, isto é, as medidas errôneas no subconjunto de medidas fasoriais e informações *a priori* inconsistentes são descartadas pelo algoritmo baseado em máxima correntropia. Ao final do processamento, a metodologia MCC/APSI é capaz de fornecer estimativas razoavelmente precisas, mesmo em situações severas onde erros grosseiros ocorrem nos dois subconjuntos de medição.




Figura 6.13 – Pesos para ângulos de medidas PMUs e APSI de cada barramento na convergência (caso *EG-SCADA&PMU* - Condição A)




Figura 6.14 – Pesos para magnitudes de tensão de medidas PMUs e APSI de cada barramento na convergência (caso *EG-SCADA&PMU* - Condição B)

### 6.4.1.3 Métricas do estimador MCC/APSII para os ensaios do sistema-teste do IEEE de 14 barras

Os resultados na Tabela 6.8 fornecem uma avaliação do desempenho do estimador de estados MCC/APSII com base nos índices de desempenho adotados e calculados para todos os estudos de caso descritos acima. Os resultados da tabela evidenciam que a abordagem de estimação em duas etapas supera os resultados do estimador MQP convencional em cada um dos estudos de caso aplicados ao sistema-teste de 14 barras do IEEE.

Tabela 6.8 – IEEE 14-bus performance indices

		Condição A			
		Caso Base		EG-SCADA	
		MQP	MCC/APSI	MQP	MCC/APSI
Métrica de tensão	$M_V$	$5,27 \times 10^{-3}$	$2,16 \times 10^{-4}$	$7,05 \times 10^{-3}$	$1,87 \times 10^{-4}$
Erro médio	$\theta$	$1,07 \times 10^{-3}$	$7,08 \times 10^{-5}$	$3,07 \times 10^{-3}$	$-4,74 \times 10^{-5}$
	$ V $	$4,64 \times 10^{-3}$	$1,37 \times 10^{-4}$	$4,06 \times 10^{-3}$	$8,24 \times 10^{-5}$
Desv.-padrão do erro	$\theta$	$9,86 \times 10^{-4}$	$1,18 \times 10^{-4}$	$3,56 \times 10^{-3}$	$1,29 \times 10^{-4}$
	$ V $	$2,01 \times 10^{-3}$	$8,22 \times 10^{-5}$	$3,01 \times 10^{-3}$	$8,34 \times 10^{-5}$

		Condição B					
		Caso Base		EG-SCADA		EG-SCADA&PMU	
		MQP	MCC/APSI	MQP	MCC/APSI	MQP	MCC/APSI
Métrica de Tensão	$M_V$	$3,63 \times 10^{-3}$	$2,29 \times 10^{-3}$	$1,21 \times 10^{-2}$	$7,28 \times 10^{-3}$	$5,22 \times 10^{-3}$	$3,44 \times 10^{-3}$
Erro Médio	$\theta$	$-1,42 \times 10^{-3}$	$-7,43 \times 10^{-4}$	$-4,50 \times 10^{-3}$	$-2,16 \times 10^{-3}$	$-3,32 \times 10^{-3}$	$-1,87 \times 10^{-3}$
	$ V $	$-2,62 \times 10^{-3}$	$-7,71 \times 10^{-4}$	$-1,08 \times 10^{-2}$	$-3,79 \times 10^{-3}$	$-3,03 \times 10^{-3}$	$-1,10 \times 10^{-3}$
Desv.-Padrão do erro	$\theta$	$1,18 \times 10^{-3}$	$1,12 \times 10^{-3}$	$2,07 \times 10^{-3}$	$2,84 \times 10^{-3}$	$1,65 \times 10^{-3}$	$1,84 \times 10^{-3}$
	$ V $	$1,61 \times 10^{-3}$	$1,51 \times 10^{-3}$	$1,81 \times 10^{-3}$	$5,00 \times 10^{-3}$	$1,77 \times 10^{-3}$	$1,78 \times 10^{-3}$

#### 6.4.1.4 Rastreamento de erros grosseiros

Os resultados acima podem ser submetidos a um exame adicional que visa utilizar o dado APSI rejeitado no processo de estimação híbrida de estados para rastrear os erros grosseiros no subconjunto de medidas SCADA. O procedimento utilizado para este objetivo é o descrito na Seção 5.5 deste documento.

A Tabela 6.9 resume os resultados da aplicação da metodologia de identificação dos erros grosseiros nas medidas convencionais. Para os estudo de caso envolvendo medidas errôneas nesta Seção 6.4, verifica-se que são identificadas as informações *a priori* de estados inconsistentes, o que permite determinar o subconjunto suspeito de conter erros grosseiros entre as medidas convencionais. O número de medidas suspeitas depende da quantidade de variáveis de estado *a priori* rejeitadas e da condição de observabilidade apropriada fornecida pelas medidas fasoriais. A Tabela 6.9 reporta três testes de hipóteses: o teste do  $\chi^2$  e os testes de resíduo normalizado sobre  $\mathbf{r}_{SS}$  e  $\mathbf{r}_{SMCC}$ , sendo que nestes últimos é utilizado o nível de significância igual a  $\lambda = 3$  para identificar se uma medida SCADA possui erro grosseiro ou não. Já o teste do  $\chi^2$  é baseado no limiar de detecção obtido a partir da distribuição do qui-quadrado com uma probabilidade de alarme falso de 5%.

Verifica-se que o estimador MQP falha no teste do  $\chi^2$  em todos os estudos de caso realizados. Na tabela, pode-se notar que, para o caso EG-SCADA na condição B, o teste  $r_{SS}^N$  sinaliza a medição corrompida, mas o estágio de identificação na primeira

etapa de estimação não pode ser realizado devido à falha na detecção de erro grosseiro no teste do  $\chi^2$ . Nesse caso, o valor obtido para a soma ponderada dos quadrados dos resíduos  $J(\hat{\mathbf{x}}_S)$  é de 38,77 e o limiar da distribuição do qui-quadrado correspondente aos graus de liberdade é  $K = 40,1$ .

Os resultados de dois estudos de caso também reforçam que, conforme esperado, o teste  $r_{SS}^N$  não é capaz de identificar as medidas errôneas devido à ocorrência de conjunto crítico de medidas no subconjunto de medidas SCADA. Por outro lado, a identificação correta desses erros grosseiros nas medidas convencionais é alcançada mediante o cruzamento de informações com os resultados do estimador híbrido MCC/APSI, por meio do teste  $r_{SMCC}^N$  em todos os casos de erros grosseiros em medidas SCADA simulados nesta seção, conforme indicado na última coluna da Tabela 6.9.



Tabela 6.9 – Identificação de erros grosseiros em medidas SCADA através dos resultados do estimador MCC/APSI

Condição de Observ.	Estudo de caso	Erro grosseiro	APSI	Medidas SCADA	Teste de Hipóteses		
			inconsistentes	suspeitas ( $\mathcal{S}_{SMCC}$ )	Teste do $\chi^2$ em $J(\hat{x}_S)$	$r_{SS}^N$	$r_{SMCC}^N$
A	EG-SCADA	$p_{7-9}, q_{7-9}$	$\bar{\theta}_9, \bar{\theta}_{10},$ $ \bar{V} _9$ e $ \bar{V} _{10}$	$V_9, V_{11}, p_{9-4}, q_{9-4},$ $p_{7-9}, q_{7-9}, p_{10-9}, q_{10-9},$ $p_{14-9}, q_{14-9}, p_{10-11}, q_{10-11},$ $P_{11}, Q_{11}$	Falso	Não sinalizado	$p_{7-9}, q_{7-9}$
	EG-SCADA	$ V _{11}$	$\bar{\theta}_{11},  \bar{V} _{11},$ e $ \bar{V} _{12}$	$V_6, V_{11}, p_{11-6}, q_{11-6}, p_{12-16},$ $q_{12-6}, p_{12-13}, q_{12-13}, P_6, Q_6$	Falso	$ V _{11}$	$ V _{11}$
B	EG-SCADA & PMU	$P_5, Q_5$ (SCADA) $ V _5, \theta_5$ (PMU)	$\bar{\theta}_3$ a $\bar{\theta}_6$ e $\bar{\theta}_{11}$ a $\bar{\theta}_{13},  \bar{V} _1$ a $ \bar{V} _5$ e $ \bar{V} _{11}$ a $ \bar{V} _{13}$	31 Medidas SCADA	Falso	Não sinalizado	$P_5, Q_5$

## 6.4.2 Avaliação de desempenho com sistemas de médio porte

Nesta subseção, o estimador de estados MCC/APSI é aplicado aos sistemas-teste do IEEE de 57 e 118 barras. O plano de medição empregado para cada sistema é apresentado na Tabela 6.10. Nesta tabela, são descritos o número de pares de medidas de potência (injeções nas barras  $P/Q$  e fluxos nos ramos  $p_{ij}/q_{ij}$ ) e de magnitudes de tensão ( $|V|$ ) monitoradas pelo sistema SCADA e também as medidas de fasores de tensão ( $\dot{V}$ ) e de corrente nos ramos ( $\dot{I}$ ) provenientes dos dispositivos PMU. As notações  $m$  e  $\bar{n}$  representam o total de medidas fornecidas por cada sensor e o número de barras não observáveis relacionados às correspondentes classes de medidas. Todos os três tipos de estudo de caso são realizados: *caso base*; *EG-SCADA*, em que uma ou duas medidas do subconjunto SCADA são contaminadas por erros grosseiros, com magnitude entre 10 a 30 desvios-padrão das medidas; e *EG-SCADA&PMU*, que envolve múltiplos erros grosseiros em medidas convencionais e PMUs. Especificamente, as medidas errôneas são uma medida convencional e uma unidade de medição de fasor sincronizado, que pode ser uma perda de informação de tensão nodal ou um fasor de corrente errôneo, cuja magnitude do erro está entre 20 a 40 desvios-padrão da medida PMU. O posicionamento do erro grosseiro, assim como o valor da magnitude do erro para as medidas de SCADA e PMU, é realizado aleatoriamente através de uma distribuição uniforme em cada simulação individual. Para os resultados apresentados nesta subseção, considera-se que o estágio de processamento de erros grosseiros do primeiro estágio é desativado, ou seja, qualquer medida errônea processada pelo estimador MQP de estados afeta sua solução e, como consequência, informações *a priori* inconsistentes são produzidas. Justifica-se a desativação do processamento de erros grosseiros no primeiro nível de estimação para melhor avaliar a capacidade de resiliência do estimador híbrido MCC/APSI, isto é, verificar seu desempenho tanto na eliminação de informações *a priori* que são inconsistentes com as estimativas dadas pelas medidas fasoriais, quanto na identificação de medidas SCADA contaminadas por erros grosseiros.

Tabela 6.10 – Número de medidas SCADA e PMU para os sistemas-teste do IEEE de 57 e 118 barras

IEEE 57 barras							
Sensor	$P/Q$	$ V $	$p_{ij}/q_{ij}$	$\dot{V}$	$\dot{I}$	$m$	$\bar{n}$
SCADA	34	29	58	-	-	213	0
PMU	-	-	-	18	65	166	18
IEEE 118 barras							
Sensor	$P/Q$	$ V $	$p_{ij}/q_{ij}$	$\dot{V}$	$\dot{I}$	$m$	$\bar{n}$
SCADA	72	67	120	-	-	451	0
PMU	-	-	-	35	117	304	29

Os resultados de todos os casos simulados são relatados por valores médios e estão resumidos na Tabela 6.11. O total de 8.000 simulações para cada sistema, com diferentes condições operacionais de carga e geração são utilizados para validar a abordagem proposta.

O *caso base* compreende 2.000 simulações em que as medidas de SCADA e PMU estão isentas de erros grosseiros. Mediante resultados dos valores de métrica de tensão, é perceptível que a alta penetração das PMUs melhora substancialmente os resultados das estimativas, uma vez que os índices são reduzidos em 31% e 45%, considerando, respectivamente, a inclusão de medidas fasoriais sincronizadas nos barramentos nos sistemas-teste do IEEE de 57 e 118 barras. O mesmo desempenho entre os estimadores de estados MQP e MCC/APSI é observado para a média dos erros e os valores de desvios-padrão dos resultados obtidos em várias simulações.

