

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE ELETRICIDADE

**ALOCAÇÃO ÓTIMA DE MEDIDORES PARA
A ESTIMAÇÃO DE ESTADO EM REDES
ELÉTRICAS INTELIGENTES**

ANTONIO ADOLPHO MARTINS RAPOSO

São Luís – MA, Brasil

2016

ANTONIO ADOLPHO MARTINS RAPOSO

**ALOCAÇÃO ÓTIMA DE MEDIDORES PARA A ESTIMAÇÃO DE ESTADO
EM REDES ELÉTRICAS INTELIGENTES**

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão como parte dos requisitos para obtenção do título de mestre em Engenharia Elétrica.

Orientadores: Prof. Anselmo Barbosa Rodrigues, D. Sc.
Prof^a. Maria da Guia da Silva, Ph. D.

São Luís – MA, Brasil

2016

Raposo, Antonio Adolpho Martins.

Alocação ótima de medidores para a estimação de estado em redes elétricas inteligentes / Antonio Adolpho Martins Raposo. – São Luís, 2016.

147 f.

Impresso por computador (fotocópia).

Orientador: Anselmo Barbosa Rodrigues.

Coorientadora: Maria da Guia da Silva.

Dissertação (Mestrado) – Universidade Federal do Maranhão, Programa de Pós-Graduação em Engenharia de Eletricidade, 2016.

1. Redes de distribuição. 2. Estimação de estado. 3. Simulação Monte Carlo. 4. Variáveis aleatórias correlacionadas. 5. Distribuição normal bivariada. I. Título.

CDU 621.311.1

**ALOCAÇÃO ÓTIMA DE MEDIDORES PARA A ESTIMAÇÃO DE ESTADO
EM REDES ELÉTRICAS INTELIGENTES**

ANTONIO ADOLPHO MARTINS RAPOSO

Dissertação aprovada em 26 de fevereiro de 2016.

BANCA EXAMINADORA

Prof. Anselmo Barbosa Rodrigues, D. Sc.

(Orientador – UFMA)

Profa. Maria da Guia da Silva, Ph. D.

(Orientadora – UFMA)

Prof. Julio Cesar Stacchini de Souza, D. Sc.

(Examinador – UFF)

Prof. Denisson Queiroz Oliveira, D. Sc.

(Examinador – UFMA)

À minha mãe pelo apoio e confiança.
À minha irmã pelo companheirismo.
Àqueles que apoiaram, incentivaram e
compreenderam o meu envolvimento nesse
trabalho, e com quem tenho convivido
diariamente.

AGRADECIMENTOS

À Deus, que me capacitou e me sustentou física, mental e espiritualmente durante todo esse período em que estive envolvido nesse projeto.

À minha mãe pelos ensinamentos, conselhos e incentivo.

À minha irmã pela ajuda e disponibilidade.

À minha orientadora Prof^a. Dr^a. Maria da Guia da Silva pelas contribuições, críticas e sugestões, pelo compartilhar de sua experiência e de seus conhecimentos, e principalmente pela amizade.

Ao meu orientador Prof. Dr. Anselmo Barbosa Rodrigues por orientar de forma clara e sucinta cada etapa desta dissertação e por compartilhar de sua vasta experiência e de seus conhecimentos em sistemas de distribuição.

Aos professores do PPGEE da UFMA pelas contribuições.

Aos amigos que fiz durante o mestrado.

À CAPES, pelo apoio financeiro.

E as pessoas que contribuíram direta ou indiretamente para que mais um sonho fosse realizado na minha vida.

RESUMO

Para planejar e operar adequadamente uma Rede Elétrica Inteligente (REI), muitas novas considerações técnicas, no âmbito de sistemas de distribuição, devem ser apreciadas, por exemplo: a estabilidade – devido a instalação de Geração Distribuída (GD), o despacho de carga e geração, o gerenciamento de dispositivos de armazenamento de energia e a avaliação do impacto da conexão de veículos elétricos na rede de distribuição. O principal pré-requisito para muitas destas novas funções do centro de controle do sistema de distribuição é a determinação do estado da rede elétrica (módulo e a fase das tensões nodais) em tempo real a partir de dispositivos de medição nela instalados. Em centros de controle de sistemas de transmissão esta tarefa é realizada por ferramentas de estimação de estado. Desta forma, a Estimação de Estado em Redes de Distribuição (EERD) é um dos alicerces para a implantação de uma REI. A presença de um número reduzido de medições pode tornar a rede elétrica não-observável no âmbito da EERD. Isto é, as variáveis de estado (módulo e fase das tensões nodais em todas as barras) não podem ser determinadas a partir de um conjunto de medições por um estimador de estado. Devido a isto, geralmente adiciona-se um grande número de pseudo-medições ao plano de medição existente para assegurar a observabilidade e viabilizar a EERD. Um problema com esta estratégia é que a precisão do estado estimado é comprometida devido ao fato de que os erros associados com as pseudo-medições são consideravelmente maiores do que aqueles referentes às medições reais. Consequentemente é necessário alocar medidores (magnitude das tensões, fluxos de potência ativa e reativa, magnitude das correntes, etc.) para garantir a precisão do EERD. O problema de alocação de medidores para a estimação de estado em redes de transmissão é, geralmente, realizado com o objetivo de assegurar a observabilidade. Por outro lado, a alocação de medidores para EERD é realizada visando minimizar índices probabilísticos associados com os erros entre os vetores de estado estimado e verdadeiro. Um componente importante do método usado para resolver o problema de alocação de medidores é a técnica probabilística usada para estimar a função objetivo. Devido à natureza não-linear do problema de EERD, a melhor opção tem sido utilizar a Simulação Monte Carlo (SMC). Uma desvantagem da SMC para estimar a função objetivo do problema de alocação é o seu alto custo computacional devido a necessidade de resolver um problema de estimação de estado não-linear para cada

elemento da amostra. O principal objetivo desta dissertação é propor técnicas probabilísticas para melhorar o desempenho computacional de metodologias existentes para alocação de medidores sem sacrificar a precisão do estado estimado. Este compromisso foi estabelecido usando-se duas estratégias. Na primeira, um modelo linearizado é usado para estimar o estado e a SMC para determinar os riscos da função objetivo. Na segunda, uma fórmula analítica fechada é usada para determinar os riscos com base no modelo linearizado. Além disso, as versões melhoradas dos algoritmos de alocação propostos nesta dissertação consideram o efeito da correlação entre as medições. As metodologias de alocação propostas foram testadas no sistema de distribuição britânico de 95 barras. Os resultados dos testes demonstraram que a introdução das estratégias propostas em um algoritmo de alocação de medidores reduziu significativamente o seu custo computacional. Além disso, pode-se observar que ocorreram melhorias na precisão em alguns casos, pois as estimativas dos riscos fornecidas pela SMC não são precisas com pequenas amostras.

Palavras-chave: Redes de Distribuição, Estimação de Estado, Simulação Monte Carlo, Variáveis Aleatórias Correlacionadas, Distribuição Normal Bivariada, Alocação de Medidores.

ABSTRACT

To plan and operate properly a Smart Grid (SG), many new technical considerations in the context of distribution systems, must be considered, for example: stability (due to installation of Distributed Generation (DG), the load and generation dispatch, management of energy storage devices and the assessment of the impact of electric vehicle connection on the distribution system. The main prerequisite for many of these new functions in the distribution system control center is to determine the electrical network state (magnitude and angle of nodal voltages) in real time from measurement devices installed in it. In the transmission system control centers, this task is performed by the state estimation tool. Thus, the Distribution System State Estimation (DSSE) is one of the cornerstones for the implementation of a SG. The presence of a small number of measurements can make the grid unobservable in the context of the DSSE. That is, the state variables (magnitude and angle of the node voltages of all bus) can not be determined from a set of measurements by a state estimator. Due to this, it is usually added a large number of pseudo measurements to the existing measurement plan to ensure observability and to enable the DSSE. A drawback with this strategy is that the accuracy of the estimated state is compromised due to the fact that the errors associated with the pseudo measurements are considerably higher than those relating to real measurements. Consequently, it is necessary to allocate meters (voltage magnitude, active and reactive power flows, current magnitudes, etc.) to guarantee the accuracy of the DSEE. The meter placement problem for the state estimation in the transmission networks is usually carried out with the objective of assuring the observability. On the other hand, the meter placement for the EERD aims to minimize probabilistic index associated with the errors between the true and estimated state vectors. An important component of the method used to solve the meters placement problem is a probabilistic technique used to estimate the objective function. Due to the nonlinear nature of DSSE problem, the best option has been to use the Monte Carlo Simulation (MCS). A disadvantage of the MCS to estimate the objective function of the allocation problem is its high computational cost due to the need to solve a nonlinear state estimation problem for each sample element. The main objective of this dissertation is to propose a probabilistic techniques to improve the computational performance of existing methodologies for meter placement without reducing the accuracy of the estimated

state. This compromise has been established using two strategies. In the first one, a linear model is used to estimate the state and the MCS is applied to determine the risks of the objective function. In the second one, a closed analytical formula is used to determine the risks based on the linearized model. Furthermore, the improved versions of the meter placement algorithms proposed in this dissertation consider the effect of the correlation among the measurements. The proposed meter placement algorithms were tested in the British distribution system of 95 bus. The tests results demonstrate that the introduction of the proposed strategies in a meter placement algorithm significantly reduced its computational cost. Moreover, it can be observed that there were improvements in accuracy in some cases, because the risk estimates provided by MCS are not accurate with small samples.

Keywords: Distribution Networks, State Estimation, Monte Carlo Simulation, Correlated Random Variables, Bivariate Normal Distribution, Meter Placement.

LISTA DE FIGURAS

Figura 1.1: Localização da rede de distribuição na infraestrutura do sistema de energia elétrica (Adaptado de Karady e Holbert (2013)).....	2
Figura 1.2: Rede primária do tipo radial simples.....	3
Figura 1.3: Diagrama unifilar de uma rede radial com recurso.	4
Figura 1.4: Rede primária do tipo primária seletiva.	5
Figura 1.5: Diagrama unifilar de uma rede secundária do tipo radial simples.....	6
Figura 1.6: Rede de distribuição secundária do tipo banco de transformadores.....	7
Figura 1.7: Rede de distribuição do tipo secundário seletivo.	7
Figura 1.8: Diagrama unifilar de uma rede secundária malhada (Adaptado de Short (2014)). ...	9
Figura 1.9: Diagrama unifilar de uma rede secundária de barra única (Adaptado de Short (2014)).....	10
Figura 1.10: Componentes de uma AMI (Adaptado de Thomas e McDonald (2015)).	17
Figura 1.11: Integração através da REI (Adaptado de Smart Grid & Smart Storage (2015))....	22
Figura 2.1: O Estimador de estado na arquitetura da rede de distribuição.....	31
Figura 2.2: Método de Gauss-Newton para estimação de estado.	38
Figura 2.3: Modelo π da linha.	39
Figura 3.1: Diagrama de dispersão segundo o grau de correlação entre as variáveis.	47
Figura 3.2: Curva de carga do sistema teste UKGDS.....	50
Figura 3.3: Diagrama de dispersão entre a demanda de potência ativa e reativa.....	51
Figura 3.4: PDF de uma distribuição normal com média 30 e desvio padrão 15.	52
Figura 3.5: PDFs de uma distribuição normal bivariada.	54
Figura 3.6: Diagrama de dispersão e as curvas de nível da PDF bivariada, ilustrada na Figura 3.5, segundo o grau de correlação entre as variáveis.	54
Figura 3.7: Método de Gauss-Newton para estimação de estado com medições correlacionadas.	62

Figura 4.1: Sistema com dois componentes em paralelo.....	67
Figura 4.2: Técnica de SMC aplicada ao sistema com dois componentes independentes em paralelo.....	68
Figura 4.3: Fluxograma do método SPV (Adaptado de Singh, Pal e Vinter (2009)).....	73
Figura 5.1: Fluxograma para a inversão parcial de G^{-1}	77
Figura 5.2: Fluxograma do método SMCLIN.....	79
Figura 5.3: Visualização gráfica do índice de probabilidade P_i^V	83
Figura 5.4: Visualização gráfica do índice de probabilidade P_i^θ	84
Figura 5.5: Fluxograma do método ANA2PDF.....	86
Figura 6.1: Diagrama unifilar do STD_UKGDS95 (Adaptado de Singh, Pal e Vinter (2009)).	89
Figura 6.2: Magnitudes e fases das tensões no sistema STD_UKGDS95.....	90
Figura 6.3: Histogramas para a barra #95 (módulo e fase da tensão) do sistema UKGDS para correlação entre medições de potência ativa e reativa $\rho = 0,8$	93
Figura 6.4: Gráfico de probabilidade normal para θ_{95} e V_{95} para correlação entre medições de potência ativa e reativa $\rho = 0,8$	94
Figura 6.5: Histogramas para a barra #95 (módulo e fase da tensão) do sistema UKGDS para correlação entre medições de potência ativa e reativa $\rho = 0,95$	95
Figura 6.6: Gráfico de probabilidade normal para θ_{95} e V_{95} para correlação entre medições de potência ativa e reativa $\rho = 0,95$	96
Figura 6.7: (a) PDF da distribuição bivariada de θ_{95} e V_{95} . (b) Diagrama de dispersão e as curvas de nível da PDF bivariada de θ_{95} e V_{95} para correlação entre medições de potência ativa e reativa $\rho = 0,8$	98
Figura 6.8: (a) PDF da distribuição bivariada de θ_{95} e V_{95} . (b) Diagrama de dispersão e as curvas de nível da PDF bivariada de θ_{95} e V_{95} para correlação entre medições de potência ativa e reativa $\rho = 0,95$	99
Figura 6.9: Alocações dos medidores obtidas pelos métodos SPV, SMCLIN e ANA2PDF para o Caso #1-C.....	102
Figura 6.10: Erros relativos na magnitude estimada da tensão obtidos pelo SPV. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.....	103

Figura 6.11: Erros relativos na fase estimada da tensão obtidos pelo SPV. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.	104
Figura 6.12: Comparação entre P_i e R_i obtidos pelo SPV para o Caso #1-C. (a) sem a presença de medidor (b) com a alocação de 1 medidor.	105
Figura 6.13: Erros relativos na magnitude estimada da tensão calculados com a SMCLIN para o Caso #1-C. (a) sem a presença de medidores (b) com a alocação de 1 medidor no sistema..	106
Figura 6.14: Erros relativos na fase estimada da tensão calculados pela SMCLIN para o Caso #1-C. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.	107
Figura 6.15: Comparação entre P_i e R_i calculados pela SMCLIN para o Caso #1-C. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.....	108
Figura 6.16: Alocação dos medidores segundo os métodos SPV e SMCLIN para o Caso #1-D.	109
Figura 6.17: Alocação dos medidores obtida pelo método ANA2PDF para o Caso #1-D.	110
Figura 6.18: Comparação entre o tempo computacional dos métodos de alocação para o Caso #1.....	112
Figura 6.19: Alocação dos medidores obtida pelo método SPV para o Caso #2-C.....	114
Figura 6.20: Alocação dos medidores obtida pelo método SMCLIN para o Caso #2-C.	115
Figura 6.21: Alocação dos medidores obtida pelo método ANA2PDF para o Caso #2-C.	116
Figura 6.22: Alocação dos medidores obtidas através métodos SPV, SMCLIN e ANA2PDF para o Caso #2-D.....	117
Figura 6.23: Erros relativos na magnitude estimada da tensão calculados pelo método SPV para o Caso #2-D. (a) sem a presença de medidores (b) com a alocação de 1 medidor no sistema.	118
Figura 6.24: Erros relativos na fase estimada da tensão calculados pelo método SPV para o Caso #2-D. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.....	119
Figura 6.25: Comparação entre P_i e R_i calculados pelo método SPV para o Caso #2-D. (a) sem a presença de medidor (b) com a instalação de um medidor.....	120
Figura 6.26: Erros relativos na magnitude estimada da tensão calculados pelo método SMCLIN para o Caso #2-D. (a) sem a presença de medidores (b) com a alocação de 1 medidor.....	121
Figura 6.27: Erros relativos na fase estimada da tensão obtidos com a SMCLIN para o Caso #2-D. (a) sem a presença de medidor (b) com a alocação de 1 medidor.	122

Figura 6.28: Comparação entre P_i e R_i obtidos pelo método SMCLIN para o Caso #2-D. (a) sem a presença de medidores (b) com a alocação de 1 medidor.	123
Figura 6.29: Comparação entre o tempo computacional dos métodos de alocação para o Caso #2.....	125
Figura 6.30: Alocação de medidor segundo o método SPV para o Caso #3-C.	127
Figura 6.31: Erros relativos (a) na magnitude estimada da tensão e (b) na fase estimada da tensão para a primeira amostra de 100 elementos da SMC.....	128
Figura 6.32: Erros relativos (a) na magnitude estimada da tensão e (b) na fase estimada da tensão para a segunda amostra de 100 elementos da SMC.	129
Figura 6.33: Comparação entre P_i e R_i (a) para a primeira rodada distinta da apresentada nas Tabelas 6.8 e 6.9, e (b) para a segunda rodada distinta da apresentada nas Tabelas 6.8 e 6.9..	130
Figura 6.34: Alocação de medidor segundo o método SPV para o Caso #3-D.	131
Figura 6.35: Alocação de medidor segundo os métodos SMCLIN e ANA2PDF para o Caso #3-D.....	132
Figura 6.36: Comparação entre o tempo computacional dos métodos de alocação para o Caso #3.....	134
Figura 6.37: Comparação entre P_i e R_i - Caso #3-C com uma amostra de 10000 para a SMC.	136
Figura 6.38: Erros relativos na magnitude estimada da tensão (a) e na fase estimada da tensão (b) para o caso Caso #1-D do método SPV com apenas um medidor de fluxo de potência instalado no ramo 2/4.....	137

LISTA DE TABELAS

Tabela 6.1: Principais dados do STD_UKGDS95.	88
Tabela 6.2: Estatísticas fornecidas pela função <i>kstest</i> para $\rho = 0,8$	92
Tabela 6.3: Estatísticas fornecidas pela função <i>kstest</i> para $\rho = 0,95$	94
Tabela 6.4: Valores mínimo e máximo dos índices P_i e R_i para o Caso #1.	101
Tabela 6.5: Comparação entre o número de medidores alocados para o Caso #1.	101
Tabela 6.6: Comparação entre o tempo computacional dos métodos de alocação para o Caso #1.	111
Tabela 6.7: Valores mínimo e máximo dos índices P_i e R_i para o Caso #2.	113
Tabela 6.8: Comparação entre o número de medidores alocados para o Caso #2.	113
Tabela 6.9: Comparação entre o tempo computacional dos métodos de alocação para o Caso #2.	124
Tabela 6.10: Valores mínimo e máximo dos índices P_i e R_i para o Caso #3.	125
Tabela 6.11: Comparação entre o número de medidores alocados para o Caso #3.	126
Tabela 6.12: Comparação entre o tempo computacional dos métodos de alocação para o Caso #3.	133
Tabela 6.13: Resultados referentes à primeira análise sobre o impacto do tamanho da amostra no método SPV.	136
Tabela 6.14: Resultados referentes à segunda análise sobre o impacto do tamanho da amostra no método SPV.	138