Na sequência, é detalhada a capacidade de rejeição de erros grosseiros relacionada à metodologia proposta. Os resultados para o caso *EG-SCADA* também são mostrados na Tabela 6.11, considerando 4.000 simulações para cada sistema-teste. Para essa anomalia específica, os erros grosseiros ocorrem apenas no subconjunto de medidas convencionais, onde um (1 EG) ou dois (2 EG) erros grosseiros com localização aleatória são simulados e processados pelo estimador de estados baseado no método MQP no primeiro estágio da abordagem híbrida. Conforme indicado na tabela, os resultados das métricas para estimativas obtidas pelo estimador baseado no sistema SCADA apresentam qualidade inferior quando comparadas com o *caso base*, o que é uma consequência da ausência do estágio de processamento de erros grosseiros. Por outro lado, quando as estimativas baseadas no sistema SCADA são tomadas como informações *a priori* pelo estimador MCC/APSI e processadas em conjunto com medidas PMU, informações *a priori* inconsistentes não contaminam as estimativas finais. A Tabela 6.11 também mostra as 2.000 simulações restantes, por sistema-teste, nas condições mais severas correspondentes ao caso *EG-SCADA&PMU*. Observe que mesmo considerando erros grosseiros presentes nos dois subconjuntos de medidas, os resultados para o estimador de estados MCC/APSI indicam o bom desempenho da estratégia proposta. Desta forma, a metodologia robusta para a estratégia de estimação híbrida em dois estágios é capaz de descartar informações *a priori* inconsistentes, bem como os erros grosseiros presentes no subconjunto de medidas PMU.

Tabela 6.11 – Índices de Desempenho para os sistemas-teste do IEEE de 57 e 118 barras

<b>IEEE 57 Barras</b>									
		<i>Caso Base</i>		<i>EG-SCADA</i>				<i>EG-SCADA&amp;PMU</i>	
		<i>MQP</i>	<i>MCC/APSI</i>	<i>MQP</i>		<i>MCC/APSI</i>		<i>MQP</i>	<i>MCC/APSI</i>
				1 EG	2 EG	1 EG	2 EG		
Métrica de Tensão	$M_V$	$7,83 \times 10^{-3}$	$5,39 \times 10^{-3}$	$1,08 \times 10^{-2}$	$1,42 \times 10^{-2}$	$7,80 \times 10^{-3}$	$9,78 \times 10^{-3}$	$1,16 \times 10^{-2}$	$8,64 \times 10^{-3}$
Erro Médio	$\theta$	$7,78 \times 10^{-6}$	$-2,74 \times 10^{-6}$	$1,32 \times 10^{-4}$	$2,04 \times 10^{-4}$	$6,51 \times 10^{-5}$	$1,01 \times 10^{-4}$	$-6,56 \times 10^{-5}$	$-4,65 \times 10^{-5}$
	$ V $	$3,02 \times 10^{-5}$	$1,12 \times 10^{-5}$	$-1,74 \times 10^{-5}$	$-4,00 \times 10^{-5}$	$5,02 \times 10^{-6}$	$-1,30 \times 10^{-5}$	$1,41 \times 10^{-5}$	$7,43 \times 10^{-6}$
Desv.-padrão do erro	$\theta$	$6,41 \times 10^{-3}$	$5,47 \times 10^{-3}$	$8,37 \times 10^{-3}$	$1,08 \times 10^{-2}$	$6,64 \times 10^{-3}$	$8,35 \times 10^{-3}$	$9,11 \times 10^{-3}$	$7,39 \times 10^{-3}$
	$ V $	$3,39 \times 10^{-3}$	$2,78 \times 10^{-3}$	$4,57 \times 10^{-3}$	$5,84 \times 10^{-3}$	$3,26 \times 10^{-3}$	$3,77 \times 10^{-3}$	$4,72 \times 10^{-3}$	$3,37 \times 10^{-3}$

<b>IEEE 118 Barras</b>									
		<i>Caso Base</i>		<i>EG-SCADA</i>				<i>EG-SCADA&amp;PMU</i>	
		<i>MQP</i>	<i>MCC/APSI</i>	<i>MQP</i>		<i>MCC/APSI</i>		<i>MQP</i>	<i>MCC/APSI</i>
				1 EG	2 EG	1 EG	2 EG		
Métrica de Tensão	$M_V$	$2,99 \times 10^{-3}$	$1,65 \times 10^{-3}$	$4,46 \times 10^{-3}$	$5,55 \times 10^{-3}$	$2,23 \times 10^{-3}$	$2,73 \times 10^{-3}$	$4,40 \times 10^{-3}$	$2,30 \times 10^{-3}$
Erro Médio	$\theta$	$1,29 \times 10^{-5}$	$1,24 \times 10^{-5}$	$-1,14 \times 10^{-4}$	$-6,62 \times 10^{-5}$	$-4,24 \times 10^{-5}$	$-2,94 \times 10^{-5}$	$6,38 \times 10^{-5}$	$7,25 \times 10^{-6}$
	$ V $	$-6,05 \times 10^{-5}$	$-2,20 \times 10^{-5}$	$2,95 \times 10^{-5}$	$3,33 \times 10^{-5}$	$1,08 \times 10^{-5}$	$1,71 \times 10^{-5}$	$1,67 \times 10^{-5}$	$1,41 \times 10^{-5}$
Desv.-padrão do erro	$\theta$	$1,91 \times 10^{-3}$	$1,17 \times 10^{-3}$	$2,76 \times 10^{-3}$	$3,39 \times 10^{-3}$	$1,61 \times 10^{-3}$	$1,98 \times 10^{-3}$	$2,70 \times 10^{-3}$	$1,66 \times 10^{-3}$
	$ V $	$1,41 \times 10^{-3}$	$8,43 \times 10^{-4}$	$2,02 \times 10^{-3}$	$2,56 \times 10^{-3}$	$1,15 \times 10^{-3}$	$1,43 \times 10^{-3}$	$2,03 \times 10^{-3}$	$1,22 \times 10^{-3}$

A Tabela 6.12 apresenta os índices de eficiência global para o método híbrido proposto com o processamento de erros grosseiros. Como pode ser visto, são obtidas excelentes taxas de desempenho através dos resultados fornecidos em diversas simulações feitas com os sistemas-teste do IEEE de 57 e 118 barras. A caracterização da eficiência do método é dada pela eliminação apropriada dos erros grosseiros em medidas fasoriais e pela identificação das medidas espúrias no subconjunto SCADA, de acordo com a metodologia de rastreamento de erros grosseiros. Por fim, a Tabela 6.13 resume os tempos médios computados no processamento da estimação híbrida de estados para ambos os sistemas-teste, considerando todos os estudos de caso. Como a metodologia de rastreamento de erros grosseiros no conjunto de medidas SCADA é considerada um procedimento extra a ser realizado após a estimação MCC/APSI de estados, os tempos médios correspondentes para esse estágio são mostrados separadamente ao do estimador baseado na máxima correntropia. Pode-se notar na Tabela 6.13 que os tempos computados para o *caso base* e *EG-SCADA* (um e dois erros grosseiros) não são tão diferentes. Tal fato é devido ao processamento de medidas fasoriais sincronizadas isentas de erros grosseiros e com suas correspondentes exatidões superiores em relação às informações *a priori*, o que geralmente faz com que o algoritmo convirja em não mais do que duas iterações. Por outro lado, os tempos de CPU são maiores para os casos *EG-SCADA&PMU*, o que é de se esperar pelo motivo de que dados espúrios estão presentes nas duas classes de medidas. Também pode-se notar que os tempos médios computados para o rastreamento de erros grosseiros aumentam levemente com o aumento no número de erros grosseiros, pois o tempo de processamento depende do número de medidas SCADA suspeitas, como consequência direta do aumento do número de informações *a priori* que são rejeitadas na segunda etapa da arquitetura de estimação.

Tabela 6.12 – Eficiência do processamento de erros grosseiros para o estimador híbrido MCC/APSI de estados e rastreamento de medidas espúrias no sistema SCADA

<b>IEEE 57 Barras</b>			
<i>EG-SCADA</i>			
	1 GE	2 GE	<i>EG-SCADA&amp;PMU</i>
PMU	-	-	98,35%
SCADA	99,75%	99,70%	98,95%
<b>IEEE 118 Barras</b>			
<i>EG-SCADA</i>			
	1 GE	2 GE	<i>EG-SCADA&amp;PMU</i>
PMU	-	-	97,50%
SCADA	99,75%	99,60%	99,50%

Tabela 6.13 – Tempos médios de processamento em segundos para os sistemas-teste do IEEE de 57 e 118 barras

<b>IEEE 57 Barras</b>				
	<i>Caso Base</i>	<i>EG-SCADA 1EG</i>	<i>EG-SCADA 2EG</i>	<i>EG-SCADA &amp;PMU</i>
<i>MCC/APSI</i>	0,183	0,198	0,212	0,392
<i>Rastreamento</i>	–	0,0025	0,0042	0,0027
<b>IEEE 118 Barras</b>				
	<i>Caso base</i>	<i>EG-SCADA 1EG</i>	<i>EG-SCADA 2EG</i>	<i>EG-SCADA &amp;PMU</i>
<i>MCC/APSI</i>	0,946	0,956	0,947	2,128
<i>Rastreamento</i>	–	0,0168	0,0170	0,0179

#### 6.4.3 Validação do Estimador MCC/APSI

Esta seção é dedicada à validação do estimador MCC/APSI a partir da comparação com resultados de um estimador híbrido simultâneo baseado no método dos mínimos quadrados ponderados.

Para a devida comparação com a metodologia proposta, considera-se um estimador de estados tradicional capaz de processar medidas convencionais oriundas do sistema SCADA, habilitado também para processar simultaneamente medidas fasoriais de tensão e corrente fornecidas pelo sistema de medição de fasores sincronizados, através de um algoritmo unificado baseado nas rotações rápidas de Givens. Este estimador híbrido simultâneo é denotado neste trabalho como MQP-Híbrido. A metodologia é apresentada em (LEITES, 2010), onde é exaustivamente testada utilizando vários sistemas-teste do IEEE. Ressalta-se que o processamento de medidas pelo estimador MQP-Híbrido é feito a partir de um vetor único de medidas, o que difere substancialmente do estimador de dois estágios apresentado neste trabalho, com as estimativas convencionais baseadas em medidas SCADA do primeiro estágio sendo tratadas como informações *a priori* no segundo estágio. Ambos estimadores são aplicados aos mesmos sistemas-teste do IEEE utilizados nas seções anteriores: 14, 30, 57 e 118 barras. As comparações de resultados apresentadas não consideram a presença de erros grosseiros nos conjuntos de medidas. Os planos de medição utilizados estão descritos na Tabela 6.14, em que  $m$  e  $\bar{n}$  são, respectivamente, o número total de medidas e o número de barramentos não observáveis pelo sensor em cada sistema-teste.

As Tabelas 6.15 a 6.18 apresentam os resultados para as estimativas de ângulos e magnitudes de tensão nas barras obtidas para os estimadores MQP-Híbrido e MCC/APSI. Nota-se que essencialmente os resultados para os quatro sistemas-teste são apresentadas não consideram equivalentes. Isto é esperado uma vez que, uma vez que a metodologia do estimador híbrido em (LEITES, 2010) realiza aproximações

Tabela 6.14 – Número de medidas SCADA e PMU para os sistemas-teste do IEEE de 14, 30, 57 e 118 barras

IEEE 14 barras								
Sensor	$P/Q$	$ V $	$p_{ij}/q_{ij}$	$\dot{V}$	$\dot{I}$	$m$	$\bar{n}$	
SCADA	12	6	34	-	-	52	0	
PMU	-	-	-	14	19	33	0	
IEEE 30 barras								
Sensor	$P/Q$	$ V $	$p_{ij}/q_{ij}$	$\dot{V}$	$\dot{I}$	$m$	$\bar{n}$	
SCADA	36	7	136	-	-	179	0	
PMU	-	-	-	2	11	13	20	
IEEE 57 barras								
Sensor	$P/Q$	$ V $	$p_{ij}/q_{ij}$	$\dot{V}$	$\dot{I}$	$m$	$\bar{n}$	
SCADA	34	29	58	-	-	213	0	
PMU	-	-	-	18	65	166	18	
IEEE 118 barras								
Sensor	$P/Q$	$ V $	$p_{ij}/q_{ij}$	$\dot{V}$	$\dot{I}$	$m$	$\bar{n}$	
SCADA	72	67	120	-	-	451	0	
PMU	-	-	-	35	117	304	29	

para as variâncias das medidas fasoriais. Entretanto, os valores para as estimativas obtidas pelos estimadores MQP-Híbrido e MCC/APSI são relativamente próximos, pois na ausência de erros grosseiros o estimador MCC/APSI comporta-se como um estimador tradicional devida à largura inicial das janelas de Parzen ser suficientemente ampla para conter todos os erros aleatórios das medidas.

Para uma melhor apreciação dos resultados numéricos obtidos pelos estimadores MQP-Híbrido e MCC/APSI, são apresentadas análises estatísticas das estimativas com base nas métricas de média e variância dos erros absolutos relativos aos resultados de estudos de fluxo de potência convergidos subjacentes aos casos apresentados. A Tabela 6.19 apresenta os indicadores estatísticos mencionados para os quatro sistemas-teste. Excelentes resultados são obtidos para os dois estimadores, podendo-se notar uma certa superioridade no desempenho da arquitetura MCC/APSI. Uma explicação para tal desempenho é que o tratamento das estimativas resultantes do estimador convencional como informações *a priori* de estados pelo estimador MCC/APSI garante a execução de dados mais precisos no segundo estágio.

Tabela 6.15 – Estados estimados obtidos através dos estimadores MQP-Híbrido e MCC/APSI para o Sistema-teste de 14 barras

Barra	MQP-Híbrido		MCC/APSI	
	$\theta$	V	$\theta$	V
1	-	1,0596	-	1,0596
2	-0,0714	1,0446	-0,0714	1,0446
3	-0,2150	1,0096	-0,2150	1,0096
4	-0,1760	1,0234	-0,1760	1,0234
5	-0,1527	1,0297	-0,1527	1,0297
6	-0,2726	1,0696	-0,2726	1,0696
7	-0,2186	1,0407	-0,2187	1,0407
8	-0,1870	1,0896	-0,1870	1,0896
9	-0,2622	1,0210	-0,2622	1,0210
10	-0,2705	1,0202	-0,2705	1,0202
11	-0,2741	1,0402	-0,2741	1,0401
12	-0,2898	1,0487	-0,2898	1,0486
13	-0,2893	1,0405	-0,2893	1,0403
14	-0,2967	1,0068	-0,2966	1,0067

Tabela 6.16 – Estados estimados obtidos através dos estimadores MQP-Híbrido e MCC/APSI para o Sistema-teste de 30 barras.

Barra	MQP-Híbrido		MCC/APSI		Barra	MQP-Híbrido		MCC/APSI	
	$\theta$	V	$\theta$	V		$\theta$	V	$\theta$	V
1	-	1,0534	-	1,0532	16	-0,0820	0,9905	-0,0816	0,9937
2	-0,0092	1,0278	-0,0092	1,0277	17	-0,0866	0,9841	-0,0862	0,9872
3	-0,0242	1,0220	-0,0241	1,0252	18	-0,1019	0,9709	-0,1014	0,9742
4	-0,0286	1,0142	-0,0286	1,0140	19	-0,1045	0,9677	-0,1039	0,9709
5	-0,0501	0,9894	-0,0501	0,9893	20	-0,1000	0,9721	-0,0995	0,9753
6	-0,0286	1,0073	-0,0286	1,0072	21	-0,0912	0,9747	-0,0908	0,9779
7	-0,0473	0,9914	-0,0473	0,9913	22	-0,0912	0,9750	-0,0909	0,9782
8	-0,0146	1,0071	-0,0146	1,0070	23	-0,0986	0,9679	-0,0981	0,9711
9	-0,0396	1,0150	-0,0396	1,0149	24	-0,1015	0,9586	-0,1010	0,9618
10	-0,0820	0,9891	-0,0819	0,9891	25	-0,1055	0,9594	-0,1049	0,9627
11	0,0235	1,0757	0,0233	1,0786	26	-0,1141	0,9391	-0,1134	0,9424
12	-0,0726	1,0056	-0,0723	1,0087	27	-0,1027	0,9701	-0,1020	0,9733
13	-0,0358	1,0359	-0,0357	1,0389	28	-0,0325	1,0021	-0,0325	1,0020
14	-0,0897	0,9877	-0,0893	0,9910	29	-0,1278	0,9470	-0,1270	0,9503
15	-0,0912	0,9821	-0,0907	0,9853	30	-0,1465	0,9338	-0,1455	0,9371



Tabela 6.17 – Estados estimados obtidos através dos estimadores MQP-Híbrido e MCC/APSI para o Sistema-teste de 57 barras.

MQP-Híbrido			MCC/APSI		MQP-Híbrido			MCC/APSI	
Barra	$\theta$	$V$	$\theta$	$V$	Barra	$\theta$	$V$	$\theta$	$V$
1	-	1,0019	-	1,0019	31	-0,1561	0,9706	-0,1560	0,9721
2	0,0190	0,9631	0,0190	0,9642	32	-0,1277	0,9473	-0,1282	0,9501
3	0,0392	0,9823	0,0392	0,9823	33	-0,1283	0,9457	-0,1287	0,9484
4	0,0409	0,9690	0,0410	0,9690	34	-0,0754	0,9309	-0,0761	0,9380
5	0,0553	0,9530	0,0554	0,9530	35	-0,0701	0,9323	-0,0701	0,9323
6	0,0679	0,9488	0,0680	0,9488	36	-0,0650	0,9366	-0,0650	0,9366
7	0,0962	0,9696	0,0962	0,9695	37	-0,0605	0,9394	-0,0605	0,9394
8	0,1515	0,9982	0,1515	0,9982	38	-0,0460	0,9469	-0,0460	0,9469
9	0,0532	0,9592	0,0532	0,9592	39	-0,0614	0,9390	-0,0614	0,9390
10	0,0049	0,9852	0,0048	0,9852	40	-0,0661	0,9367	-0,0661	0,9367
11	0,0196	0,9688	0,0196	0,9688	41	-0,0410	0,9644	-0,0410	0,9644
12	0,0066	1,0231	0,0066	1,0231	42	-0,0687	0,9465	-0,0687	0,9466
13	0,0055	0,9823	0,0055	0,9823	43	0,0016	0,9664	0,0015	0,9664
14	-0,0024	0,9753	-0,0024	0,9753	44	-0,0402	0,9532	-0,0402	0,9532
15	0,0059	0,9814	0,0059	0,9814	45	-0,0167	0,9745	-0,0167	0,9745
16	-0,0122	1,0139	-0,0122	1,0139	46	-0,0240	0,9666	-0,0240	0,9666
17	-0,0144	1,0047	-0,0144	1,0047	47	-0,0418	0,9522	-0,0414	0,9536
18	-0,0151	0,9510	-0,0145	0,9519	48	-0,0428	0,9510	-0,0428	0,9510
19	-0,0439	0,9321	-0,0432	0,9330	49	-0,0399	0,9556	-0,0399	0,9556
20	-0,0507	0,9320	-0,0499	0,9330	50	-0,0404	0,9497	-0,0399	0,9509
21	-0,0460	0,9425	-0,0453	0,9434	51	-0,0148	0,9786	-0,0144	0,9795
22	-0,0455	0,9445	-0,0455	0,9445	52	0,0370	0,9274	0,0371	0,9274
23	-0,0453	0,9435	-0,0453	0,9435	53	0,0266	0,9127	0,0265	0,9146
24	-0,0316	0,9382	-0,0316	0,9382	54	0,0302	0,9282	0,0302	0,9296
25	-0,1004	0,9495	-0,1002	0,9504	55	0,0385	0,9506	0,0385	0,9506
26	-0,0249	0,9360	-0,0247	0,9383	56	-0,0852	0,9524	-0,0852	0,9524
27	0,0208	0,9452	0,0208	0,9474	57	-0,0911	0,9415	-0,0911	0,9415
28	0,0448	0,9546	0,0449	0,9546					
29	0,0607	0,9640	0,0608	0,9640					
30	-0,1194	0,9510	-0,1193	0,9519					

Tabela 6.18 – Estados estimados obtidos através dos estimadores MQP-Híbrido e MCC/APSI para o Sistema-teste de 118 barras.

MQP-Híbrido			MCC/APSI		MQP-Híbrido			MCC/APSI	
Barra	$\theta$	$V$	$\theta$	$V$	Barra	$\theta$	$V$	$\theta$	$V$
1	-0,0123	0,9551	-0,0114	0,9562	61	0,3491	0,9947	0,3487	0,9954
2	-0,0043	0,9733	-0,0035	0,9744	62	0,3371	0,9977	0,3367	0,9984
3	-0,0065	0,9685	-0,0057	0,9696	63	0,3187	0,9977	0,3183	0,9984
4	0,0274	0,9981	0,0281	0,9993	64	0,3016	1,0012	0,3013	1,0019
5	0,0317	1,0003	0,0323	1,0015	65	0,223	1,0047	0,2228	1,0055
6	0,0073	0,9901	0,0076	0,9913	66	0,251	1,0498	0,2507	1,0506

Continua na próxima página

Tabela 6.18 – Continuação da página anterior

MQP-Híbrido			MCC/APSI		MQP-Híbrido			MCC/APSI	
Barra	$\theta$	V	$\theta$	V	Barra	$\theta$	V	$\theta$	V
7	0,0058	0,9896	0,0065	0,9907	67	0,2802	1,0215	0,2798	1,0222
8	0,0783	1,0152	0,0790	1,0164	68	0,1737	1,0095	0,1726	1,0110
9	0,1211	1,0347	0,1220	1,0359	69	-	1,0350	-	1,0360
10	0,1642	1,0505	0,1651	1,0518	70	-0,004	0,9840	-0,0039	0,9850
11	0,0098	0,9880	0,0106	0,9891	71	0,0017	0,9867	0,0017	0,9878
12	0,0085	0,9901	0,0092	0,9912	72	0,0475	0,9800	0,0475	0,9810
13	0,0016	0,9757	0,0023	0,9768	73	-0,002	0,9910	-0,0020	0,9920
14	0,0079	0,9847	0,0086	0,9858	74	-0,018	0,9580	-0,0183	0,9590
15	0,0251	0,9701	0,0256	0,9712	75	-0,004	0,9711	-0,0045	0,9722
16	0,0137	0,9842	0,0144	0,9854	76	0,0106	0,9427	0,0103	0,9441
17	0,0571	0,9897	0,0576	0,9908	77	0,1062	1,0060	0,1052	1,0076
18	0,0320	0,9731	0,0325	0,9742	78	0,1069	1,0047	0,1059	1,0062
19	0,0272	0,9631	0,0277	0,9642	79	0,1203	1,0091	0,1193	1,0107
20	0,0415	0,9646	0,0420	0,9656	80	0,1708	1,0400	0,1697	1,0415
21	0,0617	0,9675	0,0621	0,9685	81	0,1718	1,0259	0,1706	1,0274
22	0,0942	0,9785	0,0946	0,9795	82	0,1548	0,9878	0,1523	0,9899
23	0,1576	1,0022	0,1579	1,0033	83	0,1661	0,9838	0,1632	0,9860
24	0,1190	0,9920	0,1190	0,9928	84	0,1905	0,9810	0,1871	0,9834
25	0,2730	1,0502	0,2732	1,0512	85	0,2069	0,9850	0,2068	0,9872
26	0,2768	1,0152	0,2770	1,0162	86	0,2376	0,9927	0,2375	0,9949
27	0,1710	0,9681	0,1713	0,9691	87	0,3181	1,0149	0,3178	1,0171
28	0,1316	0,9631	0,1319	0,9642	88	0,2192	0,9921	0,2154	0,9943
29	0,0996	0,9645	0,1000	0,9656	89	0,2486	1,0051	0,2474	1,0070
30	0,1057	1,0102	0,1060	1,0113	90	0,200	0,9850	0,1959	0,9871
31	0,0944	0,9671	0,0949	0,9682	91	0,2153	0,9800	0,2141	0,9821
32	0,1285	0,9642	0,1280	0,9654	92	0,2465	0,9931	0,2453	0,9951
33	0,0202	0,9722	0,0207	0,9732	93	0,2439	0,9913	0,2427	0,9932
34	0,0355	0,9861	0,0357	0,9870	94	0,2475	0,9943	0,2463	0,9962
35	0,0306	0,9806	0,0308	0,9815	95	0,2154	0,9871	0,2121	0,9892
36	0,0306	0,9801	0,0308	0,9810	96	0,1881	0,9950	0,1869	0,9966
37	0,0400	0,9879	0,0402	0,9888	97	0,1748	1,0139	0,1736	1,0155
38	0,0965	0,9980	0,0966	0,9988	98	0,2209	1,0240	0,2197	1,0255
39	0,0026	0,9718	0,0029	0,9726	99	0,3781	1,0100	0,3767	1,0117
40	-0,0084	0,9701	-0,0082	0,9709	100	0,3412	1,0171	0,3399	1,0188
41	-0,0091	0,9684	-0,0088	0,9693	101	0,2919	0,9994	0,2906	1,0012
42	0,0235	0,9848	0,0234	0,9856	102	0,2605	0,9948	0,2592	0,9968
43	0,0789	0,9764	0,0790	0,9773	103	0,424	1,0012	0,4225	1,0028