LISTA DE ABREVIATURAS

AD – Automação da Distribuição

ADSL – *Asymmetric Digital Subscriber Line*

AMI – *Advanced Metering Infrastructure*

AMR – *Automatic Meter Reading*

AMS – *Asset Management System*

CIS – *Customer Information System*

DMS – *Distribution Management System*

EERD – Estimação de Estado em Redes de Distribuição

GD – Geração Distribuída

GIS – *Geographical Information System*

MDMS – *Meter Data Management System*

MGN – Método iterativo de Gauss-Newton

MQP – Mínimos Quadrados Ponderados

MVAP – Mínimos Valores Absolutos Ponderados

OMS – *Outage Management System*

OVV – Otimização Volt-Var

PDF – *Probability Density Function*

PMU – *Phasor Measurement Unit*

REI – Rede Elétrica Inteligente

RNA – Rede Neural Artificial

SCADA – *Supervisor Control and Data Acquisition*

SMC – Simulação Monte Carlo

TIC – Tecnologias de Informação e Comunicação

SUMÁRIO

1 INTRODUÇÃO	1
1.1 Redes de Distribuição de Energia Elétrica	1
1.1.1 Rede de distribuição primária	2
1.1.2 Rede de distribuição secundária	5
1.2 Automação de Redes de Distribuição Convencionais	10
1.2.1 Subsistemas de um centro de controle de distribuição.....	11
1.2.2 Comentários finais.....	18
1.3 Redes Elétricas Inteligentes	19
1.4 Estimação de Estado em Redes de Distribuição	23
1.5 Alocação de Medidores para Estimação de Estado em Redes de Distribuição	25
1.6 Motivação da Pesquisa	26
1.7 Objetivos da Dissertação	27
1.8 Estrutura da Dissertação.....	28
2 ESTIMAÇÃO DE ESTADO VIA MÉTODO DE GAUSS-NEWTON	30
2.1 Introdução	30
2.2 Classificação dos Estimadores de Estado	32
2.3 Método de Gauss-Newton com Medições Descorrelacionadas	33
2.4 Algoritmo de Estimação de Estado via Método de Gauss-Newton.....	36
2.5 Funções de Medição e Estrutura da Matriz Jacobiana H	38
2.5.1 Funções de medição $h(x)$	39
2.5.2 Estrutura da matriz Jacobiana H	40
3 ESTIMAÇÃO DE ESTADO COM MEDIÇÕES CORRELACIONADAS.....	43
3.1 Introdução	43
3.2 Conceitos Básicos sobre Estatística Multivariada	44

3.2.1 Principais definições.....	44
3.2.2 Estimação de parâmetros em distribuições multivariadas	48
3.2.3 Distribuições de probabilidades multivariadas	51
3.2.4 Transformação linear de vetores aleatórios	55
3.3 Métodos para Descorrelacionar Variáveis Aleatórias Gaussianas	56
3.3.1 Método de decomposição de Cholesky para descorrelacionar variáveis aleatórias gaussianas	57
3.3.2 Método de decomposição em autovalores e autovetores para descorrelacionar variáveis aleatórias gaussianas	58
3.4 Método de Gauss-Newton para Estimação de Estado com Medições Correlacionadas	59
4 ALGORITMO DE ALOCAÇÃO DE MEDIDORES EM REDES DE DISTRIBUIÇÃO BASEADO NO ÍNDICE DE PROBABILIDADE BIVARIADO	63
4.1 Introdução	63
4.2 Método de Simulação Monte Carlo.....	63
4.2.1 SMC não-sequencial.....	67
4.3 Método SPV para Alocação de Medidor	68
5 PROPOSTA DE ALOCAÇÃO DE MEDIDORES EM REDES DE DISTRIBUIÇÃO	74
5.1 Introdução	74
5.2 Alocação de Medidores via SMC Linear	74
5.3 Alocação de Medidores via Método Analítico.....	79
6 RESULTADOS DOS TESTES.....	87
6.1 Introdução	87
6.2 Descrição do Sistema Teste.....	88
6.3 Dados das Simulações	89
6.4 Testes Estatísticos para Validar as Hipóteses Usadas no Cálculo de P_i	90
6.4.1 Teste de aderência de Kolmogorov-Smirnov	91

6.4.2 Testes de hipóteses para o coeficiente de correlação populacional	96
6.5 Análise dos Métodos SPV, SMCLIN e ANA2PDF na Alocação de Medidores em Redes de Distribuição	99
6.5.1 Resultados do Caso #1	101
6.5.2 Resultados do Caso #2	112
6.5.3 Resultados do Caso #3	125
6.6 Impacto do Tamanho da Amostra da SMC no Desempenho do Método SPV	134
7 CONCLUSÕES.....	139
7.1 Introdução	139
7.2 Principais Contribuições	139
7.3 Aplicações Práticas	140
7.4 Sugestões para Trabalhos Futuros.....	142
REFERÊNCIAS	144

INTRODUÇÃO

1.1 Redes de Distribuição de Energia Elétrica

Historicamente, os sistemas elétricos de potência são divididos em três zonas funcionais, denominadas de subsistemas de geração, transmissão e distribuição.

O subsistema de distribuição, ou apenas sistema de distribuição, é o responsável por transportar energia elétrica aos consumidores de baixa e média tensão. Subestações de distribuição reduzem a tensão de subtransmissão – níveis típicos de tensão de subtransmissão estão entre 34,5 kV e 230 kV (Brown 2009) – a níveis mais baixos, de tal modo que possam ser transportadas com segurança em áreas urbanas. A localização do sistema de distribuição na infraestrutura do sistema de energia elétrica é mostrada na Figura 1.1.

A distribuição de energia elétrica pode ser realizada através de linhas aéreas, isoladas ou não, ou através de linhas subterrâneas. Linhas aéreas possuem baixo custo de instalação quando comparadas às linhas subterrâneas. Porém estão mais expostas às intempéries (Brown 2009) e a manutenção é mais cara devido à necessidade de podas de árvores, limpeza de isoladores, etc. Podem ser citadas como outras vantagens das linhas subterrâneas: o uso em áreas de pequena extensão geográfica e de grande densidade de carga (Short 2014), e para fins *estéticos* como é o caso de cidades turísticas.

O sistema de distribuição é formado por dois subsistemas: a rede de distribuição primária e a rede de distribuição secundária. Nas próximas subseções serão apresentadas as principais características das redes de distribuição primárias e secundárias.

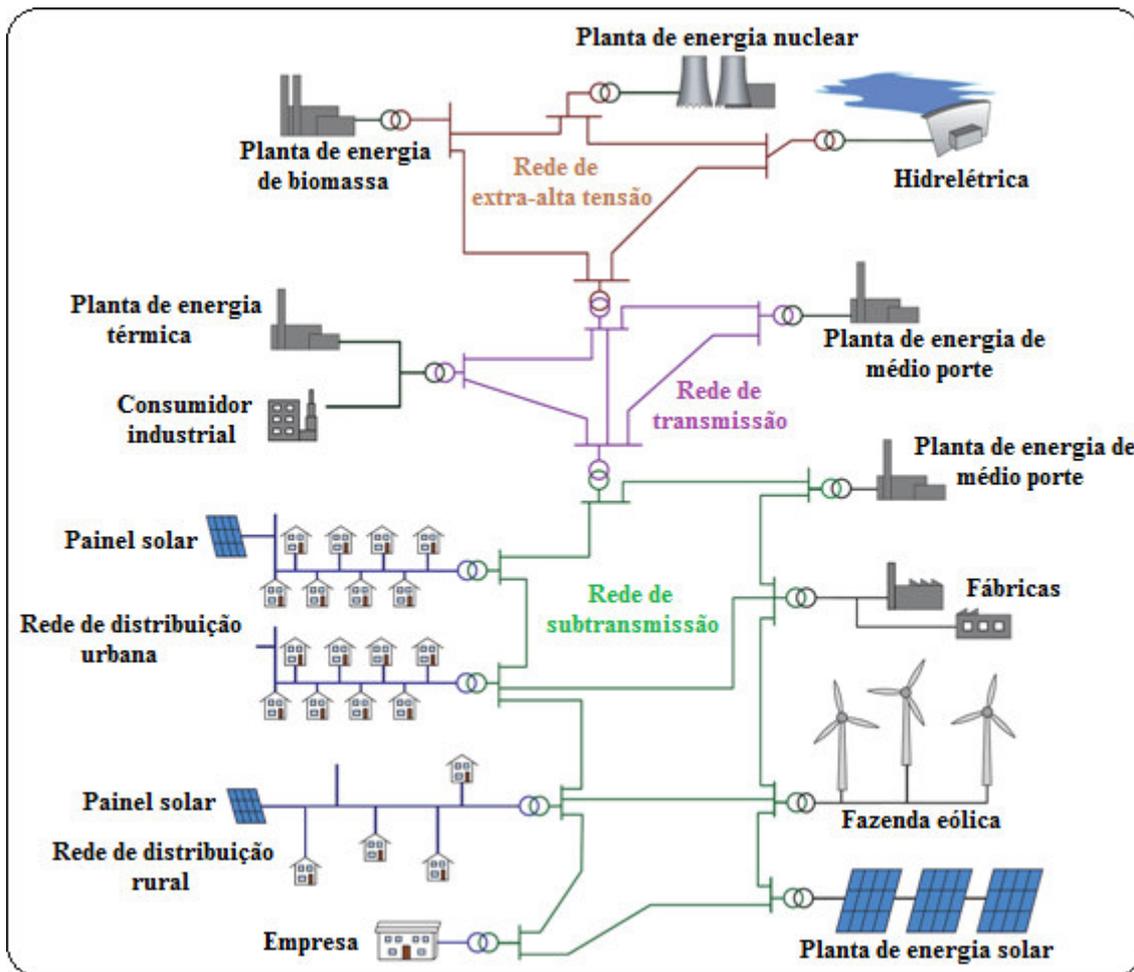


Figura 1.1: Localização da rede de distribuição na infraestrutura do sistema de energia elétrica (Adaptado de Karady e Holbert (2013)).

1.1.1 Rede de distribuição primária

A rede de distribuição primária é a parte do sistema de energia elétrica que está localizada entre a subestação de distribuição e os transformadores de distribuição. A rede de distribuição primária é composta por circuitos denominados de alimentadores. Um alimentador possui várias ramificações derivadas do seu tronco principal denominadas laterais. As seções do tronco principal de um alimentador são geralmente trifásicas enquanto as laterais podem ser trifásicas, bifásicas ou monofásicas. As laterais monofásicas são principalmente usadas em áreas com baixa densidade de carga, tais como as zonas rurais.

Nos sistemas de transmissão a rede é sempre interligada, visando aumentar a confiabilidade e reduzir efeitos oriundos de faltas. O mesmo não ocorre com os sistemas de distribuição, que podem ser operados em várias configurações.

O modo de operação radial é o tipo mais simples de operação da rede primária e também o mais comum. Neste modo de operação cada consumidor está conectado diretamente à fonte de energia através de um único caminho (Short 2014). As redes radiais possuem diversas vantagens sobre as redes malhadas, tais como:

- i) Fácil proteção de correntes de falta;
- ii) Baixas correntes de falta ao longo da maior parte do alimentador;
- iii) Fácil controle de tensão;
- iv) Fácil controle e previsão dos fluxos de potência;
- v) Baixo custo.

Os principais tipos de redes de distribuição primárias são:

- i) Radial simples;
- ii) Radial com recurso;
- iii) Primária seletiva;

Na configuração radial simples os consumidores são conectados a um único alimentador. Na ocorrência de uma falta nos ramais da rede primária, o fornecimento de energia aos consumidores a jusante da falta é interrompido até que a falta seja reparada. Uma falta no alimentador interrompe o fornecimento a todos os consumidores daquele alimentador até que seja reparada (Brown 2009). O diagrama de uma rede primária do tipo radial simples é ilustrado na Figura 1.2.

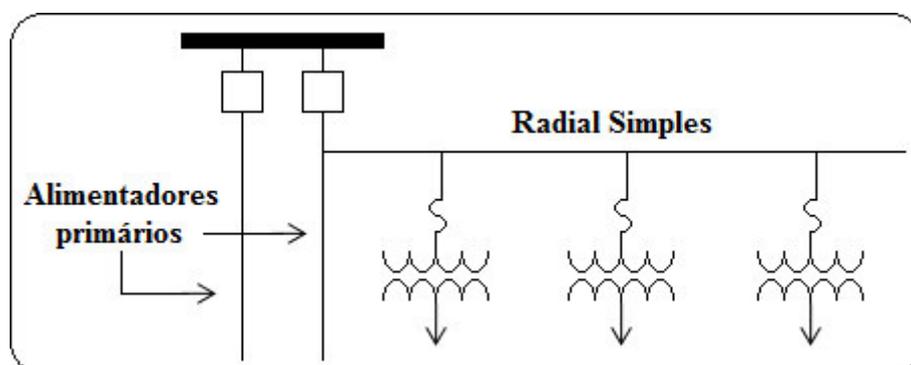


Figura 1.2: Rede primária do tipo radial simples.

Para aumentar a confiabilidade da rede de distribuição, em geral as concessionárias de energia conectam alimentadores em locais específicos através de chaves normalmente abertas. Essas conexões permitem que na ocorrência de uma falta os consumidores a jusante da falta sejam conectados a um ponto de fornecimento alternativo para reduzir os seus tempos de restauração. É importante enfatizar que esta transferência de carga é realizada preservando-se a radialidade da rede. Esse tipo de configuração é chamado de radial com recurso. Em geral, as chaves normalmente abertas (NA) são manualmente operadas, mas algumas concessionárias usam chaves automáticas para realizar a transferência de carga automaticamente (Short 2014). A Figura 1.3 mostra o diagrama unifilar de uma rede radial com recurso.

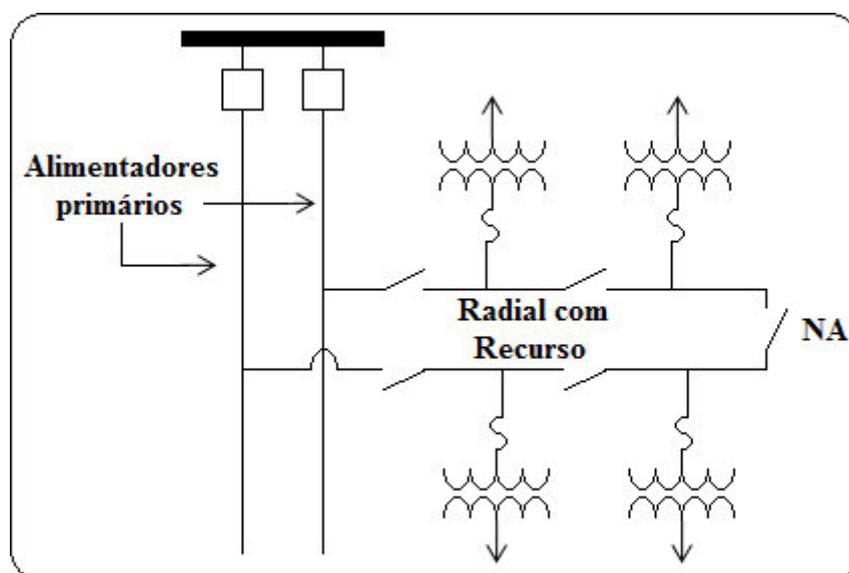


Figura 1.3: Diagrama unifilar de uma rede radial com recurso.

Algumas cargas, tais como os hospitais, necessitam de uma maior confiabilidade e por isso não podem estar conectadas a apenas um alimentador. Nesta situação é usada uma configuração denominada primário seletivo, na qual a carga é conectada a dois alimentadores por meio de duas chaves: uma normalmente aberta e uma normalmente fechada (NF). Na ocorrência de uma falta que retire de operação um dos alimentadores, a carga pode ser chaveada para outro alimentador energizado. É importante notar que em ambos os casos a radialidade da rede é preservada. A configuração primária seletiva é ilustrada na Figura 1.4.

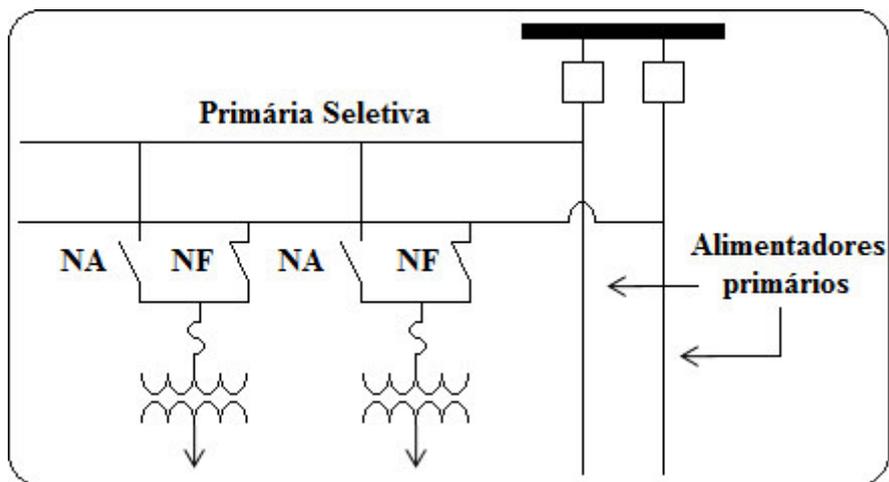


Figura 1.4: Rede primária do tipo primária seletiva.

1.1.2 Rede de distribuição secundária

A rede de distribuição secundária é a parte da rede de distribuição que está entre o sistema primário e a propriedade do consumidor. A rede de distribuição secundária é composta pelos seguintes equipamentos:

- i) Transformadores abaixadores de distribuição (por exemplo, 13.8 kV - 380V/220V);
- ii) Circuitos secundários;
- iii) Ramais de serviço para os consumidores;
- iv) Medidores para faturar o consumo de energia.

Os principais tipos de redes de distribuição secundárias são:

- i) Exclusivo;
- ii) Radial;
- iii) Banco de transformadores;
- iv) Malhado (“Grid”);
- v) Barra única (“Spot”);
- vi) Secundário Seletivo.

O tipo exclusivo fornece energia elétrica para cada consumidor com um transformador e conexões secundárias individualizadas. Este tipo de rede secundária é raramente utilizado e é mais adequado para consumidores do tipo rural e comercial.

O tipo de rede secundária mais utilizada para atender consumidores residenciais e comerciais é o radial simples. Este tipo de rede atende diversos consumidores a partir de troncos secundários que se originam em um único transformador abaixador. A Figura 1.5 mostra o diagrama unifilar de uma rede secundária do tipo radial simples.

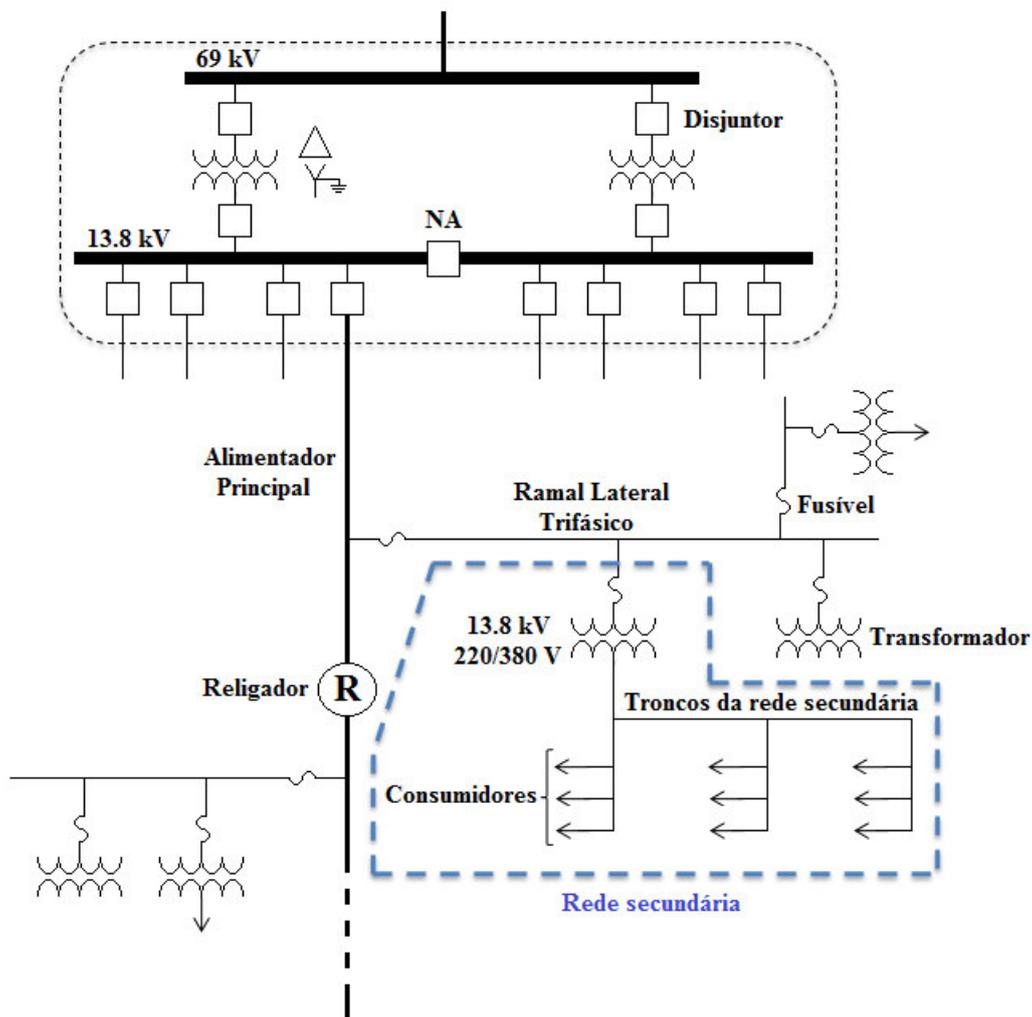


Figura 1.5: Diagrama unifilar de uma rede secundária do tipo radial simples.

O sistema de distribuição secundário de banco de transformadores consiste da interconexão do lado secundário de dois ou mais transformadores que são supridos pelo mesmo alimentador primário. Este tipo de rede é usado em áreas residenciais e

comerciais nas quais o espaçamento entre os transformadores é pequeno. Um sistema secundário do tipo banco de transformadores é mostrado na Figura 1.6.

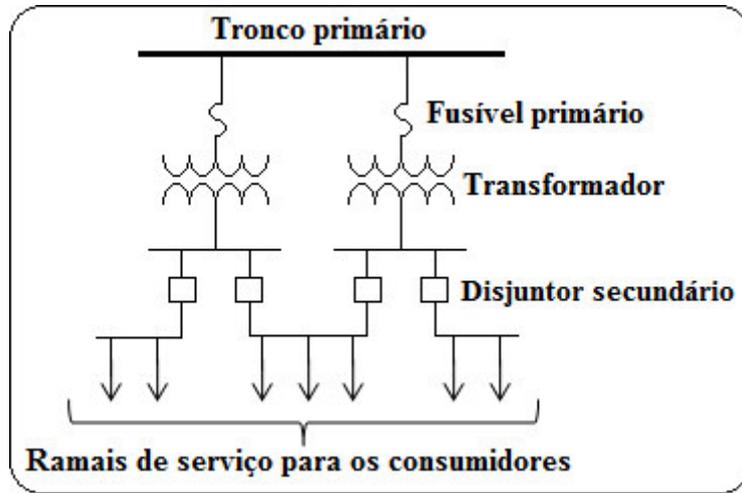


Figura 1.6: Rede de distribuição secundária do tipo banco de transformadores.

Nas redes de distribuição com secundário seletivo há chaves NA no secundário dos transformadores para realizar transferências de carga para outros transformadores abaixadores após a ocorrência de uma falha no transformador principal. Desta forma, é importante assegurar que os transformadores são adequadamente dimensionados para suportar a sua carga nativa e a carga que foi transferida. A Figura 1.7 ilustra a configuração secundário seletivo.

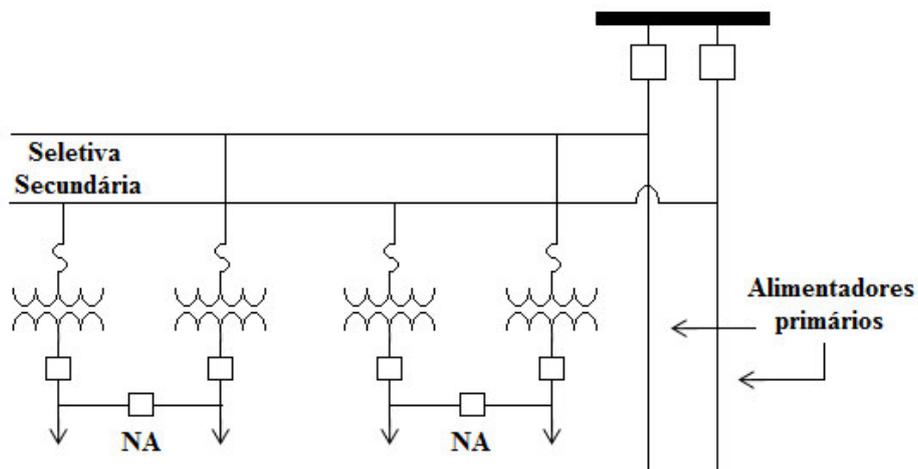


Figura 1.7: Rede de distribuição do tipo secundário seletivo.

Alguns tipos de cargas exigem níveis de confiabilidade mais elevados do que aqueles fornecidos por redes do tipo radial, banco de transformadores e secundário seletivo. Uma deficiência comum em todos estes tipos de redes secundárias citados até o momento é que uma falha na rede primária causa uma interrupção em todos os consumidores servidos pelos transformadores abaixadores. Uma alternativa para minimizar este problema é usar uma rede secundária malhada. Nesta configuração a rede secundária é suprida por vários alimentadores em pontos de conexão distintos. O emaranhado dos alimentadores primários impede que haja interrupção do fornecimento de energia para transformadores pertencentes a um mesmo alimentador. Conseqüentemente, a continuidade do fornecimento de energia é assegurada mesmo quando um alimentador está falhado, pois os consumidores do alimentador indisponível podem ser supridos pelos outros alimentadores sem violações em restrições operativas (subtensões/sobretensões e/ou sobrecargas). Adicionalmente, esta configuração deve ser dotada de dispositivos de proteção com capacidade para identificar condições de reversão de fluxo para evitar que as faltas sejam alimentadas pela rede secundária após a atuação da proteção da rede primária. Um sistema secundário malhado é mostrado na Figura 1.8.

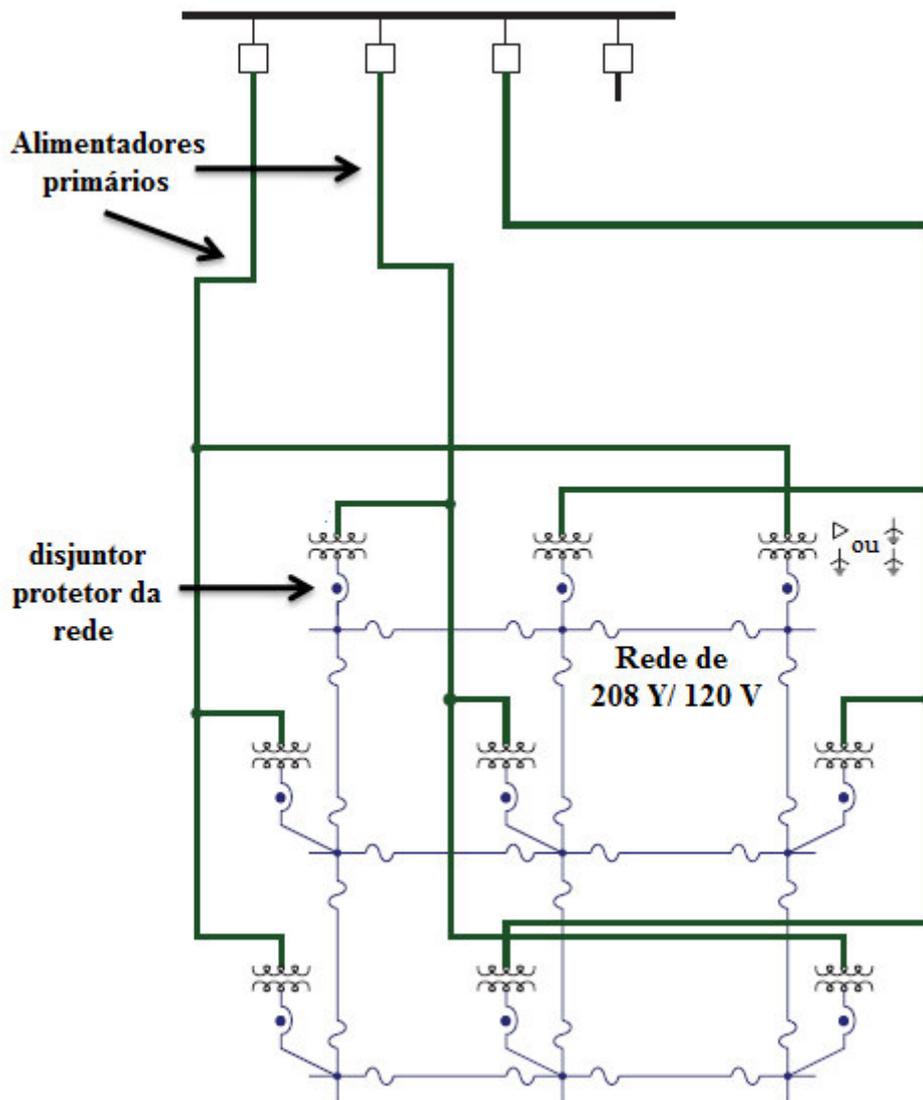


Figura 1.8: Diagrama unifilar de uma rede secundária malhada (Adaptado de Short (2014)).

Uma outra alternativa para contornar os problemas de confiabilidade das redes secundárias radial, banco de transformadores e secundário seletivo é a utilização da rede de barra única (“spot network”). As redes de barra única são compostas por dois ou mais alimentadores conectados em paralelo para suprir energia para um barramento comum a partir do qual os ramais de serviço são derivados. A Figura 1.9 mostra o diagrama unifilar de uma rede de barra única. A partir desta figura, pode-se observar que os disjuntores da rede de barra única devem identificar reversões de fluxo para eliminar faltas assim como nas redes secundárias malhadas.

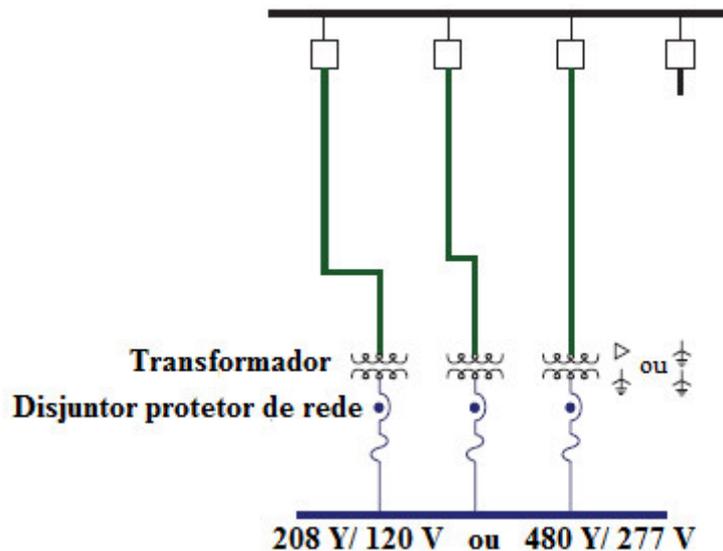


Figura 1.9: Diagrama unifilar de uma rede secundária de barra única (Adaptado de Short (2014)).

1.2 Automação de Redes de Distribuição Convencionais

A Automação da Distribuição (AD) é um conjunto de tecnologias que permite à concessionária monitorar, coordenar e operar os componentes da rede de distribuição em tempo real a partir de locais remotos. O conceito de AD está diretamente ligado a automatização das operações de todo o sistema de distribuição, tais como: o sistema SCADA (“Supervisor Control and Data Acquisition”) com seus requisitos de comunicação para atuar com ou sem a intervenção de um operador; equipamentos de proteção para o sistema de gerenciamento de falhas; sistemas de informação do consumidor e gerenciamento de ativos. Desta forma, a AD contempla os seguintes componentes do sistema de distribuição (Thomas e McDonald, 2015):

i) Automação do consumidor: tem como base medidores inteligentes instalados nas dependências dos consumidores. Os medidores de leitura automática (“AMR – Automatic Meter Reading”) têm uma importância fundamental nesse processo. O AMR armazena as medições e, periodicamente, as envia ao Sistema de Gerenciamento da Rede de Distribuição (“DMS – Distribution Management System”). O objetivo é substituir o funcionário da concessionária responsável pela leitura do consumo por um AMR em cada residência, comércio ou indústria. Implementar a automação do consumidor tem um custo relativamente alto, pois é necessário uma infraestrutura de

comunicação bastante robusta para prover o envio de dados dos consumidores à concessionária. Além disso, um único alimentador de uma dada subestação da concessionária possui centenas/milhares de pontos de carga. Visto que o objetivo é automatizar o consumidor, faz-se necessário instalar um AMR em cada ponto de carga. Para consumidores comerciais ou industriais a relação custo benefício de implementação da automação é muito mais vantajosa do que para consumidores residenciais, pois a demanda dos consumidores residenciais é muito pequena com relação a dos consumidores comerciais e industriais.

ii) Automação dos alimentadores: é geralmente caracterizada pela instalação de dispositivos seccionadores ao lado dos alimentadores. Quando ocorre um problema em um alimentador, dados são enviados à subestação ou ao centro de controle da distribuição. Uma vez identificado o problema, um técnico pode ativar remotamente um dispositivo seccionador para isolar o segmento com defeito e transferir o restante do segmento para outro alimentador, caso haja chaves de interligação disponíveis. Outros objetivos operacionais podem ser alcançados através da automação dos alimentadores, por exemplo: melhorar o perfil de tensão a partir do remanejamento de carga e a redução de perdas através do chaveamento de bancos de capacitores.

iii) Automação da subestação: tem ganhado incentivo em todo o mundo devido aos benefícios oferecidos por novos equipamentos e sistemas. A automação da subestação envolve a implantação de funções operacionais associadas com: SCADA, processamento de alarmes, controle integrado volt-var, etc. O objetivo é otimizar a gestão dos ativos e melhorar a operação, a manutenção e a confiabilidade com a mínima intervenção humana.

1.2.1 Subsistemas de um centro de controle de distribuição

Um centro de controle de distribuição pode ser dividido em subsistemas com a finalidade de dividir tarefas e aumentar a eficiência. Os principais subsistemas de um centro de controle de distribuição são: DMS, GIS, OMS, CIS, AMI e o AMS. Uma descrição resumida de cada um destes subsistemas é apresentada a seguir.

1) DMS:

Do ponto de vista de gerenciamento de uma rede de distribuição, a AD fornece toda a infraestrutura de comunicação e equipamentos para atuação do DMS. O DMS surgiu como simples extensão do SCADA dos sistemas de transmissão. É um sistema de apoio à tomada de decisão que ajuda os operadores no centro de controle a monitorar e controlar a rede de distribuição de forma eficaz, melhorando a segurança, confiabilidade, gestão de ativos e qualidade do serviço. Estes benefícios estão diretamente ligados às ferramentas de tomada de decisão e de controle do DMS. Geralmente, essas ferramentas podem ser divididas em três categorias: avaliação, otimização e restauração (Vaahedi 2014).

i) A avaliação consiste de um conjunto de funções que fornece a topologia da rede, o estado do sistema e a previsão de carga, como por exemplo:

- **Modelador da rede de distribuição:** é uma função que fornece um modelo detalhado e atualizado da rede de distribuição contendo informação de conectividade e parâmetros dos componentes para estudos elétricos. Os parâmetros elétricos (resistências, reatâncias e capacitâncias shunt) podem ser fornecidos em coordenadas de fase (a, b e c) ou componentes de sequência (positiva, negativa e zero). Os dados do modelador são pré-requisitos para diversos estudos, tais como: o fluxo de potência e o curto-circuito.
- **Estimação de estado:** fornece o estado da rede (tensão complexa em todas as barras do sistema) a partir de dados de medidores instalados na rede e informações sobre o perfil de carga dos consumidores. Diversas outras funções utilizam o estado estimado da rede, como por exemplo, o controle de tensão e potência reativa, cálculo de perdas técnicas e comerciais e o fluxo de potência *online*.
- **Previsão de carga de curto prazo:** utiliza dados de carga históricos e meteorológicos (por exemplo, a temperatura) para prever a carga do sistema em cada hora para um período de estudo (por exemplo, diário ou semanal). As informações da previsão de carga fornecem dados de entrada para aplicações de planejamento da operação como a reconfiguração otimizada da rede. A previsão de carga é geralmente realizada usando-se modelos estatísticos, como séries

temporais, e baseados em inteligência artificial, como as redes neurais artificiais (RNA) (Li 2011).

- **Análise de curto-circuito:** calcula as tensões e correntes nas três fases para um conjunto de cenários de falta considerando condições de pré-falta especificadas. As correntes de falta calculadas podem ser comparadas com as capacidades de interrupção e limites de corrente de curto-circuito dos equipamentos.
- **Fluxo de Potência:** fornece para os operadores o perfil de tensão e os fluxos de potência na rede para identificar condições anormais de operação nos alimentadores tais como subtensões nas barras e sobrecargas nos circuitos. Este cálculo é realizado periodicamente ou quando há qualquer mudança na topologia ou nas cargas. Os operadores também podem requisitar a execução do fluxo de potência quando necessário.
- **Estimação de Carga:** estima as potências ativa e reativa nos pontos de carga visto que geralmente a única medição disponível na rede de distribuição é localizada na barra da subestação. Esta estimativa é realizada dividindo-se a carga da barra da subestação entre os transformadores abaixadores baseados em fatores de participação ou perfis de carga históricos obtidos a partir de campanhas de medição de carga.

ii) As aplicações de otimização são ferramentas que auxiliam os operadores na tomada de decisões para alcançar objetivos referentes a índices de desempenho da rede de distribuição. As principais aplicações de otimização existentes em redes de distribuição são a Otimização Volt-Var (OVV) e a Reconfiguração Ótima da Rede.