Continua na próxima página

Tabela 6.18 – Continuação da página anterior

MQP-Híbrido			MCC/APSI		MQP-Híbrido			MCC/APSI	
Barra	$\theta$	V	$\theta$	V	Barra	$\theta$	V	$\theta$	V
44	0,1794	0,9780	0,1792	0,9790	104	0,3594	0,9711	0,3580	0,9728
45	0,2251	0,9847	0,2249	0,9857	105	0,3566	0,9651	0,3552	0,9668
46	0,3276	1,0048	0,3273	1,0057	106	0,3326	0,9653	0,3312	0,9670
47	0,2203	1,0152	0,2201	1,0160	107	0,3065	0,9521	0,3052	0,9538
48	0,2480	1,0160	0,2477	1,0168	108	0,386	0,9671	0,3807	0,9687
49	0,2331	1,0248	0,2328	1,0257	109	0,3984	0,9680	0,3932	0,9697
50	0,2360	1,0038	0,2357	1,0046	110	0,4358	0,9736	0,4306	0,9752
51	0,2417	0,9772	0,2414	0,9780	111	0,5474	0,9801	0,5418	0,9817
52	0,2403	0,9693	0,2393	0,9706	112	0,3893	0,9753	0,3842	0,9769
53	0,2576	0,9564	0,2567	0,9575	113	0,0623	0,9931	0,0627	0,9942
54	0,2882	0,9548	0,2879	0,9556	114	0,1391	0,9618	0,1386	0,9631
55	0,2830	0,9518	0,2822	0,9528	115	0,1414	0,9617	0,1409	0,9630
56	0,2835	0,9539	0,2827	0,9548	116	0,1814	1,0048	0,1797	1,0061
57	0,2585	0,9735	0,2575	0,9745	117	-0,01	0,9796	-0,0091	0,9807
58	0,2556	0,9658	0,2546	0,9670	118	-0,003	0,9536	-0,0027	0,9549
59	0,3513	0,9847	0,3510	0,9854					
60	0,3416	0,9934	0,3412	0,9941					

Tabela 6.19 – Resultados das métricas de média e variância para os estimadores MQP-Híbrido e MCC/APSI.

14 Barras		
	MQP-Híbrido	MCC/APSI
Erro abs. médio	0,000256	0,000239
Variância do erro	$2,65 \times 10^{-8}$	$2,01 \times 10^{-8}$
30 Barras		
	MQP-Híbrido	MCC/APSI
Erro abs. médio	0,001355	0,000144
Variância do erro	$9,67 \times 10^{-6}$	$9,27 \times 10^{-8}$
57 Barras		
	MQP-Híbrido	MCC/APSI
Erro abs. médio	0,000699	0,000144
Variância do erro	$1,87 \times 10^{-6}$	$1,23 \times 10^{-7}$
118 Barras		
	MQP-Híbrido	MCC/APSI
Erro abs. médio	0,00114	0,000103
Variância do erro	$4,27 \times 10^{-6}$	$4,22 \times 10^{-8}$

## 6.5 ANÁLISE GERAL DOS RESULTADOS

A aplicação do conceito de correntropia para a modelagem do problema de estimação de estados em sistemas de potência, combinada com a resolução através do algoritmo da versão rápida das rotações de Givens, mostra-se eficaz na estimação de estados. Suas vantagens são particularmente evidenciadas quando o conjunto de medidas é contaminado por erros grosseiros. Com o objetivo de confirmar esta propriedade, os modelos de correntropia para a estimação de estados são submetidos neste capítulo a diversos testes para a validação da sua resiliência e robustez numérica na presença de erros grosseiros.

A primeira contribuição desta tese diz respeito a um estimador de estados que processa somente uma classe de medida, que no caso são as medidas convencionais fornecidas pelo sistema SCADA. A série de resultados obtidos tem por base a execução do estimador MCC aplicado a quatro sistemas-teste, considerando diversos tipos e configurações de erros grosseiros, sejam eles simples ou múltiplos, conformes e não conformes. O processamento do algoritmo MCC ortogonal não apresentou nenhuma dificuldade de convergência, sendo que o número de iterações tomadas pelo *laço externo* é um fator que depende do número de erros grosseiros presentes no conjunto de medidas. Já para o *laço interno*, onde é processado o algoritmo das rotações rápidas de Givens com diferentes “janelas de observação” para as medidas, leva em média de 3 a 4 iterações, indiferentemente da quantidade de medidas errôneas presentes no conjunto de medidas. De acordo com as simulações realizadas no sistema-teste de 14 barras do IEEE, os pesos dinâmicos associados às medidas são facilmente atribuídos no decorrer do processo iterativo, o que também leva a uma metodologia para a identificação e exclusão de *outliers*, assim como a recuperação de medidas que são atingidas pelo efeito de espalhamento de erros grosseiros.

Ainda com relação ao desempenho, deve-se mencionar que a avaliação dos resultados do estimador MCC é realizada a partir da comparação direta com o estimador de estados convencional baseado no método MQP equipado com o teste do máximo resíduo normalizado. Um desempenho superior é particularmente verificado para o estimador MCC quando múltiplos erros grosseiros fortemente correlacionados estão presentes no conjunto de medidas. Nesta severa condição, o estimador MCC é capaz de eliminar os erros grosseiros e ainda garantir boas estimativas para as variáveis de estado, o que não é proporcionado pelo estimador tradicional.

Outro fator avaliado como forma de validação do estimador MCC é o processamento de erros grosseiros, mediante a execução de extensivos testes nos quais tanto o local onde a medida errônea é posicionada quanto a magnitude do erro são selecionados por sorteio tendo como base uma distribuição uniforme. Tal procedimento fornece uma análise estatística justa dos resultados. Estes indicam superioridade nos índices de sucesso de eliminação de erros grosseiros pelo estimador MCC quando

comparados aos resultados do estimador MQP. Do mesmo modo, o estimador híbrido proposto foi avaliado mediante comparação com um estimador convencional capaz de processar medidas SCADA e fasoriais de forma unificada. Neste contexto, sob as mesmas condições de observabilidade e na ausência de erros grosseiros em ambos conjuntos de medidas, os resultados entre os estimadores são equivalentes.

Os resultados para a arquitetura híbrida de estimação de estados com base no modelo de correntropia podem ser analisados em duas partes. A primeira é referente ao estimador MCC capaz de processar informações de estados *a priori* simultaneamente com as medidas fasoriais sincronizadas, combinando, portanto, a saída do estimador MQP com os dados de PMUs. Observa-se que boas estimativas são obtidas pelo estimador MCC/APSI, mesmo quando processam informações *a priori* fornecidas por medidas SCADA contaminadas no primeiro estágio de estimação. Ressalta-se que as informações *a priori* de estado são incluídas sem custo computacional no processo de estimação de estados. A segunda análise é referente ao rastreamento de erros grosseiros no subconjunto de medidas SCADA, feito a partir da associação da saída do estimador robusto de estados e o modelo de medidas convencionais. Ao aplicar a normalização de resíduos é possível identificar, com altas taxas de sucesso, as medidas SCADA estão contaminadas por erros grosseiros, cujos efeitos refletidos nas informações *a priori* foram previamente eliminados no curso da estimação MCC/APSI.

Em resumo, os resultados obtidos mediante as propostas de estimação MCC e estimação híbrida MCC/APSI, para diferentes sistemas-teste e considerando ainda a inclusão de diversos tipos e configurações de erros grosseiros em medidas convencionais e fasoriais, indicam que as metodologias propostas de estimação são não apenas viáveis, mas plenamente eficientes para aplicação à modelagem em tempo real de sistemas elétricos de potência.

## 6.6 CONCLUSÃO

Neste Capítulo foram apresentados resultados obtidos com os algoritmos propostos para a estimação de estados baseada no critério de máxima correntropia, resolvido mediante o algoritmo ortogonal das rotações rápidas de Givens, e aplicados aos sistemas-teste IEEE 14, 30, 57 e 118 barras.

A resolução baseada na versão rápida das rotações de Givens facilita o processamento de medidas ponderadas, que resultam da aplicação das propriedades de correntropia. Conseqüentemente, as propriedades de resiliência podem ser aplicadas eficientemente no decorrer do processo iterativo. Os resultados apresentados têm o objetivo de validar o métodos propostos. Para este fim, uma grande quantidade de simulações foram realizadas com sistemas-teste de 14, 30, 57 e 118 barras do IEEE, de modo a permitir uma análise estatística dos resultados quando o algoritmo é submetido a diferentes condições de operação e a diferentes erros grosseiros. Os resultados

alcançados para a eliminação dos efeitos de erros grosseiros tiveram êxito superior a 96% das simulações com a presença de medidas espúrias. Uma vantagem evidente da metodologia proposta advém de sua propriedade intrínseca em fornecer estimativas confiáveis sem a necessidade da etapa de pós-processamento para detecção, identificação e eliminação de erros grosseiros.

Também são apresentados os resultados para o estimador de estados híbrido, com arquitetura de dois estágios, capaz de processar medidas convencionais e fasoriais sincronizadas. A arquitetura mantém o estimador clássico MQP no primeiro estágio, enquanto possibilita processar medidas fasoriais no segundo módulo, que trata como informações de estado *a priori* os resultados provenientes do primeiro estágio. A principal contribuição desta metodologia é a utilização do método MCC no segundo estágio, o que permite explorar as propriedades superiores de rejeição de informações espúrias deste algoritmo de estimação e assim obter estimativas confiáveis mesmo se erros grosseiros estiverem presentes em medidas SCADA, em medidas fasoriais ou em ambas. Estudos de caso utilizando os sistemas-teste de 14, 57 e 118 barras do IEEE confirmam as propriedades de resiliência do estimador MCC/APSI.

Pode-se simultaneamente concluir que os algoritmos propostos apresentam boas características de robustez, pois convergiram quando submetidos a condições severas envolvendo vários tipos erros grosseiros. As propriedades de resiliência do método MCC mostram-se capazes de eliminar os efeitos dos erros grosseiros, sem a necessidade de realizar procedimentos adicionais de detecção, identificação e remoção de medidas espúrias. Adicionalmente, as rotações rápidas de Givens facilitam tanto o processamento de medidas quanto de informações *a priori* de estados além de emprestarem robustez numérica ao processamento, conforme assegurado pelas propriedades do estimador ortogonal.

## 7 CONCLUSÕES GERAIS

### 7.1 CONSIDERAÇÕES FINAIS

A operação em tempo real de sistemas elétricos de potência tem como principal objetivo assegurar o suprimento de energia elétrica aos consumidores e garantir a continuidade e qualidade do serviço. Nesta perspectiva, a estimação de estados é a ferramenta essencial para permitir que o Operador do sistema elétrico monitore a condição de operação corrente, com base em informações coletadas da rede elétrica praticamente em tempo real. Os algoritmos de estimação de estados devem necessariamente levar em conta que tais dados estão sujeitos a diversos tipos de erros, que tendem a contaminar medidas provenientes do sistema SCADA assim como as do sistema de medição fasorial sincronizada, e conseqüentemente garantir que tais erros grosseiros sejam eliminados antes de produzir estimativas confiáveis a serem disponibilizadas ao Operador do sistema.

A proposta desta tese pode ser sumarizada como a concepção de algoritmos de estimação de estados baseados nas propriedades do critério de máxima correntropia (MCC) tendo como método de solução as rotações ortogonais de Givens, de acordo como apresentado nos Capítulos 4 e 5. Os estimadores resultantes são capazes de eliminar automaticamente e de forma numericamente robusta, dentro do curso do próprio processo de estimação, os efeitos de possíveis erros grosseiros presentes no conjuntos de medidas de modo a fornecer estimativas confiáveis para as variáveis de estado.

Dois modelos de estimação são propostos com base no algoritmo ortogonal. O primeiro, o qual processa somente uma classe de medida, é desenvolvido e exaustivamente testado em redes elétricas distintas e com diferentes tipos e condições de erros grosseiros. O objetivo é explorar a capacidade de rotações Givens de três multiplicadores (G3M) para processar medidas individualmente, possibilitando assim remover facilmente os efeitos de erros grosseiros, rotulados como *outliers* dentro do processo de otimização. Além disso, as rotações ortogonais fornecem robustez numérica a um algoritmo que lida com pesos de medidas amplamente distintos, uma conhecida causa de problemas de mau condicionamento numérico. A característica de reponderação das medidas através do algoritmo MCC é uma consequência do ajuste iterativo da largura das janelas Parzen, mecanismo utilizado para depurar o conjunto de dados disponíveis ao estimador de estados. Os ajustes das janela de Parzen, por sua vez, são realizados por meio de uma combinação de métodos convencionais de processamento de erros grosseiros, como resíduos normalizados e o método- $\hat{b}$  para fornecer estimativas das magnitudes de erros de medição. A combinação das ferramentas acima mencionadas mostra-se eficaz para produzir um algoritmo de estimação de estados numericamente robusto, capaz de suprimir erros grosseiros durante o próprio processo

de estimação, dispensando estágios adicionais de pós-processamento.

Outro modelo desenvolvido nesta tese de doutorado é uma implementação híbrida baseada no MCC aplicada a uma arquitetura de estimação de estados de dois estágios, capaz de processar medidas convencionais e fasoriais sincronizadas. A extensão da função-objetivo do modelo de estimação MCC de estados permite suprimir tanto valores discrepantes em informações *a priori* sobre variáveis de estados, quanto medidas fasoriais errôneas. A arquitetura de estimação de estados robusta é composta de dois níveis. Enquanto o primeiro estágio consiste em um estimador convencional baseado nas medidas SCADA, o algoritmo MCC é empregado para processar medidas oriundas de PMUs no segundo estágio. Este é dotado da capacidade de processar informações *a priori* de estado (APSI), o que possibilita mesclar o resultados de ambos os estimadores e assim melhorar a qualidade das estimativas convencionais mediante o processamento dos dados fasoriais disponíveis. Do ponto de vista prático, uma propriedade particularmente atraente do esquema proposto é que a observabilidade com relação às medidas PMU não é necessária, desde que a rede elétrica seja observável com respeito às medidas SCADA. O principal objetivo do uso de um estimador baseado em MCC no segundo estágio é explorar suas propriedades superiores de rejeição de dados errôneos, a fim de produzir estimativas válidas mesmo sob a ocorrência de erro grosseiros nos subconjuntos de medição SCADA e PMU.

Um procedimento extra vinculado ao estimador MCC híbrido robusto é igualmente proposto nesta tese para identificar medidas errôneas no subconjunto SCADA a partir dos resultados da estimação MCC/APSI de estados. Esta abordagem de rastreamento de erros grosseiros em medidas convencionais baseia-se no cruzamento dos resultados das estimativas finais e dos resíduos de estimação em medidas suspeitas. Estas são selecionadas através de sua relação com as informações *a priori* rejeitadas no curso do processo de estimação. Testes exaustivos reportados neste documento indicam que a metodologia resultante é capaz de identificar com excelente precisão erros grosseiros presentes em medidas convencionais.

O desempenho das dos métodos propostos nesta tese é aferido mediante índices específicos que permitem a comparação dos valores estimados com os obtidos de estudos de fluxo de potência convergido. Os resultados dos diversos estudos de caso realizados indicam que valores adequados para os índices de desempenho são consistentemente alcançados, independentemente do porte do sistema investigado.

Em resumo, conclui-se a partir dos resultados numéricos de simulação neste trabalho, obtidos para os sistemas-teste do IEEE de 14, 30, 57 e 118 barras, que as metodologias propostas tanto para a Estimação Robusta com base em uma única classe de medidas quanto para a Estimação Híbrida de Estados são plenamente viáveis para aplicação na modelagem em tempo real de sistemas elétricos de potência. É importante salientar as excelentes características de robustez dos algoritmos pro-



postos, atestadas pela obtenção de convergência em todos os casos, mesmo quando submetidos a vários tipos de erros grosseiros múltiplos.

## 7.2 SUGESTÕES PARA TRABALHOS FUTUROS

A implementação das propostas de Estimação MCC de Estados apresentadas neste trabalho tem por objetivo promover um processo unificado para expurgar automaticamente erros grosseiros possivelmente presentes no conjunto de medidas de modo a produzir boas estimativas para as variáveis de estados. As propriedades da metodologia discutida nesta tese indicam um grande potencial para avanço com respeito as outras propostas encontradas na literatura, como (ASCARI; SIMÕES COSTA; MIRANDA, 2019; MENEGHETTI *et al.*, 2020; TAVARES *et al.*, 2017; PESTEH; MOAYYED; MIRANDA, 2020; PESTEH; MOAYYED; MIRANDA *et al.*, 2019). Ressalta-se também as vantagens em se utilizar os métodos ortogonais para emprestar robustez numérica ao processo, e ainda usufruir dos benefícios a eles associados, como o processamento linha-a-linha, a facilidade de verificação dos pesos das medidas, a inclusão de informações *a priori* sem custo computacional, entre outros.

Os tópicos relacionados a seguir são vistos como temas potenciais para trabalhos de pesquisa futuros:

- Aplicação dos conceitos de correntropia a arquiteturas distribuídas de estimação de estados, com estudos de implementação tanto em conexão com modelos hierárquicos quanto descentralizados de estimação. Entende-se por modelos hierárquicos as arquiteturas compostas por regiões da rede elétrica que possuem estimadores de estados independentes, sujeitas à coordenação das estimativas em um nível superior. Já os modelos descentralizados utilizam as redes de comunicação entre as áreas, retirando a necessidade de outros níveis superiores de coordenação (VAN CUTSEM; HORWARD; RIBBENS-PAVELLA, 1981; YANG; ZHANG; ZHOU, 2012; ZHAO; ABUR, 2005; ZHENG *et al.*, 2017). A ideia geral é aplicar os benefícios de resiliência do estimador MCC a tais modelos, assim como reduzir o custo computacional através do particionamento da rede elétrica;
- Investigar adaptações do critério de máxima correntropia à arquitetura APSI em blocos proposta em (BEZ *et al.*, 2020) para a estimação híbrida de estados. Esta abordagem permite processar medidas fasoriais sincronizadas concomitantemente com as informações *a priori* de estado por um algoritmo não-iterativo de estimação. A agregação dos princípios de máxima correntropia ao algoritmo do segundo estágio apresenta-se como potencialmente vantajosa para permitir a depuração de dados errôneos durante o processo de estimação híbrida;

- Investigar a aplicação das rotações de Givens com três multiplicadores (G3M) a estimadores MCC híbridos baseados na estratégia de fusão de estimativas. Estimadores híbridos baseados no princípio de fusão sensorial surgiram como uma proposta muito promissora para combinar estimativas obtidas individualmente a partir de medidas fasoriais sincronizadas e de medidas convencionais (SIMÕES COSTA; ALBUQUERQUE; BEZ, 2013). Mais recentemente, este conceito foi estendido pela aplicação de algoritmos de máxima correntropia aos módulos individuais de estimação, os quais processam medidas SCADA e medidas fasoriais (ASCARI; SIMÕES COSTA; MIRANDA, 2019). Da mesma forma que os métodos propostos nesta tese, tais estimadores podem se beneficiar das propriedades desejáveis de robustez numérica do algoritmo G3M, bem como das estratégias de ajuste das janelas de Parzen igualmente desenvolvidas no presente trabalho;
- Utilização do modelo MCC para a validação da topologia da rede nos estudos de modelagem em tempo real. Esta estratégia compõem o escopo da coestimação de estados e topologia do sistema elétrico de potência. O modelo MCC é utilizado para a inclusão da topologia em (MENEGETTI *et al.*, 2020) para processar os *status* dos disjuntores juntamente com as medidas e eliminar possíveis erros presentes na topologia. As propriedades das rotações rápidas de Givens podem ser utilizadas para incluir os dados disponíveis sobre a topologia no processo de estimação, sob a forma de informações *a priori* (FREITAS; SIMOES COSTA, 2015; VOSGERAU *et al.*, 2010). A agregação adicional dos conceitos de máxima correntropia permite a rejeição não apenas de erros grosseiros em medidas, mas também de possíveis dados espúrios sobre a topologia da rede. A incorporação das rotações ortogonais neste processo contribuiria para melhorar a robustez numérica, em uma aplicação que novamente envolve ponderações largamente discrepantes dos dados disponíveis para a coestimação;
- Exploração de outros conceitos da Teoria da Informação para o estudo do ajuste das Janelas de Parzen. Para que a rejeição automática de erros grosseiros seja realizada corretamente é imprescindível que ocorra o ajuste iterativo dos *kernels* gaussianos. Desta forma, outras técnicas oriundas da TI podem auxiliar no ajuste da largura destas janelas, como a divergência de Kullback-Leibler, a desigualdade de Cauchy-Schwarz e redes Bayesianas (MAGALHAES CARVALHO; LEITE DA SILVA; MIRANDA, 2018; BESSANI *et al.*, 2020; MIRANDA; TEIXEIRA; PEREIRA, 2019);
- Implementação de estimadores de estados baseados em modelos de máxima correntropia aplicados à sistemas de distribuição levando em conta as evidentes diferenças entre os sistemas de transmissão e de distribuição. Os modelos MCC de estimação de estados podem igualmente contribuir para a modelagem

em tempo real dos sistemas de distribuição (KHALILI; RASTEGARNIA; SANEI, 2015), desde que adaptados para enfrentar os seguintes desafios: limitações quanto às medidas disponíveis nas redes de distribuição; possível presença de microrredes e geração distribuída, cargas contemplando a presença de veículos elétricos, entre outros;

- O uso de pseudo-medidas geradas a partir da disponibilidade do histórico de dados da Operação do sistema pode ser vista como uma possibilidade de melhoria da redundância virtual de medidas, e assim contribuir para a melhoria do processamento de erros grosseiros. Esta perspectiva gera uma nova fonte de dados para a estimação de estados, cuja integração às classes existentes de medidas abre novas possibilidades de aplicação dos estimadores baseados no critério de máxima correntropia.

## REFERÊNCIAS

- ABUR, Ali; GOMEZ EXPOSITO, A. **Power System State Estimation: Theory and Implementation**. Edição: Marcel Dekker. [S.l.]: CRC press, 2004. P. 336. DOI: 10.1201/9780203913673.
- ALLAM, M.F.; LAUGHTON, M.A. Power-system dynamic-state estimation by optimal variable incremental displacements. **Proceedings of the Institution of Electrical Engineers**, Institution of Engineering e Technology (IET), v. 123, n. 5, p. 433, 1976. DOI: 10.1049/piee.1976.0096.
- ALSAC, O. *et al.* Generalized state estimation. **IEEE Transactions on Power Systems**, v. 13, n. 3, p. 1069–1075, ago. 1998. ISSN 0885-8950. DOI: 10.1109/59.709101.
- ANTONIO, A. B.; TORREÃO, J. R. A.; DO COUTTO FILHO, M. B. Meter placement for power system state estimation using simulated annealing. *In*: 2001 IEEE Porto Power Tech Proceedings (Cat. No.01EX502). [S.l.]: IEEE, 2001. DOI: 10.1109/ptc.2001.964910.
- ASCARI, Larah Bruning; SIMÕES COSTA, Antonio; MIRANDA, Vladimiro. Correntropy-Based Fusion Strategy for Incorporating PMU Measurements into Power System State Estimation. *In*: 2019 IEEE Milan PowerTech. [S.l.]: IEEE, jun. 2019. DOI: 10.1109/ptc.2019.8810446.
- AVILA-ROSALES, Rene *et al.* Recent experience with a hybrid SCADA/PMU on-line state estimator. *In*: 2009 IEEE Power & Energy Society General Meeting. [S.l.]: IEEE, jul. 2009. DOI: 10.1109/pes.2009.5275954.
- BALDICK, R. *et al.* Implementing nonquadratic objective functions for state estimation and bad data rejection. **IEEE Transactions on Power Systems**, v. 12, n. 1, p. 376–382, Fev. 1997. DOI: 10.1109/59.575722.
- BESSANI, Michel *et al.* Multiple households very short-term load forecasting using bayesian networks. **Electric Power Systems Research**, Elsevier BV, v. 189, p. 106733, dez. 2020. DOI: 10.1016/j.epsr.2020.106733.
- BEZ, Daniel *et al.* A Block Version of Orthogonal Rotations for Improving the Accuracy of Hybrid State Estimators. **IEEE Transactions on Power Systems**, Institute of Electrical e Electronics Engineers (IEEE), p. 1–1, 2020. DOI: 10.1109/tpwrs.2020.2991863.
- BI, T.S.; QIN, X.H.; YANG, Q.X. A novel hybrid state estimator for including synchronized phasor measurements. **Electric Power Systems Research**, Elsevier BV, v. 78, n. 8, p. 1343–1352, ago. 2008. DOI: 10.1016/j.epsr.2007.12.002.