- **A OVV:** determina as ações de controle ótimo para minimizar uma dada função objetivo, como demanda de carga ou consumo de energia, mantendo aceitáveis a tensão e o carregamento ao longo de todo o alimentador. Exemplos de controle incluem:
 - Controle de tap do transformador da subestação;
 - Controle de tap de reguladores de tensão monofásicos ou trifásicos localizados nas subestações ou nos alimentadores;
 - Banco de capacitores chaveados localizados nos alimentadores;

- Geradores de energia conectados ao sistema de distribuição nos quais o controle supervisão está disponível.

A OVV aproveita as medições dos medidores inteligentes, devido a periodicidade de suas medições (geralmente de 5 em 5 minutos), para realizar a sua funcionalidade. Além disso, a OVV tem a característica de abandonar suas funções se um componente ou ação de controle não funciona. Essa característica é chamada de projeto seguro contra falhas.

- **Reconfiguração ótima de rede:** fornece ações de chaveamento recomendadas para o operador e um plano para realizar estas ações. Estas ações são realizadas com o objetivo de minimizar funções objetivo, tais como: minimização das perdas resistivas totais na rede, minimização do pico de demanda para um grupo de alimentadores selecionado e balanceamento de carga para um conjunto de alimentadores.

iii) As aplicações de restauração são responsáveis pela localização, isolamento e restauração de falhas na rede de distribuição. Esta funcionalidade melhora a confiabilidade da rede de distribuição através da redução da frequência e do tempo de restauração das interrupções no fornecimento de energia elétrica para os consumidores. Esta redução é obtida com a operação dos dispositivos: disjuntores, religadores, chaves automáticas, localizadores de falta, etc. O restabelecimento do fornecimento de energia realizado pelas aplicações de restauração envolve os seguintes passos: detecção da falta, localização aproximada da falta, isolamento do componente defeituoso e restauração do fornecimento de energia para o maior número de consumidores no menor tempo possível.

2) Sistema de Informação Geográfica (“GIS – Geographical Information System”):

O modelador da rede de distribuição inclui um modelo da rede dinâmico que reflete o status de chaves e disjuntores. Este modelo é suplementado com o GIS para que os operadores da rede de distribuição tenham noção física (espacial) da rede de distribuição. O GIS é responsável por obter, armazenar, manipular, analisar e gerenciar todos os tipos de dados geográficos da rede. Além disso, ele fornece características elétricas e físicas do sistema de distribuição, como conectividade, comprimento de

linhas, tipo de construção, tipo de condutores, número de condutores, tipo de circuito (subterrâneo ou aéreo), tipo de transformador, etc. Esta função é responsável por criar o modelo unifilar da rede e é essencial para a integração de outras funções do centro de controle da rede de distribuição.

3) Sistema de Gerenciamento de Falhas (“OMS – Outage Management System”):

É um ambiente de intercâmbio de informações entre a concessionária e os consumidores que coleta informações sobre interrupções no fornecimento de energia e auxilia na sua restauração. As principais funções do OMS são (Vaahedi 2014):

- Localização do dispositivo de proteção que eliminou a falta (por exemplo, fusível ou disjuntor) para identificar as partes do sistema que estão energizadas e desenergizadas;
- Organizar e classificar as tarefas realizadas na restauração usando critérios associados com a interrupção, tais como: dimensão (número de consumidores ou potência não fornecida), duração e criticalidade da emergência (instalações onde há risco de fatalidades devido a interrupções no fornecimento de energia, por exemplo, os hospitais). Classificar as falhas segundo um dado critério, que pode ser: criticidade, quantidade de consumidores sem serviço, tipo de cliente fora de serviço ou duração da falha;
- Fornecer informações sobre as falhas, tais como impacto nos consumidores, e estimar o tempo de restauração.

Um OMS moderno consiste em um modelo detalhado da rede de distribuição. Ele usa o GIS para identificar a localização da falha. Ele também se integra com o SCADA do DMS para manter o modelo elétrico do sistema atualizado, prever interrupções e rastrear quais os clientes estão fora de serviço ou já foram restaurados. Utilizando o modelo da rede e rastreando o *status* de disjuntores, chaves e fusíveis, é possível identificar os consumidores que estão fora de serviço, quais foram restaurados e os primeiros consumidores interrompidos pela falha. O acompanhamento destas informações é vital para relatar com precisão as estatísticas de interrupções.

4) Sistema de Informação do Consumidor (“CIS – Customer Information System”):

É a interface entre a concessionária e o consumidor. Os consumidores podem acessar as seguintes informações armazenadas no CIS (Thomas e McDonald, 2015):

- Localização e o tipo do consumidor;
- Tipo de medidor instalado;
- Tipo de pagamento, histórico de pagamento e informação sobre tarifação;
- Histórico sobre consumo e;
- Quaisquer tipos de irregularidades, por exemplo, no pagamento, consumo, etc.

5) Avançada Infraestrutura de Medição (“AMI – Advanced Metering Infrastructure”):

A leitura automatizada de medidores teve um papel importante na simplificação e melhoramento do processo de leitura de medidores realizado pelas concessionárias de distribuição. As exigências e aspirações dos consumidores da atualidade requerem uma comunicação bidirecional entre o consumidor e a concessionária e uma AMI que pode coletar dados medidos e também usar o medidor de energia para realizar um conjunto de funcionalidades para a implementação de uma Rede Elétrica Inteligente (REI). A AMI permite que a concessionária execute funções de controle e dá ao consumidor a capacidade para escolher o modelo de tarifação que desejar, tendo controle dos seus gastos (tarifação inteligente – *smart billing*) (Thomas e McDonald, 2015). A Figura 1.10 ilustra o diagrama de blocos do sistema de uma AMI, que inclui uma unidade de coleta de dados, uma rede de comunicação e um centro de processamento de dados, geralmente referenciado como Sistema de Gerenciamento da Medição de Dados (“MDMS – Meter Data Management System”). A AMI está mais presente em redes de distribuição de países da Europa e da América do Norte. Em países em desenvolvimento, tais como o Brasil, a AMI é geralmente implantada somente em consumidores de grande porte, como aqueles das classes comerciais e industriais, visando minimizar perdas comerciais elevadas. Na verdade, a infraestrutura de medição

na maioria dos consumidores é ainda do tipo convencional: leitura do consumo mensal de energia realizada por equipes de campo nas instalações dos consumidores.

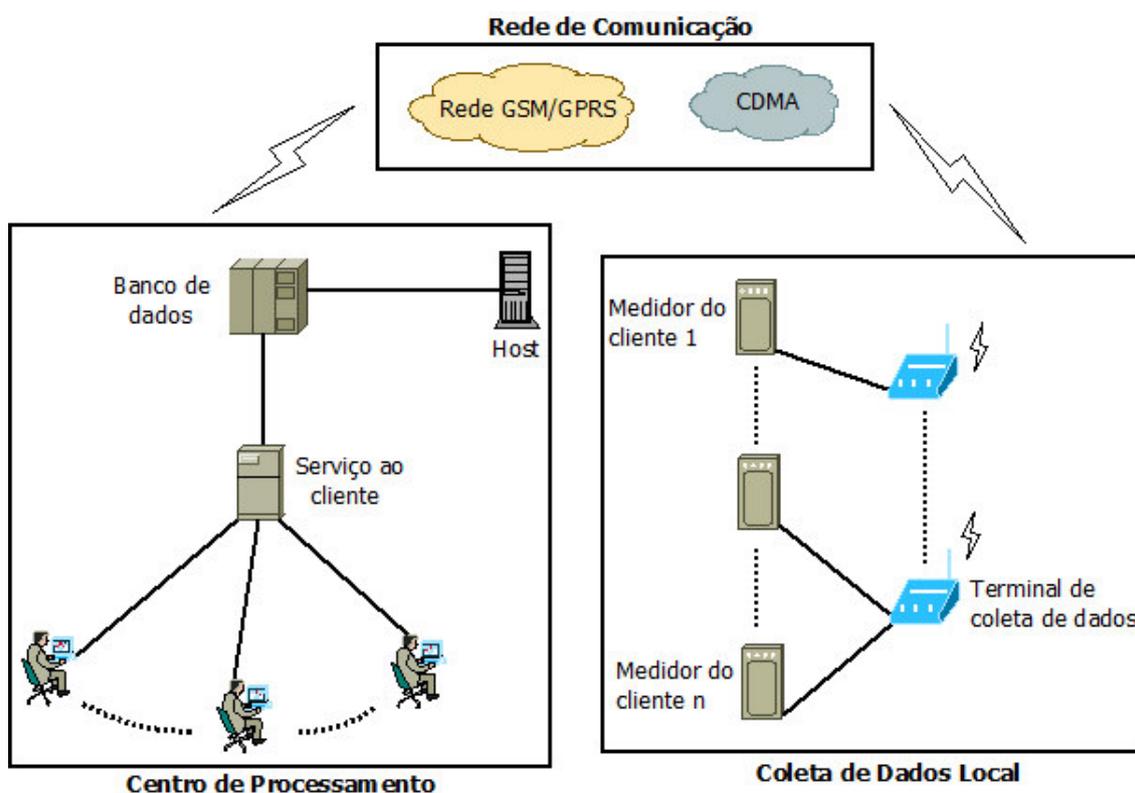


Figura 1.10: Componentes de uma AMI (Adaptado de Thomas e McDonald (2015)).

6) Sistema de Gerenciamento de Ativos (“AMS – Asset Management System”):

O gerenciamento de ativos é uma filosofia empresarial concebida para conciliar metas corporativas com decisões de despesas no nível de ativos. O AMS é uma das mais importantes atividades de uma concessionária de energia elétrica para reduzir risco de eventuais falhas e garantir o bom desempenho dos ativos. Os ativos de uma concessionária são os equipamentos instalados em campo, tais como: transformadores (que são os ativos mais caros), isoladores, buchas, condutores, comutadores, etc. Desse modo, o AMS pode ser definido como o processo de maximizar o retorno de investimentos em equipamentos através da maximização do desempenho deles e da minimização dos custos de manutenção ao longo de todo o ciclo de vida do equipamento. O AMS pode reduzir despesas, gerenciar os riscos de forma mais eficiente ou mesmo comandar ações corporativas em toda a concessionária (Thomas e

McDonald, 2015).

1.2.2 Comentários finais

Nesta seção foi apresentado um resumo associado com as principais funções associadas com a AD. Algumas funcionalidades encontradas no DMS das concessionárias são extensões diretas de aplicações existentes em centros de controle de transmissão, por exemplo, o sistema SCADA. Contudo, a quantidade e a diversidade das funções existentes nos centros de controle do sistema de distribuição são consideravelmente menores do que nos centros de controle da transmissão. Esta característica é devido ao fato de que não há uma quantidade significativa de geração conectada em redes de distribuição convencionais. Além disso, a geração existente em redes de distribuição convencionais não é despachada pela concessionária. Por exemplo, geradores distribuídos geralmente operam no modo de seguidor de tensão para evitar problemas de coordenação com equipamentos de controle de tensão da concessionária, por exemplo, os reguladores de tensão. Conseqüentemente, não existem funções no DMS associadas com a geração, tais como: despacho de carga/geração, comissionamento de unidades geradoras e controle de tensão e potência reativa via ajuste das tensões e potência de saída dos geradores. Outra aplicação encontrada tanto nos centros de controle da transmissão como nos da distribuição é a estimação de estado. Contudo, a sua aplicação em redes de distribuição convencionais é mais limitada devido a pequena disponibilidade de medições, pouca diversidade de funções e menor complexidade com relação aos sistemas de transmissão.

As funcionalidades da AD mudaram o foco de eficiência operacional das redes de distribuição. O surgimento da geração distribuída e os programas de resposta à demanda também introduzem um impacto considerável para a operação da rede. Além desses fatores, a arquitetura integrada das redes elétricas inteligentes tende a acrescentar uma quantidade enorme de dados em tempo real, com o aumento no número de sensores e a necessidade de mais informações sobre o funcionamento do sistema. Em vista disso, a seção seguinte aborda alguns conceitos e destaca desafios e vantagens das REIs.

1.3 Redes Elébricas Inteligentes

Nos sistemas elétricos de potência convencionais a produção de energia elétrica é realizada de forma centralizada em usinas de geração de grande porte devido à economia de escala. Estas usinas de geração (térmicas, hidráulicas, nucleares, etc.) são conectadas ao sistema de transmissão. Recentemente, ocorreram avanços significativos em tecnologias de construção de geradores de pequeno porte, por exemplo, as turbinas a gás. Além disso, o setor elétrico mundial sofreu diversas mudanças estimuladas pela reestruturação de outros setores da economia, tais como: transportes, telecomunicações, gás natural, etc. As principais características do processo de reestruturação do setor elétrico mundial são: introdução de competição na geração, privatização de empresas públicas ou estatais, assegurar acesso aberto aos sistemas de transmissão/distribuição e permitir que os consumidores possam escolher os seus fornecedores de energia. Os avanços nas tecnologias de construção de geradores de pequeno porte e a reestruturação do setor elétrico viabilizaram a produção de energia elétrica em pequena escala através de unidades localizadas próximo dos consumidores ou conectadas diretamente à rede de distribuição. Este tipo de geração é denominado de Geração Distribuída (GD) (Willis et al. 2002).

A conexão da GD na rede de distribuição afeta significativamente sua operação, pois estas redes foram originalmente projetadas para operar com fluxos unidirecionais (sentido da fonte para a carga) e as injeções de potência da GD têm sentido oposto as injeções das cargas. Desta forma, a conexão de GD pode causar violações em limites operacionais da rede de distribuição como, por exemplo, a ocorrência de sobretensões em períodos de carga leve. Neste cenário, os aspectos de controle e gerenciamento da rede de distribuição tornam-se mais complexos, pois o sistema de distribuição deixa de ser uma rede passiva (composta apenas por cargas) para se tornar uma rede ativa (formada por geradores e cargas).

Atualmente, a utilização de tecnologias de GD baseadas em fontes de energia renováveis (solar, eólica, biomassa, maré, etc.) tem sido estimulada pelos altos preços dos combustíveis fósseis e preocupação com as reduções de gases causadores do efeito estufa. O principal desafio encarado pelas concessionárias de distribuição associado com a conexão de GD renovável é a variabilidade na sua potência de saída causada

pelas flutuações estocásticas na fonte de energia primária. A transição para as fontes de energia renovável exigirá uma mudança fundamental na forma como a energia é armazenada e utilizada. A natureza imprevisível da energia gerada a partir de fontes sustentáveis implica em melhorar os sistemas de armazenamento de eletricidade ou utilizar a eletricidade apenas quando ela está disponível. Na verdade, ambos os aspectos devem ser considerados nesta mudança de paradigma. As tecnologias de armazenamento de energia ainda não estão suficientemente desenvolvidas. Assim, no curto prazo, é necessário ajustar a demanda de energia para corresponder à geração disponível. Para que a demanda esteja em conformidade com a geração os consumidores necessitam estar conscientes de quando há energia e serem capazes de programar o seu consumo de acordo com a energia disponível (Beard 2010).

Em suma, o consumidor precisa se tornar muito mais engajado com a indústria de energia elétrica do que tem sido. Para reduzir as emissões de poluentes, devido ao uso de combustíveis com rico teor de carbono, deve-se eletrificar os meios de transporte e os sistemas de aquecimento/refrigeração residenciais. Ou seja, é necessário gerar mais eletricidade do que aquela produzida hoje (evidentemente de fontes renováveis). Isto, por sua vez, resulta em maior fluxo de energia e utilização das redes de distribuição. Se a nova demanda de eletricidade deve ser atendida, ela deve ser flexível o suficiente para se adaptar a imprevisibilidade e inflexibilidade de fontes de energia sustentáveis.

Evidentemente, as redes de distribuição convencionais não estão preparadas para atender as exigências associadas com a produção de energia a partir de fontes de energia renováveis e programas de gerenciamento pelo lado da demanda. Esta limitação é devido ao fato de que os processos de controle, automação e gerenciamento da rede de distribuição ainda não estão tão desenvolvidos quanto aqueles relacionados com sistemas de transmissão. Esta diferença entre sistemas de transmissão e distribuição é devido ao fato de que as falhas no sistema de transmissão têm mais impacto do que no sistema de distribuição. Consequentemente priorizou-se a modernização de sistemas de transmissão visando mitigar os custos de interrupção resultantes de *blackouts*.

Os DMS convencionais possuem duas limitações: número escasso de dispositivos de medição instalados na rede e a demanda em tempo real em cada ponto de carga não é conhecida. Na verdade, apenas tem-se disponível o consumo de energia no final do período de faturamento. Desta forma, deve-se superar estas limitações das redes de distribuição convencionais para tornar possível a geração de energia a partir de

fontes renováveis e os programas de gerenciamento pelo lado da demanda. Um novo paradigma que está sendo proposto atualmente para resolver este problema é conceito de REIs, que na literatura de língua inglesa é denominada de “*Smart Grid*”. Uma REI pode ser definida como um sistema de potência complexo que utiliza comunicação bidirecional entre recursos de energia distribuídos, consumidores e um sistema de controle central com os seguintes objetivos: melhorar a qualidade do fornecimento de energia, explorar de forma otimizada a utilização de GDs renováveis, auto-reparo (“*self-healing*”) da rede elétrica durante a ocorrência de falhas nos equipamentos, possibilitar que os consumidores gerenciem o seu uso da energia elétrica para minimizar as suas despesas e otimizar o gerenciamento dos ativos através de técnicas avançadas de monitoramento da condição e inspeção (Beard 2010; Bracale et al. 2013). Uma definição alternativa dada pelo Departamento de Energia dos EUA é que, uma REI é uma rede auto restaurativa, que permite a participação ativa dos consumidores; opera de forma resiliente contra agentes externos (ataque cibernético, ataque terrorista, situação de guerra, etc.) e desastres naturais; acomoda todas as opções de geração e armazenamento; permite a introdução de novos produtos, serviços e mercados; otimiza a utilização dos ativos e; opera de forma eficiente atendendo a padrões de qualidade de energia (Hadjsaïd e Sabonnadière, 2012). A Figura 1.11 demonstra o conceito de REI.

Para uma REI, o consumidor torna-se um ativo ou mesmo proativo, quando todas as possibilidades de controle de carga, produção local ou armazenamento de energia são incluídas dependendo da tecnologia disponível e da legislação do setor elétrico em questão. Esses fatores contribuem para o aumento da complexidade do sistema. Manter ou melhorar a qualidade de energia para enfrentar esses desafios requer a implantação de mais inteligência na rede. O recente desenvolvimento das Tecnologias de Informação e Comunicação (TIC) a um custo razoável oferece possíveis soluções para o sistema elétrico. A democratização das TIC, tais como a Linha Digital Assimétrica para Assinante (“ADSL – Asymmetric Digital Subscriber Line”), trouxe vários serviços para o consumidor final em apenas um equipamento, possibilitando o advento dos medidores inteligentes (Hadjsaïd e Sabonnadière, 2012).

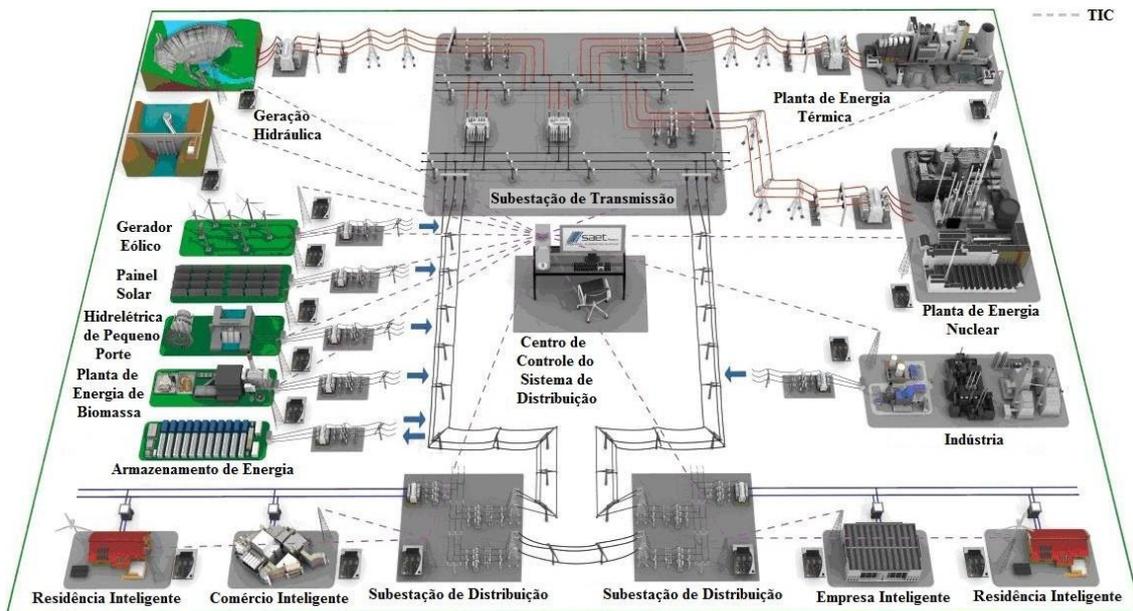


Figura 1.11: Integração através da REI (Adaptado de Smart Grid & Smart Storage (2015)).

Os medidores inteligentes têm uma importância fundamental nesse processo. Eles podem, por exemplo, oferecer estratégias de gerenciamento da demanda que permitem a participação dos consumidores na mitigação de violação em restrições operativas, redução do pico de carga, minimização das perdas ou oferecer outros serviços necessários ao sistema. Neste contexto, a instalação de um grande número de medidores inteligentes pode produzir um grande volume de dados que será requerido por muitas aplicações distintas. Apesar dos investimentos significantes na infraestrutura de telecomunicações, o grande volume de dados poderá restringir a implementação de algumas aplicações. Devido a isto, já estão sendo desenvolvidas metodologias para a compressão de dados em REI (Souza et al., 2016).

Para planejar e operar adequadamente uma REI, muitas novas considerações técnicas, no âmbito de sistemas de distribuição, devem ser consideradas, por exemplo: a estabilidade (devido a instalação de GD), o despacho de carga e geração, o gerenciamento de dispositivos de armazenamento de energia e a avaliação do impacto da conexão de veículos elétricos na rede de distribuição. O principal pré-requisito para muitas destas novas funções do DMS é a determinação do estado da rede elétrica (módulo e a fase das tensões nodais) em tempo real a partir de dispositivos de medição instalados na rede elétrica. Em centros de controle de sistemas de transmissão esta tarefa

é realizada por ferramentas de estimação de estado. Desta forma, a Estimação de Estado em Redes de Distribuição (EERD) é um dos alicerces para a implantação de uma REI.

1.4 Estimação de Estado em Redes de Distribuição

O estimador de estado processa telemidas redundantes (magnitude das tensões nas barras, injeções de potência nas barras, fluxos de potência e/ou de corrente nos circuitos), corrompidas por erros de diversos tipos, para estimar valores de módulo e fase das tensões em todas as barras, isto é, o estado do sistema em regime permanente. A partir do estado, é possível determinar outras variáveis necessárias para a análise e monitoramento do sistema, tais como: fluxos de potência nos circuitos, correntes nas linhas, injeções de potência nas barras, etc. Além das telemidas tomadas ao longo do sistema, existem outras quantidades que não são medidas diretamente, mas também contém informações relevantes sobre o estado do sistema e podem ser processadas pelo estimador de estado. Estas quantidades que podem ser estimadas sem a utilização de instrumentos de medição são denominadas de pseudo-medidas. As principais aplicações da função de estimação de estado nos centros de controle dos sistemas de transmissão são (Costa e Salgado 2014):

- i) Monitoração da segurança, cujo objetivo é monitorar a condição atual de operação do sistema (normal, emergência ou restaurativa);
- ii) Análise de segurança, cuja função é avaliar os efeitos de eventuais contingências no sistema;
- iii) Previsão de carga, cujo objetivo é estimar a demanda futura nas barras do sistema.

Geralmente, o problema de estimação é resolvido minimizando-se os desvios quadráticos ponderados entre os valores medidos e calculados de grandezas elétricas (Monticelli 1999; Abur e Expósito, 2004). Os algoritmos existentes para EERD podem ser classificados em duas categorias:

- i) Matriciais (Teng et al. 1995; Teng et al. 1996; Singh et al. 2008): utilizam o método de Gauss-Newton para minimizar os desvios quadráticos ponderados.
- ii) Híbridos (Wang e Schulz, 2004; Lin, Teng e Chen, 2001): combinam o método de Gauss-Newton com técnicas de varredura progressiva/regressiva (“*backward/forward*”).

sweep”) para estimar variáveis de estado com base na topologia radial da rede de distribuição.

As principais diferenças entre a estimação de estado em redes de distribuição e transmissão são descritas abaixo:

i) Utilização de modelagem em coordenadas de fase para estimadores de distribuição, pois esta rede é desbalanceada por natureza devido a não-transposição dos circuitos e conexão de cargas desequilibradas. Por outro lado as redes de transmissão são razoavelmente equilibradas, devido a transposição dos circuitos e podem ser modeladas usando apenas os modelos de sequência positiva.

ii) Em sistemas de transmissão há uma grande quantidade de medidores instalados e devido a isto o número de pseudo-medições é relativamente pequeno. Por outro lado, em sistemas de distribuição o número de medidores instalados é muito pequeno e o número de pseudo-medições é bastante elevado. As principais pseudo-medições usadas em EERD são aquelas associadas com as cargas ativas e reativas nos transformadores abaixadores que alimentam a rede secundária. Geralmente, estas cargas são estimadas usando-se técnicas de alocação de carga ou dados estatísticos de campanhas de medição realizadas pelas concessionárias.

iii) No sistema de transmissão as variáveis de estado são geralmente o módulo e a fase das tensões nodais. Por outro lado, em redes de distribuição podem ser utilizadas outras grandezas como variáveis de estado, tais como: partes real e imaginária das tensões nodais (notação retangular) e também o módulo e a fase das correntes nos ramos. A escolha destas grandezas tem como objetivo evitar problemas de singularidade da matriz Jacobiana quando medições de corrente são processadas pelo estimador de estado.

A presença de um número reduzido de medições pode tornar a rede elétrica não-observável no âmbito da estimação de estados. Isto é, as variáveis de estado (módulo e fase das tensões nodais em todas as barras) não podem ser determinadas a partir de um conjunto de medições por um estimador de estados. Matricialmente, a não-observabilidade está associada com o fato do posto da matriz Jacobina associada com as medições não ser igual a dimensão do vetor de variáveis de estado. Do ponto de vista prático, não é viável alocar medidores na rede de distribuição para assegurar a sua observabilidade. Esta restrição é devido às dimensões das redes de distribuição serem

consideravelmente maiores do que aquelas das redes de transmissão. A dimensão elevada das redes de distribuição é causada pelo grande número de seções e ramificações necessárias para rotear os alimentadores através de vias públicas. Desta forma a trajetória dos ramais, entre o tronco principal do alimentador e um ponto de carga, geralmente não corresponde a menor distância entre dois pontos. Devido a isto, para viabilizar a EERD geralmente utiliza-se um grande número de pseudo-medições que são adicionadas ao plano de medição existente para assegurar a observabilidade. Uma desvantagem com esta estratégia é que a precisão do estado estimado é comprometida devido ao fato de que os erros associados com as pseudo-medições são consideravelmente maiores do que aqueles referentes às medições reais. Consequentemente, o problema de alocação de medidores, para fins de EERD, tem como objetivo minimizar os erros associados com as variáveis de estado estimadas em vez de assegurar a observabilidade da rede elétrica.

1.5 Alocação de Medidores para Estimação de Estado em Redes de Distribuição

A maioria das metodologias existentes para a alocação de medidores em redes de distribuição visam a minimização de uma das seguintes funções:

- i) Probabilidade do erro relativo entre os valores verdadeiros e estimados das grandezas monitoradas ser maior do que um valor especificado (Singh et al. 2009; Singh et al. 2011);
- ii) Soma ponderada das variâncias associadas com as variáveis de estado estimadas (Strbac et al. 2005; Muscas et al. 2006; Muscas et al. 2009).

A partir da descrição acima, pode-se concluir que o problema de alocação de medidores para EERD tem as seguintes características:

- i) Não-linear: devido a natureza não-linear das equações de fluxo de potência que são a base para o problema de EERD.
- ii) Combinatorial: pois as variáveis de decisão são os locais da rede (barras ou ramos) nos quais deve-se instalar (variável de decisão é unitária) ou não um medidor (variável de decisão é nula).

iii) Estocástico: as funções objetivo são baseadas em índices probabilísticos (variâncias e probabilidades) para reconhecer as incertezas associadas com o estado estimado da rede elétrica a partir de medições corrompidas por erros de natureza diversificada.

Um componente importante do método usado para resolver o problema de alocação de medidores é a técnica probabilística usada para estimar a função objetivo. Devido a natureza não-linear do problema de EERD, a melhor opção tem sido utilizar a Simulação Monte Carlo (SMC) (Strbac et al. 2005; Muscas et al. 2006; Muscas et al. 2009; Singh et al. 2009; Singh et al. 2011; Liu et al. 2014). A SMC é usada para gerar uma amostra de medições com base nas distribuições de probabilidade (normal ou gaussiana) dos erros de medição e nos valores verdadeiros das grandezas medidas. Estes valores verdadeiros são obtidos a partir da solução do problema de fluxo de carga para a configuração do caso base da rede de distribuição. Em seguida, o estado estimado para cada elemento desta amostra é obtido usando um algoritmo de EERD tal como o método de Gauss-Newton. Finalmente, a amostra de estados estimados é usada para calcular a função objetivo de um plano de medição candidato a solução do problema de alocação. Uma desvantagem da SMC para estimar a função objetivo do problema de alocação é o seu alto custo computacional devido a necessidade de resolver um problema de estimação de estado não-linear para cada elemento da amostra.

1.6 Motivação da Pesquisa

A partir da revisão bibliográfica, pode-se notar que não há trabalhos publicados na literatura de alocação de medidores em redes de distribuição sem a presença da SMC, ou seja, a maioria das metodologias existentes para a alocação de medidores em redes de distribuição minimiza uma função objetivo a partir de uma estimativa proveniente da SMC. O desenvolvimento de uma metodologia que substitua esta técnica probabilística por uma técnica analítica é de fundamental importância para aliviar o alto custo computacional em redes reais de grande porte. O desenvolvimento de um método analítico também tornará possível a aplicação de outras técnicas de otimização, tais como meta-heurísticas (algoritmos genéticos, otimização por enxame de partículas, busca de harmonia, etc.), para melhorar a qualidade das soluções do problema de alocação de medidores. Além disso, a combinação de meta-heurísticas com o método

análítico permitirá a otimização de múltiplos objetivos no problema de alocação, por exemplo: minimização dos custos de instalação dos medidores e dos índices de desempenho probabilísticos do plano de medição. Finalmente, é importante enfatizar que a aplicação da SMC, para estimar a função objetivo do problema de alocação de medidores, é realizada com uma amostra de tamanho reduzido para minimizar o custo computacional do algoritmo de alocação. Nestes casos, a precisão das estimativas da função objetivo pode ser comprometida. Por exemplo, um plano de medição ótimo pode obter valores aceitáveis para a função objetivo com uma amostra de 100 elementos. Mas quando o mesmo plano de medição é validado com uma amostra maior (por exemplo, 10000), o valor da função objetivo pode se tornar inaceitável evidenciando o fato de que é necessário instalar mais medidores do que aqueles que foram inicialmente alocados. Em outras palavras, pode ocorrer o mascaramento de planos de medição de baixa qualidade devido a falta de precisão da SMC com amostras de tamanho reduzido.

A ausência de uma metodologia que considere os aspectos acima motivou a realização da pesquisa descrita nesta dissertação.

1.7 Objetivos da Dissertação

O principal objetivo desta dissertação é propor um algoritmo para a alocação de medidores visando melhorar a precisão do EERD. Este algoritmo foi desenvolvido pesquisando-se metodologias que tenham potencial para reduzir o custo computacional da estimação da função objetivo no problema de alocação. Desta forma, a principal contribuição do método proposto nesta dissertação com relação às metodologias existentes de alocação de medidores é o seu baixo custo computacional que permitirá a sua aplicação em redes de distribuição reais de grande porte. É importante enfatizar que esta redução no custo computacional é obtida sem sacrificar a precisão do cálculo da função objetivo. Este compromisso foi estabelecido usando-se duas estratégias. Na primeira, o vetor de estado é calculado através de um modelo linearizado e a função objetivo é estimada via SMC. Na segunda, a função objetivo é determinada através de uma função analítica fechada com base no modelo linearizado sem o uso da SMC. Estas duas estratégias se baseiam na combinação das seguintes técnicas:

- i) Linearização dos vetores de estado e medições através da expansão de Taylor;

ii) Combinações lineares de variáveis aleatórias gaussianas.

Além disso, as versões melhoradas dos algoritmos de alocação propostos nesta dissertação consideram o efeito da correlação entre as medições.

1.8 Estrutura da Dissertação

O presente trabalho está sistematizado da seguinte forma:

Capítulo 1 – Apresenta uma visão geral sobre sistemas de distribuição de energia elétrica; automação das redes de distribuição convencionais e redes elétricas inteligentes. Também é apresentada uma revisão bibliográfica mostrando os principais trabalhos realizados sobre o problema de alocação de medidor em redes de distribuição. Finalmente, destaca-se a motivação para a execução desta dissertação e os objetivos da mesma.

Capítulo 2 – Apresenta o estimador de estado via método de Gauss-Newton. Descreve a formulação do problema de estimação; as leis de formação da matriz Jacobiana e o algoritmo conceitual.

Capítulo 3 – Apresenta uma descrição de alguns conceitos básicos da estatística multivariada utilizados nesta dissertação, tais como distribuição normal, testes de hipóteses de normalidade e de coeficiente de correlação populacional. Estes conceitos são fundamentais para a metodologia analítica de alocação de medidor em redes de distribuição. Adicionalmente, apresenta-se uma visão geral sobre estimação de estado via método de Gauss-Newton com medições correlacionadas. Descreve-se a formulação do problema de estimação e o algoritmo conceitual.

Capítulo 4 – Descreve a metodologia de alocação de medidores que serve de base para as duas metodologias propostas nesta dissertação. Essa metodologia faz uso da SMC. Por esta razão, faz-se uma breve explanação sobre esta técnica probabilística.

Capítulo 5 – Neste capítulo apresentam-se as duas metodologias propostas para a alocação de medidores em redes de distribuição. Ambos os métodos baseiam-se na linearização dos vetores de estado e de medições. Entretanto, um método faz uso da simulação Monte Carlo e o outro utiliza uma fórmula analítica fechada para obter a distribuição de probabilidade do estado do sistema.

Capítulo 6 – Apresenta os resultados dos testes com as metodologias desenvolvidas nesta dissertação para a alocação de medidores em redes de distribuição. Também se apresenta uma validação de alocação de metodologias existentes baseadas na SMC com amostras reduzidas para identificar o mascaramento de planos de medição de baixa qualidade.

Capítulo 7 – Apresenta as principais conclusões resultantes desta dissertação e também algumas sugestões para trabalhos futuros.

ESTIMAÇÃO DE ESTADO VIA MÉTODO DE GAUSS-NEWTON

2.1 Introdução

Muitas funções que compõem o DMS, tais como otimização volt-var e análise de fluxo de carga, necessitam do estado estimado do sistema. Consequentemente, a estimação de estado tem grande importância para a operação segura do sistema de energia elétrica, como pode ser visto a partir da Figura 2.1. Como já fora dito, o principal objetivo do estimador de estado é fornecer, de forma coerente e confiável, uma estimativa de todas as grandezas do sistema elétrico de potência. Esta tarefa é feita a partir de telemidas redundantes (geralmente a magnitude das tensões nas barras, injeções de potência nas barras, fluxos de potência e/ou de corrente nos circuitos) que são pré-filtradas para evitar que a estimação de estado de estado seja realizada com medidas portadoras de erros grosseiros.

Matematicamente, o estimador de estado é uma ferramenta capaz de determinar a melhor estimativa de um conjunto de variáveis de estado que determina a condição operativa do sistema (Costa e Salgado 2014). Tanto em sistemas de transmissão quanto em sistemas de distribuição, o conjunto de variáveis de estado a ser determinado, geralmente, é a tensão complexa em cada barra do sistema. Isso porque a partir do estado estimado é possível determinar outras variáveis necessárias para a análise e monitoramento do sistema, tais como: fluxos de potência nos circuitos, correntes nas linhas, injeções de potência nas barras, etc. Todavia, duas considerações na modelagem do problema de estimação de estado devem ser feitas:

- **Variação de carga:** assume-se que as cargas variem lentamente em intervalos de tempo pré-especificados, ou seja, considera-se o estado do sistema em regime permanente, invariante no tempo. Isso significa que não é necessário modelar a evolução temporal do estado, desconsiderando-se informações sobre o comportamento do sistema em instantes anteriores.

- **Número de medições:** para garantir a observabilidade da rede a quantidade de medições deve ser maior ou igual à quantidade de variáveis de estado. Isso garante a obtenção do estado, pois o sistema de equações lineares resultante fica sobredeterminado.