CHAKRABARTI, S.; KYRIAKIDES, E. PMU Measurement Uncertainty Considerations in WLS State Estimation. **IEEE Transactions on Power Systems**, Institute of Electrical e Electronics Engineers (IEEE), v. 24, n. 2, p. 1062–1071, mai. 2009. DOI: 10.1109/tpwrs.2009.2016295.

CHAKRABARTI, Saikat; KYRIAKIDES, Elias *et al.* State estimation including synchronized measurements. *In*: 2009 IEEE Bucharest PowerTech. [S.l.]: IEEE, jun. 2009. DOI: 10.1109/ptc.2009.5282018.

CHEN, Chi-Tsong. **Linear System Theory and Design**. Edição: Oxford Univerty Press. 3. ed. New York: Oxford Univerty Press, 1999. P. 176. (The Oxford Serien in Electrical and Computer Engineering).

CHEN, Yanbo *et al.* Toward adaptive robust state estimation based on MCC by using the generalized Gaussian density as kernel functions. **International Journal of Electrical Power & Energy Systems**, Elsevier BV, v. 71, p. 297–304, out. 2015. DOI: 10.1016/j.ijepes.2015.03.011.

CIPRIANI, EMANOELLI; SIMÕES COSTA, ANTONIO J. A. Análise de observabilidade de medidas na estimação de estados em sistemas de potência considerando medições fasoriais sincronizadas. *In*: XVIII Congresso Brasileiro de Automática. Bonito, MS: [s.n.], 2010. P. 3436–3443.

CLANENTS, K.; KRUTNPOLZ, G.; DAVIS, P. Power System State Estimation with Measurement Deficiency: an Observability/Measurement Placement Algorithm. **IEEE Transactions on Power Apparatus and Systems**, Institute of Electrical e Electronics Engineers (IEEE), PAS-102, n. 7, p. 2012–2020, jul. 1983. DOI: 10.1109/tpas.1983.318187.

CLEMENTS, K.; KRUMPHOLZ, G.; DAVIS, P. Power System State Estimation Residual Analysis: An Algorithm Using Network Topology. **IEEE Transactions on Power Apparatus and Systems**, Institute of Electrical e Electronics Engineers (IEEE), PAS-100, n. 4, p. 1779–1787, abr. 1981. DOI: 10.1109/tpas.1981.316517.

CLEMENTS, K. A.; DAVIS, P. W. Multiple bad data and detectability and identifiability: a geometric approach. **IEEE Transactions on Power Systems**, v. 1, n. 3, p. 355–360, jul. 1985.

CUI, Yinan; KAVASSERI, Rajesh G.; BRAHMA, Sukumar M. Dynamic State Estimation Assisted Out-of-Step Detection for Generators Using Angular Difference. **IEEE Transactions on Power Delivery**, Institute of Electrical e Electronics Engineers (IEEE), v. 32, n. 3, p. 1441–1449, jun. 2017. DOI: 10.1109/tpwrdr.2016.2615594.

CUTSEM, T. V.; RIBBENS-PAVELLA, M.; MILI, L. Hypothesis Testing Identification: A New Method For Bad Data Analysis In Power System State Estimation. **IEEE**

**Transactions on Power Apparatus and Systems**, PAS-103, n. 11, p. 3239–3252, nov. 1984. ISSN 0018-9510. DOI: 10.1109/TPAS.1984.318561.

DEBS, Atif; LARSON, Robert. A Dynamic Estimator for Tracking the State of a Power System. **IEEE Transactions on Power Apparatus and Systems**, Institute of Electrical e Electronics Engineers (IEEE), PAS-89, n. 7, p. 1670–1678, set. 1970. DOI: 10.1109/tpas.1970.292822.

DO COUTTO FILHO, M. B.; GLOVER, L. D.; LEITE DA SILVA, A. M. State Estimators with Forecasting Capability. *In*: CONFERENCE; 11th, Power systems computation; 1993; Avignon; France. [S.l.]: Power Systems Computation Conference, 1993. P. 689–696.

DO COUTTO FILHO, M. B.; STACCHINI DE SOUZA, J. C. Forecasting-Aided State Estimation – Part I: Panorama. **IEEE Transactions on Power Systems**, v. 24, n. 4, p. 1667–1677, nov. 2009. ISSN 0885-8950. DOI: 10.1109/TPWRS.2009.2030295.

DO COUTTO FILHO, M. B.; STACCHINI DE SOUZA, J. C.; GUIMARAENS, M. A. Ribeiro. Enhanced Bad Data Processing by Phasor-Aided State Estimation. **IEEE Transactions on Power Systems**, v. 29, n. 5, p. 2200–2209, set. 2014. ISSN 0885-8950. DOI: 10.1109/TPWRS.2014.2304620.

DOPAZO, J. F.; KLITIN, O. A.; SASSON, A. M. State estimation for power systems: Detection and identification for gross measurements errors. *In*: Jun. PROCEEDINGS of the IEEE PICA conference. [S.l.: s.n.], 1973.

DOPAZO, J. F.; KLITIN, O. A.; VANSLYCK, L. S. State Calculation of Power Systems from Line Flow Measurements, Part II. **IEEE Transactions on Power Apparatus and Systems**, PAS-91, n. 1, p. 145–151, jan. 1972. DOI: 10.1109/TPAS.1972.293324.

DUBEY, Anamika; CHAKRABARTI, Saikat; SHARMA, Ankush *et al.* Optimal utilisation of PMU measurements in power system hybrid state estimators. **IET Generation, Transmission & Distribution**, Institution of Engineering e Technology (IET), v. 13, n. 21, p. 4978–4986, nov. 2019. DOI: 10.1049/iet-gtd.2019.0010.

DUBEY, Anamika; CHAKRABARTI, Saikat; TERZIJA, Vladimir. SCADA and PMU Measurement Based Methods for Robust Hybrid State Estimation. **Electric Power Components and Systems**, Informa UK Limited, v. 47, n. 9-10, p. 849–860, jun. 2019. DOI: 10.1080/15325008.2019.1627606.

ERDOGMUS, Deniz; PRINCIPE, Jose C. An erro-entropy minimization algorithm for supervised training of nolinear adaptative systems. **IEEE Transactions on Signal Processing**, v. 50, n. 7, p. 1780–1786, jul. 2002.

ERDOGMUS, Deniz; PRINCIPE, Jose C. Entropy minimization algorithm for multilayer perceptrons. *In*: NEURAL Networks, 2001. Proceedings. IJCNN '01. International Joint

Conference on. Washington, DC, USA: IEEE, jul. 2001. v. 4, p. 3003–3008. DOI: 10.1109/IJCNN.2001.938856.

FALCAO, D. M.; COOKE, P. A.; BRAMELLER, A. Power System Tracking State Estimation and Bad Data Processing. **IEEE Transactions on Power Apparatus and Systems**, PAS-101, n. 2, p. 325–333, Fev. 1982. DOI: 10.1109/TPAS.1982.317110.

FAN, Rui *et al.* Dynamic state estimation-based protection of power transformers. *In*: 2015 IEEE Power & Energy Society General Meeting. [S.l.]: IEEE, jul. 2015. DOI: 10.1109/pesgm.2015.7286463.

FREITAS, Victor; SIMOES COSTA, Antonio. Integrated State topology estimation based on a priori topology information. *In*: 2015 IEEE Eindhoven PowerTech. [S.l.]: IEEE, jun. 2015. DOI: 10.1109/ptc.2015.7232440.

FREITAS, Victor; SIMÕES COSTA, Antonio; MIRANDA, Vladimiro. Orthogonal method for solving maximum correntropy-based power system state estimation. **IET Generation, Transmission & Distribution**, Institution of Engineering e Technology (IET), v. 14, n. 10, p. 1930–1941, fev. 2020. DOI: 10.1049/iet-gtd.2019.1179.

GENTLEMAN, W. M. Least squares computations by Givens transformations without square roots. **Journal of the Institut of Mathematical Applications**, v. 12, p. 329–336, 1973.

GLAVIC, M.; CUTSEM, T. Van. Investigating state reconstruction from scarce synchronized phasor measurements. *In*: 2011 IEEE Trondheim PowerTech. [S.l.]: IEEE, jun. 2011. DOI: 10.1109/ptc.2011.6019163.

GOLUB, Gene H; VAN LOAN, Charles F. **Matrix computations**. [S.l.]: JHU press, 2012. v. 3.

GONÇALVES, Rodolfo Mussiato. **Processamento de erros grosseiros associado a métodos de fusão de estimativas em sistemas de potência monitorados por medidas convencionais e fasoriais**. 2016. Diss. (Mestrado) – Universidade Federal de Santa Catarina, Centro Tecnológico.

GOUVÊA, J. P. S.; SIMÕES COSTA, A. Estimador de Estados ortogonal com restrições de igualdade. *In*: SBA, 3. SBA Controle & Automação. Formaleza: SBA, Out., Nov. e Dez 1998. v. 9, p. 141–148.

GUIMARAENS, MARCIO ANDRE RIBEIRO. **SUPRESSÃO DE ERROS GROSSEIROS DE MEDIÇÃO ATRAVÉS DA COOPERAÇÃO ENTRE ESTIMADORES DE ESTADO INDEPENDENTES**. 2015. Tese (Doutorado) – Universidade Federal Fluminense.

HAMMARLING, S. A note on modifications to the Givens plane rotations. **Journal of the Institut of Mathematical Applications**, v. 13, p. 215–218, 1974.

HANDSCHIN, E. *et al.* Bad data analysis for power system state estimation. **IEEE Transactions on Power Systems**, PAS-94, n. 2, p. 329–337, mar. 1975.

HOLTEN, L. *et al.* Comparison of different methods for state estimation. **IEEE Transactions on Power Systems**, v. 3, n. 4, p. 1798–1806, nov. 1988. ISSN 0885-8950. DOI: 10.1109/59.192998.

HUG, Gabriela; GIAMPAPA, Joseph Andrew. Vulnerability Assessment of AC State Estimation With Respect to False Data Injection Cyber-Attacks. **IEEE Transactions on Smart Grid**, Institute of Electrical e Electronics Engineers (IEEE), v. 3, n. 3, p. 1362–1370, set. 2012. DOI: 10.1109/tsg.2012.2195338.

HURTGEN, Michaël; MAUN, Jean-Claude. Advantages of power system state estimation using Phasor Measurement Units. *In*: 16TH PSCC. Glasgow, Scotland: [s.n.], jul. 2008.

KAPUR, J.N. **Measures of Information and Their Applications**. Edição: Wiley. [S.l.]: Wiley, 1994.

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

KHALILI, Azam; RASTEGARNIA, Amir; SANEI, Saeid. Robust frequency estimation in three-phase power systems using correntropy-based adaptive filter. **IET Science, Measurement & Technology**, Institution of Engineering e Technology (IET), v. 9, n. 8, p. 928–935, nov. 2015. DOI: 10.1049/iet-smt.2015.0018.

KOGLIN, H.-J. *et al.* Bad data detection and identification. **International Journal of Electrical Power & Energy Systems**, v. 12, n. 2, p. 94–103, 1990. ISSN 0142-0615. DOI: [https://doi.org/10.1016/0142-0615\(90\)90005-V](https://doi.org/10.1016/0142-0615(90)90005-V).

KRSTULOVIC, J.; MIRANDA, V. Denoising auto-associative measurement screening and repairing. *In*: INTELLIGENT System Application to Power Systems (ISAP), 2015 18th International Conference on. [S.l.: s.n.], Set 2015. P. 1–6. DOI: 10.1109/ISAP.2015.7325548.

KRSTULOVIC, J.; MIRANDA, V. *et al.* Towards an auto-associative topology States estimator. **IEEE Transactions on Power Systems**, v. 28, n. 3, p. 3311–3318, Agosto 2013.

KUGA, Hélio Koiti. **Análise numérica preliminar dos métodos de estimação seqüencial**. Edição: INPE. São José dos Campos: INPE, 1982.



- LARSON, R.; TINNEY, W.; PESCHON, J. State Estimation in Power Systems Part I: Theory and Feasibility. **IEEE Transactions on Power Apparatus and Systems**, PAS-89, n. 3, p. 345–352, mar. 1970.
- LEITES, RENAN AUGUSTO DA COSTA. **Processamento de Medidas Fasoriais de Tensão e de Corrente na Estimação de Estados em Sistemas de Potência**. 2010. Diss. (Mestrado) – Universidade Federal de Santa Catarina.
- LIU, W.; POKHAREL, P. P.; PRINCIPE, J. C. Correntropy: Properties and Applications in Non-Gaussian Signal Processing. **IEEE Transactions on Signal Processing**, v. 55, n. 11, p. 5286–5298, nov. 2007. ISSN 1053-587X. DOI: 10.1109/TSP.2007.896065.
- LIU, Weifeng; POKHAREL, P. P.; PRINCIPE, J. C. Correntropy: A Localized Similarity Measure. *In*: THE 2006 IEEE International Joint Conference on Neural Network Proceedings. [S.l.: s.n.], jul. 2006. P. 4919–4924. DOI: 10.1109/IJCNN.2006.247192.
- LIU, Weifeng; POKHAREL, P. P.; PRINCIPE, Jose C. Error entropy, correntropy and M-estimation. *In*: MACHINE Learning for Signal Processing, 2006. Proceedings of the 2006 16th IEEE Signal Processing Society Workshop on. Arlington, VA, USA: IEEE, set. 2006. P. 179–184. DOI: 10.1109/MLSP.2006.275544.
- LIU, Yu; MELIOPOULOS, A. P. Sakis *et al.* Dynamic State Estimation Based Protection on Series Compensated Transmission Lines. **IEEE Transactions on Power Delivery**, Institute of Electrical e Electronics Engineers (IEEE), v. 32, n. 5, p. 2199–2209, out. 2017. DOI: 10.1109/tpwrd.2016.2633410.
- LOURENÇO, E. M. **Análise de Observabilidade e Identificação de Erros de Topologia na Estimação de Estados Generalizada**. 2001. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Elétrica. Universidade Federal de Santa Catarina.
- MAGALHAES CARVALHO, Leonel de; LEITE DA SILVA, Armando Martins; MIRANDA, Vladimiro. Security-Constrained Optimal Power Flow via Cross-Entropy Method. **IEEE Transactions on Power Systems**, Institute of Electrical e Electronics Engineers (IEEE), v. 33, n. 6, p. 6621–6629, nov. 2018. DOI: 10.1109/tpwrs.2018.2847766.
- MELIOPOULOS, A. P. Sakis *et al.* Dynamic State Estimation-Based Protection: Status and Promise. **IEEE Transactions on Power Delivery**, Institute of Electrical e Electronics Engineers (IEEE), v. 32, n. 1, p. 320–330, fev. 2017. DOI: 10.1109/tpwrd.2016.2613411.
- MENEGHETTI, R. *et al.* Information Theoretic Generalized State Estimation in power systems. **Electric Power Systems Research**, Elsevier BV, v. 182, n. 106251, p. 1–13, mai. 2020. DOI: 10.1016/j.epsr.2020.106251.

- MERRILL, Hyde M.; SCHWEPPE, F. C. Bad data suppression in power system static state estimation. **IEEE Transactions on Apparatus and Systems**, PAS-90, n. 6, p. 2718–2725, nov. 1971.
- MILI, L. *et al.* Robust State estimation based on projection statistic [of power systems]. **IEEE Transactions on Power Systems**, v. 11, n. 2, p. 1118–1127, mai. 1996.
- MIRANDA, Vladimiro. **Gross errors and missing signals (GEMS): new concepts in power system state estimation**. Porto, fev. 2013.
- MIRANDA, Vladimiro. **Informação, entropia e sistemas treináveis**. Florianópolis, Fevereiro 2015.
- MIRANDA, Vladimiro; KRSTULOVIC, Jakov *et al.* Reconstructing Missing Data in State Estimation With Autoconders. **IEEE Transactions on Power Systems**, v. 27, n. 2, p. 604–611, mai. 2012. DOI: 10.1109/TPWRS.2011.2174810.
- MIRANDA, Vladimiro; SANTOS, A.; PEREIRA, Jorge. State Estimation based on Correntropy: a proof of concept. **Power Systems, IEEE Transactions on**, v. 24, n. 4, p. 1888–1889, nov. 2009. DOI: 10.1109/TPWRS.2009.2030117.
- MIRANDA, Vladimiro; TEIXEIRA, Luis; PEREIRA, Jorge. Estimating Breaker Status with Electrical State Images and Convolutional Neural Networks. *In*: 2019 20th International Conference on Intelligent System Application to Power Systems (ISAP). [S.l.]: IEEE, dez. 2019. DOI: 10.1109/isap48318.2019.9065958.
- MODIR, Hasan; SCHLUETER, Robert. A Dynamic State Estimator for Dynamic Security Assessment. **IEEE Transactions on Power Apparatus and Systems**, Institute of Electrical e Electronics Engineers (IEEE), PAS-100, n. 11, p. 4644–4652, nov. 1981. DOI: 10.1109/tpas.1981.316806.
- MONTICELLI, A. **State Estimation in Electric Power Systems: A Generalized Approach**. Edição: SPRINGER VERLAG PUBLISHING. New York: Springer Science & Business Media, 1999. P. 394. DOI: 10.1007/978-1-4615-4999-4.
- MONTICELLI, A.; GARCIA, A. Reliable Bad Data Processing for Real-Time State Estimation. **IEEE Transactions on Power Apparatus and Systems**, PAS-102, n. 5, p. 1126–1139, mai. 1983. ISSN 0018-9510. DOI: 10.1109/TPAS.1983.318053.
- MONTICELLI, A.; MURARI, C. A. F.; WU, F. F. A Hybrid State Estimator: Solving Normal Equations By Orthogonal Transformations. **IEEE Transactions on Power Apparatus and Systems**, PAS-104, n. 12, p. 3460–3468, dez. 1985. ISSN 0018-9510. DOI: 10.1109/TPAS.1985.318896.

MONTICELLI, A.; WU, F. F.; YEN, M. Multiple Bad Data Identification for State Estimation by Combinatorial Optimization. **IEEE Transactions on Power Delivery**, v. 1, n. 3, p. 361–369, jul. 1986. ISSN 0885-8977. DOI: 10.1109/TPWRD.1986.4308016.

NOCEDAL, Jorge; WRIGHT, Stephen. **Numerical Optimization**. Edição: Springer. 2. ed. Nova Iorque: Springer, 2006. v. XXII, p. 664. (Springer Series in Operations Research and Financial Engineering).

PARZEN, Emanuel. On Estimation of a Probability Density Function and Mode. **Ann. Math. Statist.**, The Institute of Mathematical Statistics, v. 33, n. 3, p. 1065–1076, set. 1962. DOI: 10.1214/aoms/1177704472.

PESTEH, Shabnam; MOAYYED, Hamed; MIRANDA, Vladimiro. Favorable properties of Interior Point Method and Generalized Correntropy in power system State Estimation. **Electric Power Systems Research**, Elsevier BV, v. 178, p. 106035, jan. 2020. DOI: 10.1016/j.epsr.2019.106035.

PESTEH, Shabnam; MOAYYED, Hamed; MIRANDA, Vladimiro *et al.* A new interior point solver with generalized correntropy for multiple gross error suppression in state estimation. **Electric Power Systems Research**, Elsevier BV, v. 176, p. 105937, nov. 2019. DOI: 10.1016/j.epsr.2019.105937.

PICALLO, M. *et al.* A Two-Step Distribution System State Estimator with Grid Constraints and Mixed Measurements. *In: 2018 Power Systems Computation Conference (PSCC)*. [S.l.: s.n.], jun. 2018. P. 1–7. DOI: 10.23919/PSCC.2018.8442586.

PIRES, Robson C.; SIMÕES COSTA, A.; MILI, L. Iteratively reweighted least-squares state estimation through Givens rotations. **IEEE Transactions on Power Systems**, v. 14, n. 4, p. 1899–1507, nov. 1999.

PRINCIPE, Jose C. **Information-Theoretic Learning**. [S.l.], 2013.

PRINCIPE, Jose C.; DONGXIN, Xu. An introduction to information theoretic learning. *In: IEEE (Ed.). Neural Networks, 1999. IJCNN '99. International Joint Conference on*. Washington, DC, USA: IEEE, jul. 1999. v. 3, p. 1783–1787. DOI: 10.1109/IJCNN.1999.832648.

RÉNYI, A. On Measures of Entropy and Information. *In: PROCEEDINGS of the 4th Berkeley Symposium on Mathematics, Statistics and Probability*. [S.l.: s.n.], 1960. v. 1, p. 547–561.

ROUHANI, Alireza; ABUR, Ali. Linear Phasor Estimator Assisted Dynamic State Estimation. **IEEE Transactions on Smart Grid**, Institute of Electrical e Electronics Engineers (IEEE), v. 9, n. 1, p. 211–219, jan. 2018. DOI: 10.1109/tsg.2016.2548244.

- ROUSSEAU, P.; CUTSEM, Th. Van; DY LIACCO, T.E. Whither dynamic state estimation. **International Journal of Electrical Power & Energy Systems**, Elsevier BV, v. 12, n. 2, p. 104–116, abr. 1990. DOI: 10.1016/0142-0615(90)90006-w.
- SANTAMARIA, I.; POKHAREL, P. P.; PRINCIPE, J. C. Generalized correlation function: definition, properties, and application to blind equalization. **IEEE Transactions on Signal Processing**, v. 54, n. 6, p. 2187–2197, jun. 2006. ISSN 1053-587X. DOI: 10.1109/TSP.2006.872524.
- SCHWEPPE, Fred C. Power System Static-State Estimation, Part III: Implementation. **IEEE Transactions on Apparatus and Systems**, PAS-89, n. 1, p. 130–135, jan. 1970.
- SCHWEPPE, Fred C.; ROM, Douglas B. Power System Static-State Estimation, Part II: Approximate model. **IEEE Transactions on Apparatus and Systems**, PAS-89, n. 1, p. 125–130, jan. 1970.
- SCHWEPPE, Fred C.; WILDES, J. Power System Static-State Estimation, Part I: Extrac model. **IEEE Transactions on Apparatus and Systems**, PAS-89, n. 1, p. 120–125, jan. 1970.
- SHANNON, C. E. A mathematical theory of communication. **The Bell System Technical Journal**, v. 27, p. 379–423, jul. 1948.
- SIMÕES COSTA, A.; ALBUQUERQUE, A. A two-stage Orthogonal estimator to incorporate phasor measurements into power system real-time Modeling. *In*: POWER Systems Computation Conference (17th PSCC). Stockholm: [s.n.], jun. 2011. P. 1–7.
- SIMÕES COSTA, A.; ALBUQUERQUE, A.; BEZ, D. An estimation fusion method for including phasor measurements into power system real-time modeling. **IEEE Transactions on Power Systems**, v. 28, n. 2, p. 1910–1920, mai. 2013. ISSN 0885-8950. DOI: 10.1109/TPWRS.2012.2232315.
- SIMÕES COSTA, A.; GOUVÊA, J. P. S. A constrained orthogonal state estimator for external system modeling. **Electrical Power & Energy Systems**, v. 22, 555562, nov. 2000.
- SIMÕES COSTA, A.; LOURENÇO, M. E.; VIEIRA, F. Topology Error Identification for Orthogonal Estimators Considering A Priori State Information. *In*: PROC. Power Systems Computation Conference (15th PSCC). Liege, Belgian: [s.n.], ago. 2005. .26, p. 1–6.
- SIMÕES COSTA, A.; PIAZZA, T.S.; MANDEL, A. Qualitative methods to solve qualitative problems in power system state estimation. **IEEE Transactions on Power Systems**, Institute of Electrical e Electronics Engineers (IEEE), v. 5, n. 3, p. 941–949, 1990. DOI: 10.1109/59.65924.