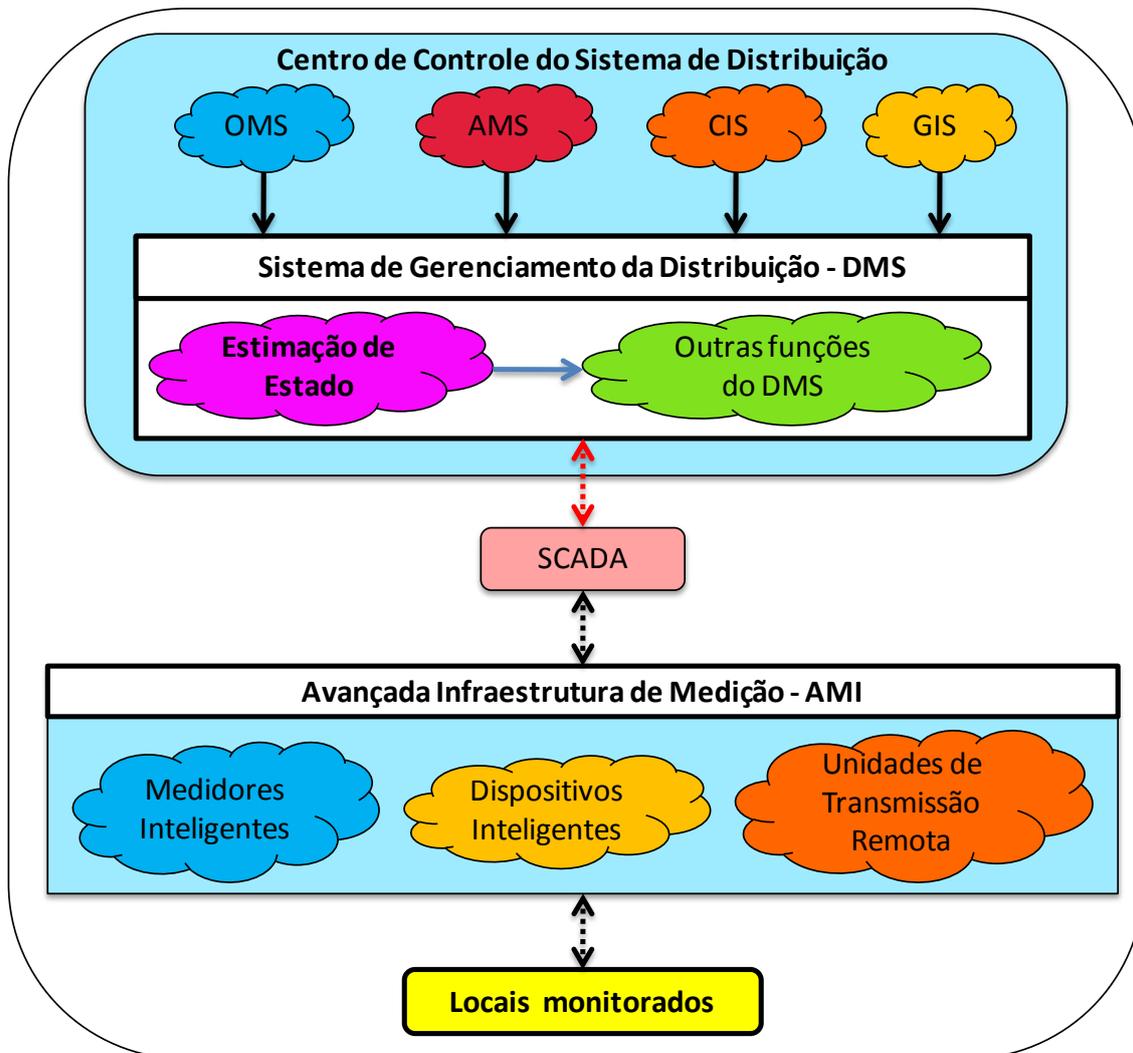


Figura 2.1: O Estimador de estado na arquitetura da rede de distribuição.

As considerações sobre a variação de carga não podem ser assumidas para os estimadores sequenciais. Estimadores sequenciais levam em consideração o comportamento dinâmico do sistema. Neste sentido, a técnica utilizada para caracterizar o comportamento dinâmico do sistema baseia-se no filtro de Kalman. Devido à complexidade de implementação, esta técnica tem sido empregada com algumas

simplificações, ou mesmo substituída por métodos ortogonais baseados nas rotações de Givens.

2.2 Classificação dos Estimadores de Estado

As principais diferenças entre os métodos de estimação de estado são: a formulação do problema; o processamento dos dados e; o algoritmo utilizado na resolução do problema formulado. Na formulação analítica do problema, a técnica mais utilizada é baseada na minimização da soma ponderada dos quadrados dos resíduos, ou seja, são os estimadores do tipo Mínimos Quadrados Ponderados (MQP). Entretanto, modelagens alternativas baseadas na minimização da soma dos valores absolutos dos resíduos também são encontradas na literatura – estimadores do tipo Mínimos Valores Absolutos Ponderados (MVAP). Quanto ao modo de processar os dados, os estimadores de estado podem ser de dois tipos: *batch*, no qual as medidas disponíveis são processadas simultaneamente e *sequenciais*, em que as quantidades medidas são processadas uma por vez (Costa e Salgado 2014).

Existe uma gama de algoritmos de otimização que podem resolver o problema de mínimos quadrados ponderados para estimadores do tipo *batch*. Todavia, devido às características particulares deste problema, o processo iterativo para a determinação do estado baseia-se nos seguintes métodos:

- solução via equação normal (método clássico);
- uso de métodos ortogonais (reflexões de Householder, rotações de Givens, etc);
- aplicação de métodos híbridos (fatoração ortogonal combinada a solução do sistema linear não-ortogonal);
- solução através do método de Hachtel (também conhecido como método da matriz aumentada ou *tableau* esparso);
- exploração do desacoplamento $P\delta - QV$ (estimadores desacoplados).

Quanto aos estimadores *sequenciais*, já foi visto que a solução recursiva de mínimos quadrados pode ser obtida através do filtro de Kalman ou através de métodos ortogonais baseados nas rotações de Givens. Para mais detalhes sobre esta teoria as referências

Monticelli (1999), Abur e Expósito (2004) ou Lewis et al. (2008) podem ser consultadas.

2.3 Método de Gauss-Newton com Medições Descorrelacionadas

Considere o conjunto de m medições dado pelo vetor z :

$$z = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_m \end{bmatrix} = \begin{bmatrix} h_1(x_1, x_2, \dots, x_n) \\ h_2(x_1, x_2, \dots, x_n) \\ \vdots \\ h_m(x_1, x_2, \dots, x_n) \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_m \end{bmatrix} = h(x) + e_z \quad (2.1)$$

Em que:

$$h^T = [h_1(x), h_2(x), \dots, h_m(x)];$$

$h_i(x)$: é a função não-linear associada com o valor calculado da medição i para o vetor de estado x ;

$x^T = [x_1, x_2, \dots, x_n]$: é o vetor de estado do sistema, e;

$e_z^T = [e_1, e_2, \dots, e_m]$: é o vetor de erros das medições.

As seguintes hipóteses são consideradas com relação aos erros de medição:

- i) $E(e_i) = 0$, para $i = 1, \dots, m$;
- ii) Os erros das medições são independentes, isto é, $E[e_i e_j] = 0$. Por conseguinte, $Cov(e_z) = E[e_z \cdot e_z^T] = R_z = \text{diag}\{\sigma_1^2, \sigma_2^2, \dots, \sigma_m^2\}$.

O desvio padrão σ_i da cada medição i é calculado para refletir a precisão esperada do correspondente medidor utilizado. A matriz R_z é a matriz de covariância das medições. O estimador que utiliza o MQP reduzirá a função objetivo dada em (2.2).

$$J(x) = \sum_{i=1}^m \frac{[z_i - h_i(x)]^2}{R_{ii}} = [z - h(x)]^T R_z^{-1} [z - h(x)] \quad (2.2)$$

No ponto de mínimo de (2.2), as condições de optimalidade de primeira ordem devem ser satisfeitas. Na forma compacta, isso pode ser expresso através de (2.3):

$$g(x) = \frac{\partial J(x)}{\partial x} = -H^T(x)R_z^{-1}[z - h(x)] = 0 \quad (2.3)$$

no qual $H(x) = \left[\frac{\partial h(x)}{\partial x} \right]$ é a matriz Jacobiana associada com o vetor $h(x)$.

Expandindo a função não-linear $g(x)$ através da série de Taylor em torno do vetor de estado $x^{(k)}$:

$$g(x) = g(x^{(k)}) + G(x^{(k)})(x - x^{(k)}) + \dots = 0 \quad (2.4)$$

Desprezando-se os termos de segunda ordem e utilizando-se o Método iterativo de Gauss-Newton (MGN), tem-se:

$$x^{(k+1)} = x^{(k)} - [G(x^{(k)})]^{-1} \cdot g(x^{(k)}) \quad (2.5)$$

Em que:

k : é o contador de iteração;

$x^{(k)}$: é o vetor solução para a iteração k ;

$g(x^{(k)}) = -H^T(x^{(k)}) \cdot R_z^{-1} \cdot [z - h(x^{(k)})]$, e;

$$G(x^{(k)}) = \frac{\partial g(x^{(k)})}{\partial x} = H^T(x^{(k)}) \cdot R_z^{-1} \cdot H(x^{(k)}) \quad (2.6)$$

A matriz $G(x)$ é denominada *Matriz Ganho* ou *Matriz de Informação*. A matriz R_z é diagonal. Por esta razão, a matriz $G(x)$ é aproximadamente duas vezes mais densa do que a matriz $H(x)$. Por outro lado, a matriz $H(x)$ é esparsa e, portanto, a matriz de informação também possui um número reduzido de elementos não-nulos, o que possibilita o uso de técnicas de esparsidade. Adicionalmente, $G(x)$ é simétrica e positiva definida, o que facilita sua fatoração. Com a fatoração de $G(x)$, o vetor solução pode ser obtido a cada iteração k através da substituição progressiva/regressiva (*forward/backward*) de acordo com (2.7):

$$[G(x^{(k)})] \cdot \Delta x^{(k+1)} = H^T(x^{(k)}) \cdot W \cdot \Delta z^{(k)} \quad (2.7)$$

em que: $\Delta x^{(k+1)} = x^{(k+1)} - x^{(k)}$, $W = R_z^{-1}$ e $\Delta z^{(k)} = [z - h(x^{(k)})]$.

A equação (2.7) é denominada *Equação Normal* e representa o sistema linear a ser resolvido a cada iteração para a determinação do incremento do vetor de estado Δx .

O problema representado em (2.7) possui tendência a um mal condicionamento numérico, implicando em problemas de convergência ou instabilidade numérica (D.-García et al. 2011). Isto pode ser verificado analisando-se o número de condicionamento da matriz ganho. O número de condicionamento espectral de uma matriz A é definido segundo (2.8).

$$Cond(A) = \frac{\lambda_{max}}{\lambda_{min}} \quad (2.8)$$

em que, λ_{max} e λ_{min} são o máximo e o mínimo autovalores da matriz A .

A equação (2.8) mede o quanto pequenas perturbações na matriz A afetam a precisão da solução x do sistema linear $Ax = b$. Quando o número de condicionamento é muito alto, pequenas perturbações na matriz A ou no vetor b produzirão grandes perturbações no vetor solução x . Em aplicações no sistema de potência, como estimação de estado, o número de condicionamento deverá ser menor ou igual a 10^{12} (D.-García et al. 2011). Para a equação normal, pode-se provar que $Cond(H^T H) = [Cond(H)]^2$, ou seja, se H não é bem condicionada, G estará altamente mal condicionada (a condição numérica de G é igual ao quadrado da condição numérica da matriz Jacobiana H). As principais fontes de mal condicionamento numérico de (2.7) são:

- Conexão de ramos que possuem impedâncias elevadas com ramos de impedância pequenas;
- Grande quantidade de medições de injeção;
- Barras de injeção nula (medições fictícias).

Para viabilizar a EERD geralmente utiliza-se um grande número de pseudo-medições que são adicionadas ao plano de medição existente para assegurar a observabilidade. Como consequência, a precisão do estado estimado é comprometida devido ao fato de que os erros associados com as pseudo-medições são consideravelmente maiores do que aqueles referentes às medições reais e o condicionamento da matriz de informação é deteriorado. Adicionalmente, as barras de injeção nula são modeladas como medições fictícias de alta precisão. Desta forma, estas barras são incluídas no problema de estimação de estado atribuindo a elas um baixo desvio padrão (entre 10^{-8} e 10^{-4}). Esta modelagem também degrada o número de condição da matriz de ganho.

Devido a estas características, o algoritmo utilizado neste trabalho para estimar o estado da rede elétrica faz uso da fatoração QR da matriz ganho, ao invés de utilizar a decomposição de Cholesky.

2.4 Algoritmo de Estimação de Estado via Método de Gauss-Newton

Nesta seção é sumarizado o algoritmo utilizado para estimar o estado da rede de distribuição. Primeiramente a equação (2.7) pode ser reescrita, omitindo-se o contador de iteração k , de acordo com (2.9):

$$\underbrace{H^T W H}_G \cdot \Delta x = H^T \cdot W \cdot \Delta z \quad (2.9)$$

A matriz W é simétrica e positiva definida, logo W pode ser fatorada pela decomposição de Cholesky, com $W = DD^T$. Uma maneira de mitigar problemas de convergência ou instabilidade numérica devido ao mal condicionamento da matriz G é o uso da fatoração ortogonal. A fim de aplicar a fatoração ortogonal ao problema de estimação de estado via MQP, a equação normal (2.9) é reescrita na forma compacta:

$$\underbrace{\tilde{H}^T \tilde{H}}_G \cdot \Delta x = \tilde{H}^T \cdot \Delta \tilde{z} \quad (2.10)$$

em que:

$$\tilde{H} = D^T H \quad (2.11)$$

$$\Delta \tilde{z} = D^T \Delta z \quad (2.12)$$

Fatorando \tilde{H} através da decomposição QR, tem-se $\tilde{H} = QR$. Usando a propriedade $QQ^T = I$, (2.10) pode ser transformada sucessivamente em:

$$R \cdot \Delta x = Q^T \cdot \Delta \tilde{z} \quad (2.13)$$

Em suma, cada iteração da estimação de estado via MGN utilizando a decomposição QR consiste nos seguintes passos:

Passo #1: Determinar a estrutura da matriz Jacobiana $H(x)$;

Passo #2: Obter a decomposição de Cholesky da matriz W ($W = DD^T$);

Passo #3: Arbitrar uma estimativa inicial para o vetor de estados $\hat{x}^{(0)}$;

$k = 0$;

Passo #4: Calcular os valores numéricos de $\tilde{H} = D^T H(\hat{x}^{(k)})$ e $\Delta\tilde{z} = D^T [z - h(\hat{x}^{(k)})]$;

Passo #5: Fatorar a matriz $\tilde{H} = QR$;

Passo #6: Atribuir $\Delta z_q = Q^T \Delta\tilde{z}$ e resolver o sistema linear $R\Delta x^{(k)} = \Delta z_q$ por substituição regressiva;

Passo #7: Verificar a convergência: se $\max|\Delta x^{(k)}| \leq \epsilon$ (em geral $\epsilon = 10^{-4}$ pu), parar o processo iterativo, caso contrário, atualizar o vetor de estados $\hat{x}^{(k+1)} = \hat{x}^{(k)} + \Delta x^{(k)}$.

Passo #8: Fazer $k = k + 1$. Se $k > N_{iter}$ (N_{iter} é o máximo número de iterações), parar o processo iterativo, caso contrário, voltar ao passo #4.

A partir dos passos acima, fica evidente que não é necessário obter e fatorar a matriz ganho G . Além disso, a fatoração QR é numericamente mais estável do que a fatoração de Cholesky. Portanto, a utilização de pesos muito elevados para medições fictícias associadas com barras de injeção nula não gera nenhum problema de instabilidade numérica. Os passos do MGN são ilustrados através do fluxograma da Figura 2.2.

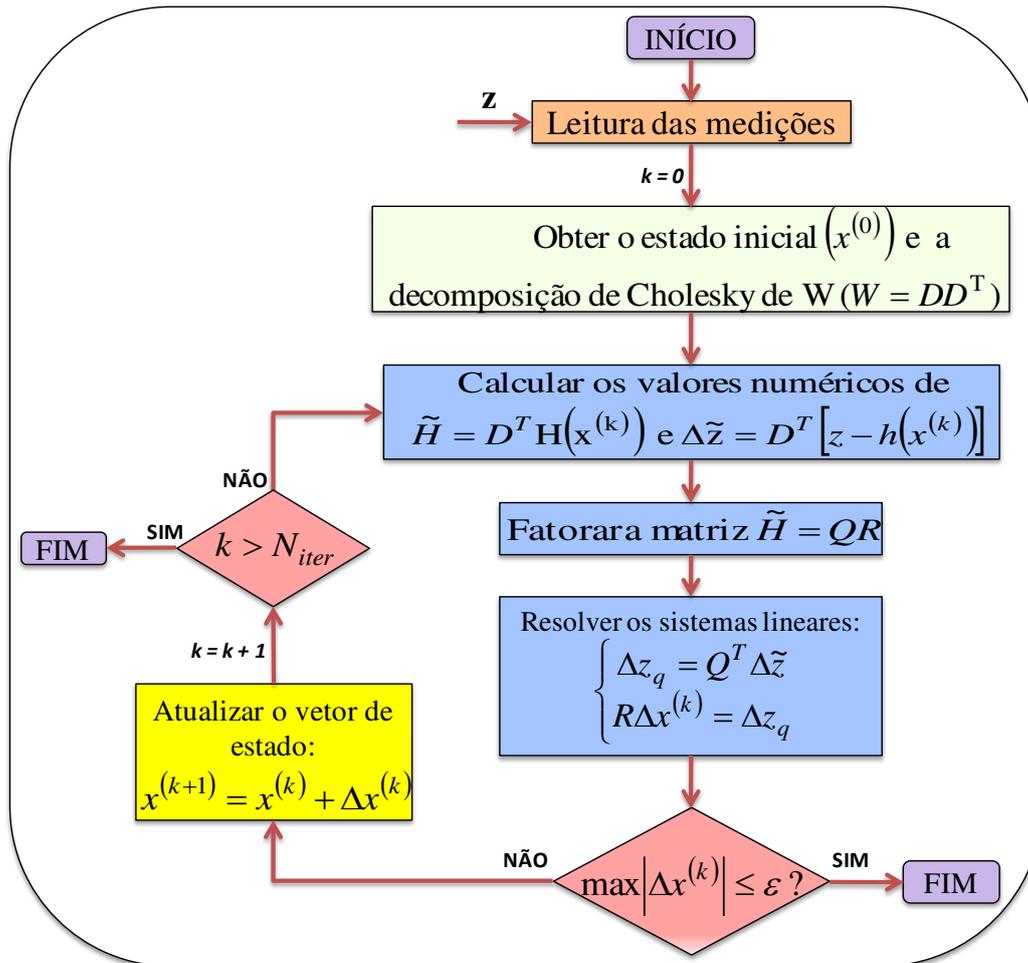


Figura 2.2: Método de Gauss-Newton para estimação de estado.

2.5 Funções de Medição e Estrutura da Matriz Jacobiana H

Nesta seção são descritas as funções não-lineares associadas a cada tipo de medição, bem como a estrutura da matriz Jacobiana H considerando-se o módulo e a fase da tensão em cada barra do sistema como variáveis de estado. As expressões para cada tipo de medição (injeção/fluxo de potência e tensão) são dadas abaixo assumindo-se o modelo π da linha ilustrado na Figura 2.3.

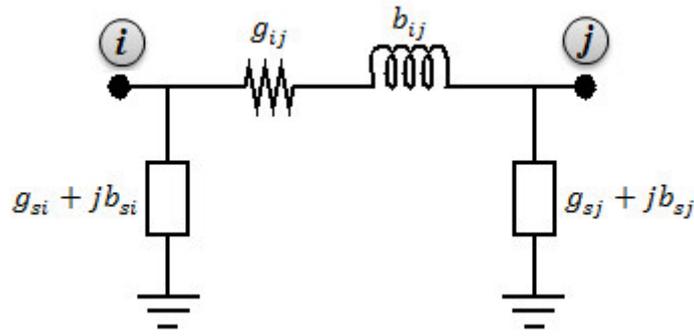


Figura 2.3: Modelo π da linha.