SIMÕES COSTA, A.; QUINTANA, V. H. A Robust Numerical Technique for Power System State Estimation. **IEEE Transactions on Power Apparatus and Systems**, PAS-100, n. 2, p. 691–698, fev. 1981.

SIMÕES COSTA, A.; QUINTANA, V. H. An Orthogonal Row Processing Algorithm for Power System Sequential State Estimation. **IEEE Transactions on Power Apparatus and Systems**, PAS-100, n. 8, p. 3791–3800, ago. 1981. ISSN 0018-9510. DOI: 10.1109/TPAS.1981.317022.

SIMÕES COSTA, A.; ROLIM, J. G.; AITCHISON, P. W. Iterative bad-data suppression applied to state estimators based on the augmented matrix method. **Electric Power Systems Research**, v. 20, p. 205–213, jun. 1991.

SLUTSKER, I.W. *et al.* Implementation of phasor measurements in state estimator at Sevillana de Electricidad. *In*: PROCEEDINGS of Power Industry Computer Applications Conference. [S.l.]: IEEE, 1995. DOI: 10.1109/pica.1995.515269.

SRINIVASAN, K.; ROBICHAUD, Y. A Dynamic Estimator for Complex Bus Voltage Determination. **IEEE Transactions on Power Apparatus and Systems**, Institute of Electrical e Electronics Engineers (IEEE), PAS-93, n. 5, p. 1581–1588, set. 1974. DOI: 10.1109/tpas.1974.293889.

SWERLING, P. Modern state estimation methods from the viewpoint of the method of least squares. **IEEE Transactions on Automatic Control**, v. 16, n. 6, p. 707–719, dez. 1971. ISSN 0018-9286. DOI: 10.1109/TAC.1971.1099815.

TAHA, Ahmad F. *et al.* Risk Mitigation for Dynamic State Estimation Against Cyber Attacks and Unknown Inputs. **IEEE Transactions on Smart Grid**, Institute of Electrical e Electronics Engineers (IEEE), v. 9, n. 2, p. 886–899, mar. 2018. DOI: 10.1109/tsg.2016.2570546.

TAVARES, Bruna *et al.* Merging conventional and phasor measurements in state estimation: A multi-criteria perspective. *In*: 2017 19th International Conference on Intelligent System Application to Power Systems (ISAP). [S.l.]: IEEE, set. 2017. DOI: 10.1109/isap.2017.8071423.

TONG, Chi Hay; FURGALE, Paul; BARFOOT, Timothy D. Gaussian Process Gauss-Newton: Non-Parametric State Estimation. *In*: 2012 Ninth Conference on Computer and Robot Vision. [S.l.]: IEEE, mai. 2012. DOI: 10.1109/crv.2012.35.

TOYOSHIMA, D. *et al.* Observability and measurement redundancy analysis on three-phase state estimation. *In*: 2012 IEEE Power and Energy Society General Meeting. [S.l.: s.n.], jul. 2012. P. 1–8. DOI: 10.1109/PESGM.2012.6345507.

VAN CUTSEM, T.; HORWARD, J. L.; RIBBENS-PAVELLA, M. A Two-Level Static State Estimator for Electric Power Systems. **IEEE Transactions on Power Apparatus and**

**Systems**, PAS-100, n. 8, p. 3722–3732, ago. 1981. ISSN 0018-9510. DOI: 10.1109/TPAS.1981.317015.

VEMPATI, N.; SILVA, C. *et al.* Topology estimation. *In: IEEE PES Power Engineering Society General Meeting*. [S.l.: s.n.], jun. 2005. v. 1, p. 806–810. DOI: 10.1109/PES.2005.1489505.

VEMPATI, N.; SLUTSKER, I. W.; TINNEY, W. F. Enhancements to Givens rotations for power system state estimation. **IEEE Transactions on Power Systems**, v. 6, n. 2, p. 842–849, mai. 1991.

VOSGERAU, F. *et al.* Power system state and topology coestimation. *In: VIII IREP - Symposium on Bulk Power System Dynamics and Control*. Busios, Brasil: [s.n.], Agosto 2010. P. 1–6.

WANG, J. W.; QUINTANA, V. H. A Decoupled Orthogonal Row Processing Algorithm for Power System State Estimation. **IEEE Transactions on Power Apparatus and Systems**, PAS-103, n. 8, p. 2337–2344, ago. 1984. DOI: 10.1109/TPAS.1984.318550.

WANG, Yue; INFIELD, David. Supervisory control and data acquisition data-based non-linear state estimation technique for wind turbine gearbox condition monitoring. **IET Renewable Power Generation**, Institution of Engineering e Technology (IET), v. 7, n. 4, p. 350–358, jul. 2013. DOI: 10.1049/iet-rpg.2012.0215.

WASHINGTON, University of. **Power Systems Test Case Archive, University of Washington, Electrical Engineering**. [S.l.: s.n.], set. 2015. [Online]. Available: <http://www.ee.washington.edu/research/pstca/>.

WU, Felix F. Power system state estimation: a survey. **International Journal of Electrical Power & Energy Systems**, v. 12, n. 2, p. 80–87, 1990. ISSN 0142-0615. DOI: [https://doi.org/10.1016/0142-0615\(90\)90003-T](https://doi.org/10.1016/0142-0615(90)90003-T).

WU, W. *et al.* Robust state estimation method based on maximum exponential square. **IET Generation, Transmission and Distribution**, v. 5, p. 1165–1172, mai. 2011. DOI: 10.1049/iet-gtd.2011.0100.

XU, Dongxin *et al.* A novel measure for independent component analysis (ICA). *In: ACOUSTICS, Speech and Signal Processing*, 1998. Proceedings of the 1998 IEEE International Conference on. Seattle, WA: IEEE, Mai. 1998. v. 2, p. 1161–1164. DOI: 10.1109/ICASSP.1998.675476.

YANG, Xuan; ZHANG, Xiao-Ping; ZHOU, Suyang. Coordinated algorithms for distributed state estimation with synchronized phasor measurements. **Applied Energy**, v. 96, p. 253–260, 2012. Smart Grids. ISSN 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2011.11.010>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0306261911007070>.

ZHANG, Q. *et al.* Impact of PMU Measurement Buffer Length on State Estimation and its Optimization. **IEEE Transactions on Power Systems**, v. 28, n. 2, p. 1657–1665, mai. 2013. ISSN 0885-8950. DOI: 10.1109/TPWRS.2012.2215890.

ZHAO, J.; MILI, L. Power System Robust Decentralized Dynamic State Estimation Based on Multiple Hypothesis Testing. **IEEE Transactions on Power Systems**, v. 33, n. 4, p. 4553–4562, jul. 2018. ISSN 0885-8950. DOI: 10.1109/TPWRS.2017.2785344.

ZHAO, Junbo; MILI, Lamine. A Framework for Robust Hybrid State Estimation With Unknown Measurement Noise Statistics. **IEEE Transactions on Industrial Informatics**, Institute of Electrical e Electronics Engineers (IEEE), v. 14, n. 5, p. 1866–1875, mai. 2018. DOI: 10.1109/tii.2017.2764800.

ZHAO, Junbo; MILI, Lamine. Vulnerability of the Largest Normalized Residual Statistical Test to Leverage Points. **IEEE Transactions on Power Systems**, Institute of Electrical e Electronics Engineers (IEEE), v. 33, n. 4, p. 4643–4646, jul. 2018. DOI: 10.1109/tpwrs.2018.2831453.

ZHAO, Junbo; NETTO, Marcos; MILI, Lamine. A Robust Iterated Extended Kalman Filter for Power System Dynamic State Estimation. **IEEE Transactions on Power Systems**, Institute of Electrical e Electronics Engineers (IEEE), v. 32, n. 4, p. 3205–3216, jul. 2017. DOI: 10.1109/tpwrs.2016.2628344.

ZHAO, Junbo; QI, Junjian *et al.* Power System Dynamic State Estimation: Motivations, Definitions, Methodologies, and Future Work. **IEEE Transactions on Power Systems**, Institute of Electrical e Electronics Engineers (IEEE), v. 34, n. 4, p. 3188–3198, jul. 2019. DOI: 10.1109/tpwrs.2019.2894769.

ZHAO, Junbo; WANG, Shaobu *et al.* A Robust State Estimation Framework Considering Measurement Correlations and Imperfect Synchronization. **IEEE Transactions on Power Systems**, Institute of Electrical e Electronics Engineers (IEEE), v. 33, n. 4, p. 4604–4613, jul. 2018. DOI: 10.1109/tpwrs.2018.2790390.

ZHAO, Liang; ABUR, A. Multi area state estimation using synchronized phasor measurements. **IEEE Transactions on Power Systems**, v. 20, n. 2, p. 611–617, mai. 2005. ISSN 0885-8950. DOI: 10.1109/TPWRS.2005.846209.

ZHENG, W. *et al.* Distributed Robust Bilinear State Estimation for Power Systems with Nonlinear Measurements. **IEEE Transactions on Power Systems**, v. 32, n. 1, p. 499–509, jan. 2017. ISSN 0885-8950. DOI: 10.1109/TPWRS.2016.2555793.

ZHONG, Shan; ABUR, A. Combined state estimation and measurement calibration. **IEEE Transactions on Power Systems**, v. 20, n. 1, p. 458–465, fev. 2005. ISSN 0885-8950. DOI: 10.1109/TPWRS.2004.841237.

ZHOU, M. *et al.* An Alternative for Including Phasor Measurements in State Estimators. **IEEE Transactions on Power Systems**, v. 21, n. 4, p. 1930–1937, nov. 2006. ISSN 0885-8950. DOI: 10.1109/TPWRS.2006.881112.

ZHU, Jun; ABUR, Ali. Bad Data Identification When Using Phasor Measurements. *In*: 2007 IEEE Lausanne Power Tech. [S.l.]: IEEE, jul. 2007. DOI: 10.1109/pct.2007.4538567.

ZHUANG, Fulin; BALASUBRAMANIAN, R. Bad Data Suppression in Power System State Estimation with a Variable Quadratic-Constant Criterion. **Power Apparatus and Systems, IEEE Transactions on**, PAS-104, n. 4, p. 857–863, jul. 1985. DOI: 10.1109/TPAS.1985.319086.



## APÊNDICE A – DADOS DO SISTEMA-TESTE DE 3 BARRAS

Tabela A.1 – Dados das Barras do Sistema-Teste de 3 Barras

Barra	Tipo	V	$\delta$	Pd	Qd	Pg	Qg	bsh
1	2	1,050	0,0	0,0	0,0	0,0	0,0	0,0
2	1	1,000	0,0	30,0	12,0	0,0	0,0	0,0
3	1	1,000	0,0	120,0	25,0	0,0	0,0	0,0

Tabela A.2 – Dados da Linhas do Sistema-Teste de 3 Barras

Barras		Resistência	Reatância	BshLin
De	Para	(p.u.)	(p.u.)	(p.u.)
1	2	0,0	0,10	0,04
1	3	0,015	0,20	0,04
2	3	0,015	0,20	0,04

- Plano de Medição

O plano de medição empregado à este sistema consiste em:

- Quantidade de medidas de magnitude de tensão: 3;
- Quantidade de medidas de fluxo de potência ativa: 4;
- Quantidade de medidas de fluxo de potência reativa: 4;
- Quantidade de medidas de injeção de potência ativa: 3;
- Quantidade de medidas de injeção de potência reativa: 3;
- Quantidade de variáveis de estado calculadas: 5;
- Redundância: 3,40.