2.5.1 Funções de medição $h(x)$

- Injeções de potência ativa, P_i^{inj} , e reativa, Q_i^{inj} , na barra i :

$$P_i^{inj} = V_i \sum_{j \in \Omega_i} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.14)$$

$$Q_i^{inj} = V_i \sum_{j \in \Omega_i} V_j (G_{ij} \sin \theta_{ij} + B_{ij} \cos \theta_{ij}) \quad (2.15)$$

- Fluxo de potência ativa, P_{ij}^{FP} , e reativa, Q_{ij}^{FP} , da barra i para a barra j :

$$P_{ij}^{FP} = V_i^2 (g_{si} + g_{ij}) - V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (2.16)$$

$$Q_{ij}^{FP} = -V_i^2 (b_{si} + b_{ij}) - V_i V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad (2.17)$$

em que:

V_i e θ_i é a magnitude e a fase da tensão na barra i , respectivamente;

$\theta_{ij} = \theta_i - \theta_j$ é a diferença angular do ramo ij ;

$G_{ij} + jB_{ij}$ é o ij -ésimo elemento da matriz de admitância complexa;

$g_{ij} + jb_{ij}$ é a admitância da linha ij ;

$g_{si} + jb_{si}$ é a admitância do elemento *shunt* conectado na barra i ;

Ω_i é o conjunto de barras que estão diretamente conectadas à barra i .

Os métodos de alocação de medidores basearam-se em uma metodologia que utiliza apenas medições de tensão, injeção e fluxo de potência. Por esta razão, omitiu-se as funções associadas à corrente no ramo ij , assim como da estrutura da matriz Jacobiana $H(x)$. Para maiores detalhes sobre as equações de corrente sugere-se consultar Monticelli (1999) ou Abur e Expósito (2004).

2.5.2 Estrutura da matriz Jacobiana H

A matriz Jacobiana associada às funções de medição tem a seguinte estrutura:

$$H = \begin{bmatrix} \frac{\partial P^{inj}}{\partial \theta} & \frac{\partial P^{inj}}{\partial V} \\ \frac{\partial Q^{inj}}{\partial \theta} & \frac{\partial Q^{inj}}{\partial V} \\ \frac{\partial P^{FP}}{\partial \theta} & \frac{\partial P^{FP}}{\partial V} \\ \frac{\partial Q^{FP}}{\partial \theta} & \frac{\partial Q^{FP}}{\partial V} \\ \frac{\partial P^{mag}}{\partial \theta} & \frac{\partial P^{mag}}{\partial V} \\ 0 & \frac{\partial V^{mag}}{\partial V} \end{bmatrix} \quad (2.18)$$

As expressões para cada partição da matriz H são dadas abaixo:

- Elementos correspondendo a medições de injeção de potência ativa na barra i :

$$\frac{\partial P_i^{inj}}{\partial \theta_i} = -V_i^2 B_{ii} + \sum_{j=1}^N V_i V_j (-G_{ij} \sin \theta_{ij} + B_{ij} \cos \theta_{ij}) \quad (2.19)$$

$$\frac{\partial P_i^{inj}}{\partial \theta_j} = V_i V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2.20)$$

$$\frac{\partial P_i^{inj}}{\partial V_i} = V_i G_{ii} + \sum_{j=1}^N V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.21)$$

$$\frac{\partial P_i^{inj}}{\partial V_j} = V_i (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.22)$$

- Elementos correspondendo a medições de injeção de potência reativa na barra i :

$$\frac{\partial Q_i^{inj}}{\partial \theta_i} = -V_i^2 G_{ii} + \sum_{j=1}^N V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.23)$$

$$\frac{\partial Q_i^{inj}}{\partial \theta_j} = -V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.24)$$

$$\frac{\partial Q_i^{inj}}{\partial V_i} = -V_i B_{ii} + \sum_{j=1}^N V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2.25)$$

$$\frac{\partial Q_i^{inj}}{\partial V_j} = V_i (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2.26)$$

- Elementos correspondendo a medições de fluxo de potência ativa no ramo ij :

$$\frac{\partial P_{ij}^{FP}}{\partial \theta_i} = V_i V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad (2.27)$$

$$\frac{\partial P_{ij}^{FP}}{\partial \theta_j} = -V_i V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad (2.28)$$

$$\frac{\partial P_{ij}^{FP}}{\partial V_i} = -V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) + 2V_i (b_{ij} + b_{si}) \quad (2.29)$$

$$\frac{\partial P_{ij}^{FP}}{\partial V_j} = -V_i (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (2.30)$$

- Elementos correspondendo a medições de fluxo de potência reativa no ramo ij :

$$\frac{\partial Q_{ij}^{FP}}{\partial \theta_i} = -V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (2.31)$$

$$\frac{\partial Q_{ij}^{FP}}{\partial \theta_j} = V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij}) \quad (2.32)$$

$$\frac{\partial Q_{ij}^{FP}}{\partial V_i} = -V_j (g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) - 2V_i (b_{ij} + b_{si}) \quad (2.33)$$

$$\frac{\partial Q_{ij}^{FP}}{\partial V_j} = -V_i(g_{ij} \sin \theta_{ij} - b_{ij} \cos \theta_{ij}) \quad (2.34)$$

- Elementos correspondendo a medições de magnitude de tensão na barra i :

$$\frac{\partial V_i^{mag}}{\partial \theta_i} = 0 \quad (2.35)$$

$$\frac{\partial V_i^{mag}}{\partial \theta_j} = 0 \quad (2.36)$$

$$\frac{\partial V_i^{mag}}{\partial V_i} = 1 \quad (2.37)$$

$$\frac{\partial V_i^{mag}}{\partial V_j} = 0 \quad (2.38)$$

ESTIMAÇÃO DE ESTADO COM MEDIÇÕES CORRELACIONADAS

3.1 Introdução

O capítulo anterior abordou a técnica de estimação de estado via MQP através da metodologia tradicional, ou seja, sem o uso da correlação entre diferentes medições ou pseudo-medições. Essa abordagem simplifica a formulação e solução do problema, mas não é coerente com aspectos práticos de medição de grandezas elétricas. Por exemplo, as medições de fluxo ou injeção de potência ativa e reativa são realizadas por um único medidor que estima estas grandezas a partir de um mesmo conjunto de transformadores de corrente e potencial. Desta forma, os erros na medição de potência ativa tendem a ser fortemente correlacionados com os da potência reativa. Em situações práticas, quando há um problema no medidor, tanto a medição de potência ativa como a medição de potência reativa são afetadas. Portanto, não faz sentido utilizar medições descorrelacionadas na estimação de estado.

Nos últimos anos tem-se observado uma gama de trabalhos sobre EERD ou em outros estudos de sistemas de potência que incluem a correlação nas medições. A necessidade de incluir modelos estocásticos para a geração e demanda na EERD foi inicialmente estudada por Ghosh e outros (1997). Neste estudo, os autores analisaram o efeito da correlação entre as medições de injeção de potência. Caro, Conejo e Mínguez (2009) demonstraram que a correlação entre diferentes medições forneciam resultados mais precisos para a estimação de estado via MQP. A possibilidade de incluir uma correlação entre diferentes cargas, geradores, entre a velocidade do vento e a potência de saída de geradores eólicos e entre a injeção de potência ativa e reativa foi investigada por Valverde, Saric e Terzija (2013) em um estudo sobre medições portadoras de erros grosseiros e fluxo de potência estocástico. Muscas et al. (2013) conseguiram resultados satisfatórios quando investigaram a correlação entre as variáveis de entrada na precisão de um EERD baseado na corrente nos ramos, incluindo Unidades de Medição Fasorial

(“PMUs – Phasor Measurement Units”). Por fim, Caro et al.(2011) obtiveram bons resultados incluindo a correlação entre medições para identificar medições portadoras de erros grosseiros.

Segundo a revisão bibliográfica, a inclusão da correlação entre variáveis de entrada do estimador de estado tem melhorado a precisão dos resultados. Portanto, é necessária uma modelagem estatística mais precisa da correlação entre variáveis de entrada do que aquela apresentada no capítulo 2. Desta forma, nas próximas seções serão apresentados os conceitos básicos de estatística multivariada que serão usados na modelagem de medições correlacionadas.

3.2 Conceitos Básicos sobre Estatística Multivariada

O propósito desta seção é introduzir algumas notações e conceitos sobre vetores aleatórios, matrizes de covariância, transformações lineares de um vetor aleatório, estimação de parâmetros em distribuições multivariadas, bem como distribuições de probabilidade multivariadas. Não se faz aqui a menção de demonstrar resultados algébricos, mas sim mostrar como os conceitos de estatística multivariada são aplicados na estimação de estado com correlação nas medições. Para uma leitura mais rigorosa sobre estatística multivariada indica-se Mingoti (2006), L.-Garcia (2008), Ross (2010) ou Miller e Childers (2012).

3.2.1 Principais definições

Definição 1: Vetor aleatório. *Seja X um vetor contendo n componentes, onde cada componente é uma variável aleatória, isto é, X_i é uma variável aleatória, $\forall i = 1, 2, \dots, n$. Então, X é chamado de vetor aleatório e é denotado por:*

$$X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} = [X_1, X_2, \dots, X_n]^T$$

De posse de um vetor aleatório, cada variável pode ser analisada separadamente através do comportamento de sua distribuição de probabilidade. Entretanto, é importante analisar o vetor como um todo, visto que pode ocorrer correlação entre as n variáveis.

Definição 2: Vetor de médias. *Seja X um vetor aleatório. O vetor $m_X = E[X]$ é chamado de vetor de médias do vetor $[X_1, X_2, \dots, X_n]^T$, sendo:*

$$m_X = E[X] = E \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} \triangleq \begin{bmatrix} E[X_1] \\ E[X_2] \\ \vdots \\ E[X_n] \end{bmatrix} = \begin{bmatrix} m_1 \\ m_2 \\ \vdots \\ m_n \end{bmatrix}$$

em que m_i denota a média (ou esperança) da variável aleatória X_i . A média m_i é uma das medidas mais utilizadas para sintetizar a informação de tendência central da distribuição de valores da variável X_i .

Definição 3: Variância. *A variância do i -ésimo componente do vetor X é denotada por $Var(X_i) = \sigma_i^2 = \sigma_{ii}$. O desvio padrão é denotado por σ_i ou $\sqrt{\sigma_{ii}}$ e fornece a informação sobre a disposição dos valores da variável X_i em relação a m_i , ou seja, indica se os valores de X_i estão próximos ou distantes da média m_i . Deste modo, valores grandes de σ_i indicam uma maior dispersão de valores em relação à média da distribuição.*

Definição 4: Covariância. *A covariância entre os valores da i -ésima e j -ésima variáveis do vetor X é definida através da expressão (3.1):*

$$Cov(X_i, X_j) = \sigma_{ij} = E[(X_i - m_i)(X_j - m_j)] \quad (3.1)$$

Quando $i = j$, a expressão (3.1) torna-se a variância da variável X_i . A covariância indica o grau de relacionamento linear entre duas variáveis aleatórias. No entanto, é difícil julgar se essa relação é forte ou não observando-se apenas o seu valor numérico, uma vez que não se tem um valor de referência mínimo ou máximo para comparação dos valores σ_{ij} . Assim, uma medida mais útil na prática é a correlação que será definida posteriormente.

Em geral, quando se têm muitas variáveis, o procedimento mais comum é obter os valores de σ_{ij} através da chamada matriz de covariâncias.

Definição 5: Matriz de covariância. A matriz de covariância do vetor aleatório X é denotada pela expressão (3.2):

$$\begin{aligned}
 C_{XX} &= \begin{bmatrix} E[(X_1 - m_1)^2] & E[(X_1 - m_1)(X_2 - m_2)] & \cdots & E[(X_1 - m_1)(X_n - m_n)] \\ E[(X_2 - m_2)(X_1 - m_1)] & E[(X_2 - m_2)^2] & \cdots & E[(X_2 - m_2)(X_n - m_n)] \\ \vdots & \vdots & \ddots & \vdots \\ E[(X_n - m_n)(X_1 - m_1)] & E[(X_n - m_n)(X_2 - m_2)] & \cdots & E[(X_n - m_n)^2] \end{bmatrix} \\
 &= \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_{nn} \end{bmatrix}
 \end{aligned} \tag{3.2}$$

Definição 6: Correlação. O coeficiente de correlação entre as i -ésima e j -ésima variáveis do vetor X é definido por:

$$\rho_{ij} = \frac{\sigma_{ij}}{\sqrt{\sigma_{ii}\sigma_{jj}}} = \frac{\sigma_{ij}}{\sigma_i\sigma_j} \tag{3.3}$$

sendo que $-1 \leq \rho_{ij} \leq 1$, $\forall i, j = 1, 2, \dots, n$. Quando $i = j$, a expressão (3.3) torna-se igual a 1. A correlação é uma medida mais adequada para avaliar o grau de relacionamento linear entre duas variáveis quantitativas do que a covariância, pois seus valores estão sempre entre os valores de referência -1 e 1 . Deste modo, quanto mais próximo de 1 , mais indicação se tem de que existe um relacionamento linear positivo entre as variáveis X_i e X_j e quanto mais próximo de -1 , mais indicação se tem de que existe um relacionamento linear negativo. Uma correlação próxima de zero indica uma desconexão entre as variáveis em questão. Quando se têm muitas variáveis, o procedimento mais comum é armazenar os valores de ρ_{ij} em uma matriz chamada matriz de correlação.

Definição 7: Matriz de correlação. A matriz de correlação do vetor aleatório X é dada por (3.4).

$$\begin{aligned}
 R_{XX} &= \begin{bmatrix} E[X_1^2] & E[X_1X_2] & \cdots & E[X_1X_n] \\ E[X_2X_1] & E[X_2^2] & \cdots & E[X_2X_n] \\ \vdots & \vdots & \ddots & \vdots \\ E[X_nX_1] & E[X_nX_2] & \cdots & E[X_n^2] \end{bmatrix} \\
 &= \begin{bmatrix} 1 & \rho_{12} & \cdots & \rho_{1n} \\ \rho_{21} & 1 & \cdots & \rho_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{n1} & \rho_{n2} & \cdots & 1 \end{bmatrix}
 \end{aligned} \tag{3.4}$$

Ambas R_{XX} e C_{XX} são matrizes $n \times n$ simétricas e positivas definidas. Se o vetor de valores esperados é nulo, isto é, $m_i = E[X_i] = 0, \forall i = 1, 2, \dots, n$, então $R_{XX} = C_{XX}$. Os elementos da diagonal de C_{XX} são obtidos através das variâncias $Var(X_i) = E[(X_i - m_i)^2]$ dos elementos de X . Se esses elementos são descorrelacionados, então $Cov(X_i, X_j) = \rho_{ij} = 0$ para $i \neq j$, e C_{XX} é uma matriz diagonal. É o caso dos estimadores que trabalham com a hipótese das medições serem descorrelacionadas (R_z é diagonal). Adicionalmente, se as variáveis aleatórias X_1, \dots, X_n são independentes, então elas são descorrelacionadas e C_{XX} é diagonal.

Em notação matricial os resultados obtidos pelas expressões (3.2) e (3.4) podem ser obtidos segundo as relações $R_{XX} = E[XX^T]$ e $C_{XX} = E[(X - m_X)(X - m_X)^T] = R_{XX} - m_X m_X^T$.

A Figura 3.1 ilustra o comportamento, em geral, dos gráficos de dispersão quando se tem correlação entre variáveis.

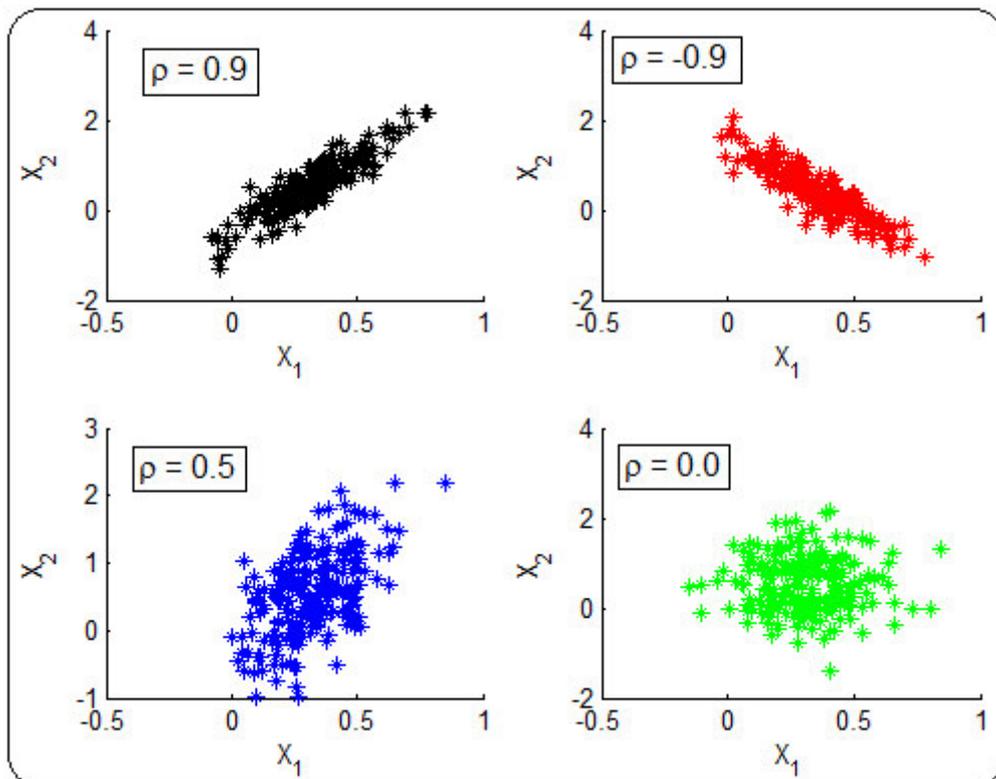


Figura 3.1: Diagrama de dispersão segundo o grau de correlação entre as variáveis.

$$\bar{X}_i = \frac{1}{m} \sum_{k=1}^m X_{ki}^{DATA}, \quad \forall i = 1, \dots, n \quad (3.6)$$

Cada elemento do vetor de médias amostrais \bar{X} representa a média amostral da i -ésima variável, $i = 1, 2, \dots, n$. A matriz de covariância C_{XX} é estimada pela matriz de covariância amostral COV^{AM} definida por:

$$COV^{AM} = \begin{bmatrix} S_{11} & S_{12} & \cdots & S_{1n} \\ S_{21} & S_{22} & \cdots & S_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ S_{n1} & S_{n2} & \cdots & S_{nn} \end{bmatrix} \quad (3.7)$$

sendo que:

$$COV_{ij}^{AM} = S_{ij} = \frac{1}{n-1} \sum_{k=1}^m (X_{ki} - \bar{X}_i)(X_{kj} - \bar{X}_j), \quad \forall i, j = 1, \dots, n \quad (3.8)$$

Cada elemento da matriz de covariância amostral COV^{AM} representa a covariância amostral entre a i -ésima e a j -ésima variável. A matriz de correlação teórica R_{XX} é estimada pela matriz de correlação amostral $CORR^{AM}$ definida por:

$$CORR^{AM} = \begin{bmatrix} R_{11} & R_{12} & \cdots & R_{1n} \\ R_{21} & R_{22} & \cdots & R_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ R_{n1} & R_{n2} & \cdots & R_{nn} \end{bmatrix} = \begin{bmatrix} 1 & R_{12} & \cdots & R_{1n} \\ R_{21} & 1 & \cdots & R_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ R_{n1} & R_{n2} & \cdots & 1 \end{bmatrix} \quad (3.9)$$

sendo que:

$$R_{ij} = \frac{S_{ij}}{\sqrt{S_{ii}S_{jj}}}, \quad \forall i, j = 1, \dots, n \quad (3.10)$$

é o coeficiente de correlação amostral entre a i -ésima e a j -ésima variável, conhecido como coeficiente de correlação de Pearson (Mingoti 2006).

Como resultado prático, deve-se encontrar a correlação entre a demanda de potência ativa e reativa medidas na subestação do sistema teste de distribuição de 95 barras denominado por UKGDS (Singh, Pal e Vinter, 2009). Os dados de medição, supostamente tomados de 30 em 30 minutos, compõem um total de 17520 amostras e estão disponíveis na referência (Singh, Pal e Vinter, 2009). A partir desses dados, a curva de carga do sistema é apresentada na Figura 3.2.

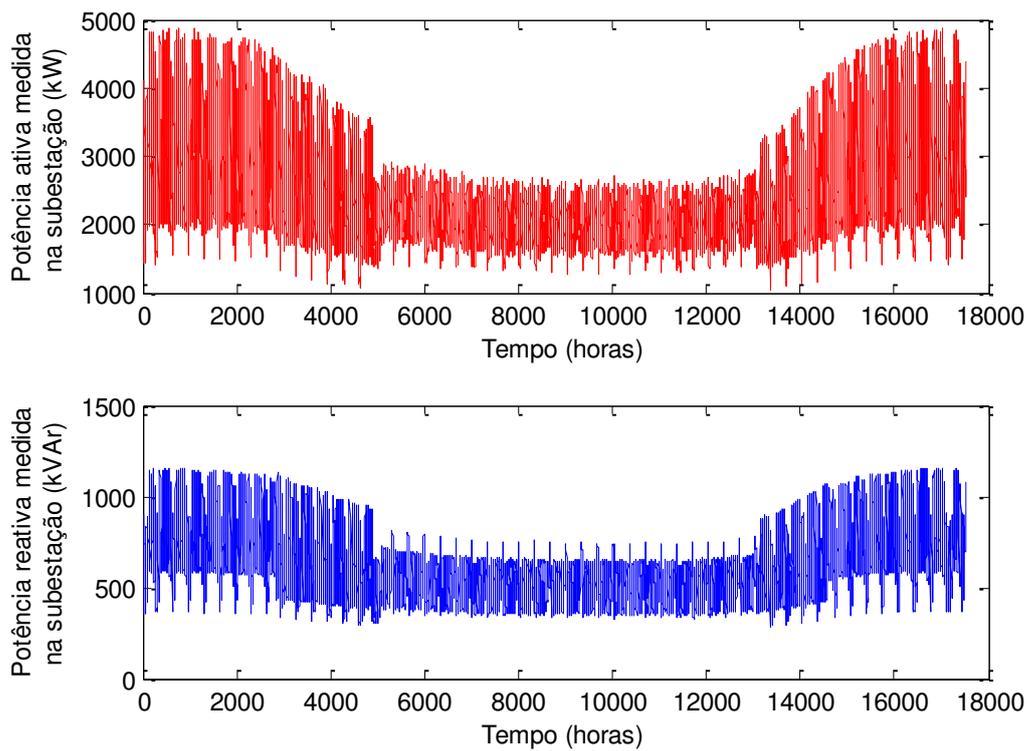


Figura 3.2: Curva de carga do sistema teste UKGDS.

A Figura 3.3 ilustra o gráfico de dispersão entre a demanda de potência ativa e reativa da amostra de medições. A partir dos dados, foi possível obter um coeficiente de correlação amostral $R_{PQ} = 0,9461$. Este valor indica uma relação praticamente linear entre a medição de demanda ativa e reativa. Como já foi mencionado, este fato se deve a medição de potência ativa ou reativa ser realizada por apenas um medidor.

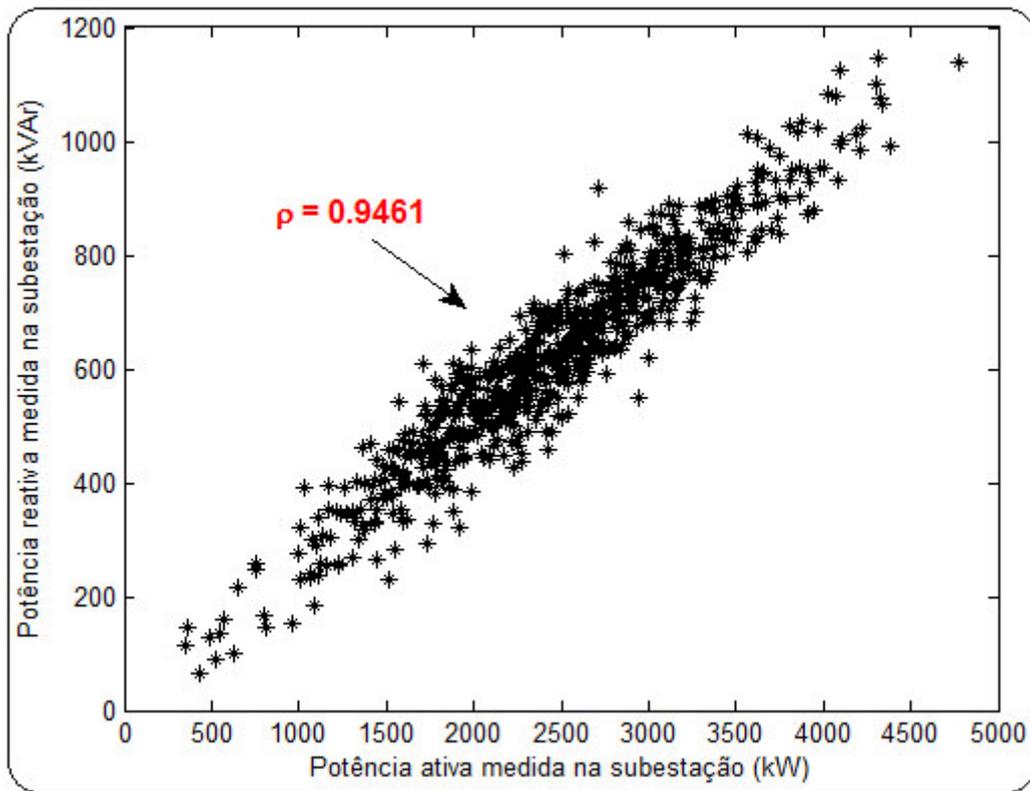


Figura 3.3: Diagrama de dispersão entre a demanda de potência ativa e reativa.

3.2.3 Distribuições de probabilidades multivariadas

Todo vetor aleatório n -variado tem seus valores gerados por um mecanismo probabilístico. Existe uma gama de distribuições de probabilidades multivariadas, mas sem dúvida, a mais conhecida é a normal (*gaussiana*) multivariada. A distribuição normal multivariada é uma generalização da normal univariada para o caso no qual se trabalha com duas ou mais variáveis aleatórias simultaneamente. A distribuição normal univariada com média μ e variância σ^2 tem a função densidade de probabilidade (“PDF – Probability Density Function”) dada por:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (3.11)$$

onde $-\infty < x < \infty$, $\mu \in (-\infty; \infty)$ e $\sigma > 0$. A forma padronizada da PDF definida em (3.11) é ilustrada na Figura 3.4.

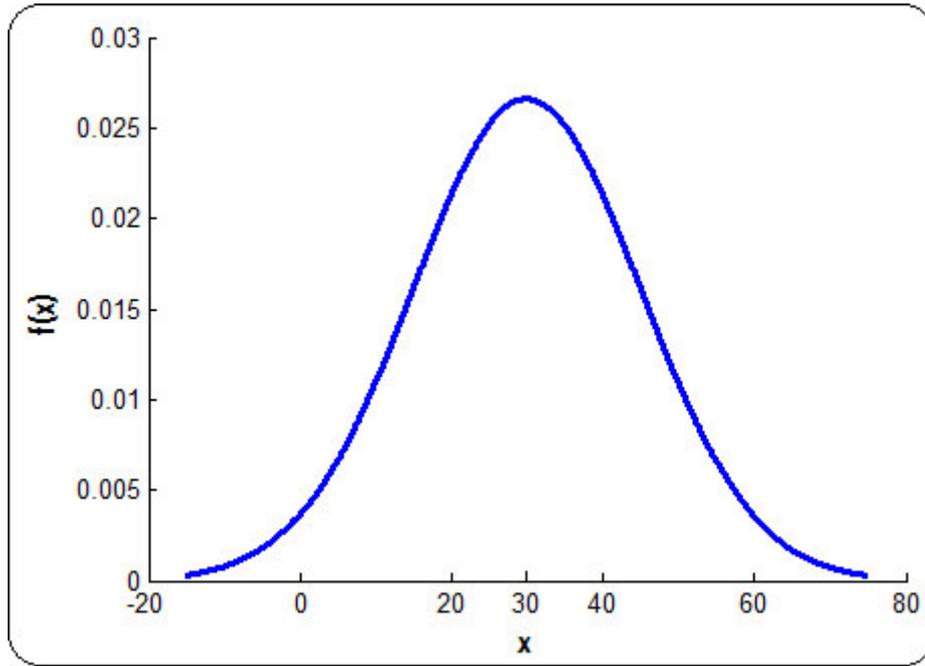


Figura 3.4: PDF de uma distribuição normal com média 30 e desvio padrão 15.

Um caso especial ocorre quando $\mu = 0$ e $\sigma = 1$. Uma distribuição normal com esta característica é denominada *distribuição normal (univariada) padronizada*. No caso de um vetor aleatório de dimensão n , ou seja, $X = [X_1 \ X_2 \ \dots \ X_n]^T$, diz-se que este vetor tem uma distribuição normal n -variada, e denota-se por $X \sim \mathcal{N}(m_X, C_{XX})$ (X tem distribuição normal multivariada com média m_X e matriz de covariância C_{XX}), se a PDF de X for dada por:

$$f_X(x) = \frac{1}{\sqrt{(2\pi)^n |C_{XX}|}} \exp \left[-\frac{1}{2} (x - m_X)^T C_{XX}^{-1} (x - m_X) \right] \quad (3.12)$$

para todo vetor $x \in \mathcal{R}^n$, em que $x = [x_1 \ x_2 \ \dots \ x_n]^T$, $-\infty < x_i < \infty$; $i = 1, 2, \dots, n$; $m_X \in \mathcal{R}^n$ e C_{XX} é definida positiva.

A quantidade $(x - m_X)^T C_{XX}^{-1} (x - m_X)$ é referida como a distância de Mahalanobis do vetor x ao vetor de médias m_X . Ela também é denominada de distância padronizada ou distância estatística (Mingoti 2006). Assim como no caso univariado, denominamos de *distribuição normal (multivariada) padronizada* quando $m_X = 0$ e $C_{XX} = I$.

Quando $n = 2$, tem-se a *distribuição normal (gaussiana) bivariada*. Considera-se o vetor de médias m_X e a matriz de covariância C_{XX} dados por:

$$m_X = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \text{ e } C_{XX} = \begin{bmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix}$$

Neste caso, a PDF do vetor $X = [X_1 \ X_2]^T$ é dada por:

$$f_{X_1, X_2}(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp \left[-\frac{\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)\left(\frac{x_2-\mu_2}{\sigma_2}\right) + \left(\frac{x_2-\mu_2}{\sigma_2}\right)^2}{2(1-\rho^2)} \right] \quad (3.13)$$

Quando $\rho = 0$, função $f_{X_1, X_2}(x_1, x_2)$ definida em (3.13) é o produto de duas densidades normais univariadas. Portanto, as variáveis X_1 e X_2 são independentes, ou seja, $f_{X_1, X_2}(x_1, x_2) = g(x_1) \cdot h(x_2)$, no qual

$$g(x_1) = \frac{1}{\sqrt{2\pi}\sigma_1} \exp \left[-\frac{1}{2} \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 \right]$$

$$h(x_2) = \frac{1}{\sqrt{2\pi}\sigma_2} \exp \left[-\frac{1}{2} \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right]$$

Por conseguinte, no caso da distribuição normal bivariada, se X_1 e X_2 forem não correlacionadas também serão independentes. A Figura 3.5 mostra alguns gráficos genéricos da distribuição normal bivariada. Todos os gráficos foram gerados com os mesmos valores do vetor de médias e matriz de covariância, exceto pela mudança do coeficiente de correlação ρ . Na Figura 3.6 têm-se as curvas de nível associadas a cada PDF da normal bivariada, assim como os respectivos gráficos de dispersão. A partir da Figura 3.6 pode-se perceber que quando há correlação entre duas distribuições normais as curvas de nível da PDF definida em (3.13) são elipses inclinadas (rotacionadas) em relação à origem; quanto maior for a correlação entre as variáveis aleatórias maior será a inclinação das curvas de nível; quanto menor for a correlação entre as variáveis aleatórias menor será a inclinação das curvas de nível, e; quando não há correlação, as curvas de nível são circunferências.

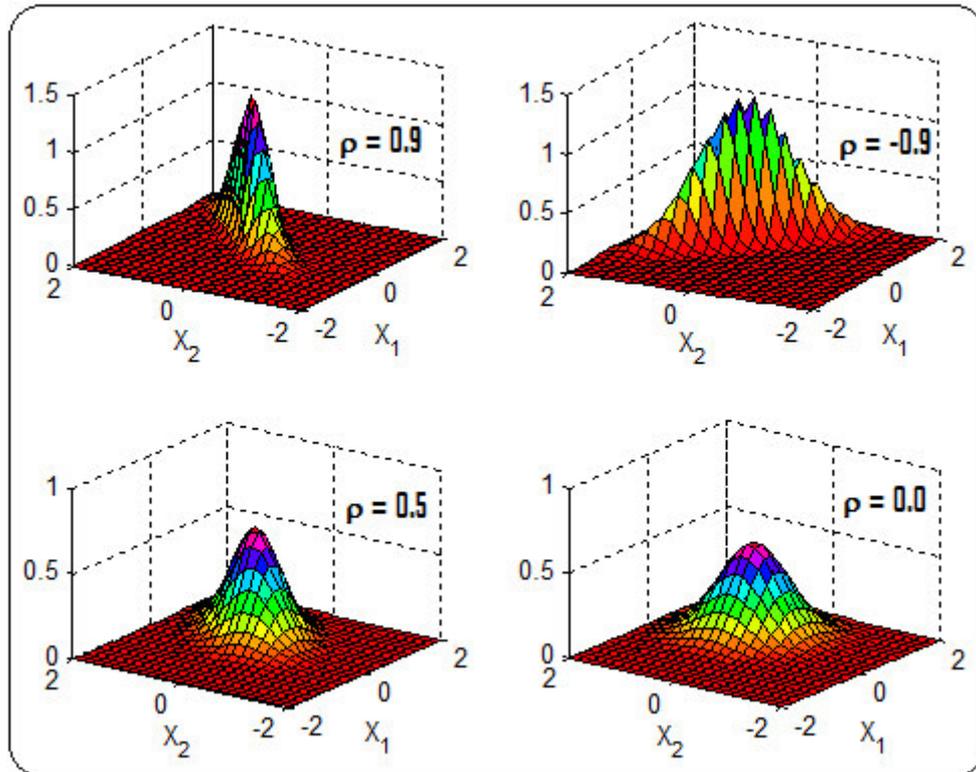


Figura 3.5: PDFs de uma distribuição normal bivariada.

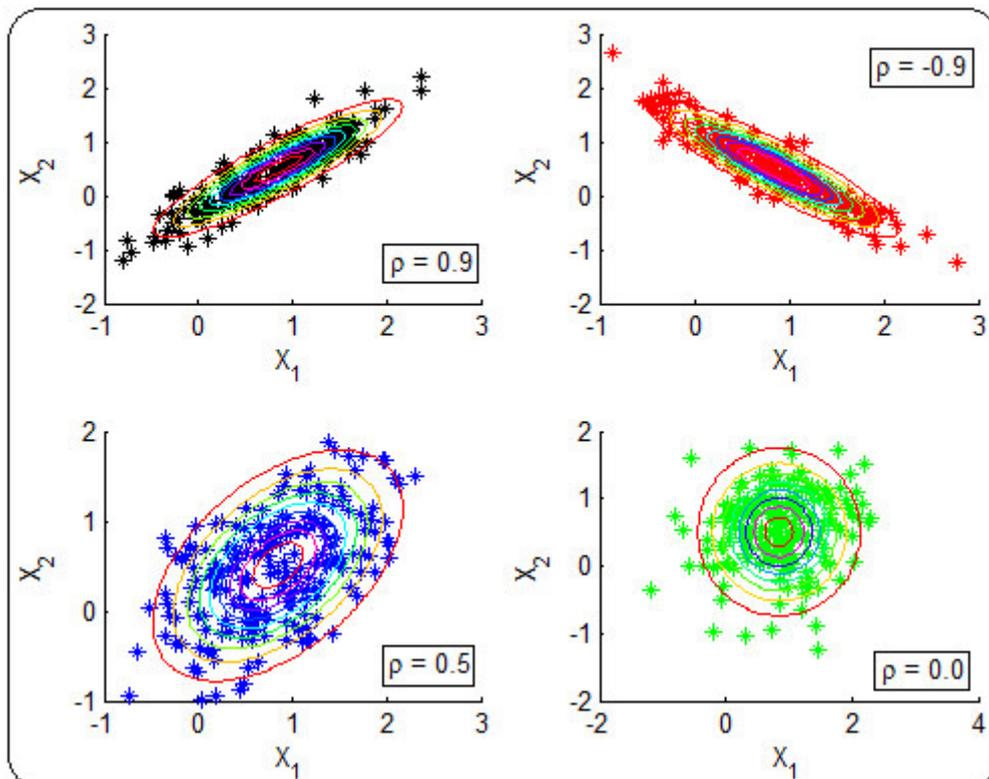


Figura 3.6: Diagrama de dispersão e as curvas de nível da PDF bivariada, ilustrada na Figura 3.5, segundo o grau de correlação entre as variáveis.

3.2.4 Transformação linear de vetores aleatórios

Muitos sistemas em engenharia podem ser representados por uma transformação linear de um vetor de variáveis aleatórias em que a *entrada* é o vetor X e a *saída* é o vetor Y . Nesta dissertação, o interesse em transformações lineares é devido ao fato de que a função objetivo do problema de alocação de medidores é calculada usando a linearização do vetor de estado estimado via expansão de Taylor. Esta transformação linear tem como vetor de entrada os erros nas medições e como vetor de saída o vetor de estado estimado. Visto que a função objetivo do problema de alocação requer a distribuição de probabilidade do vetor de estado estimado, é necessário desenvolver uma metodologia para determinar as distribuições de probabilidade das variáveis de saída de transformações lineares de vetores aleatórios.

Dada uma matriz A de dimensão $m \times n$ e um vetor coluna $b = [b_1, b_2, \dots, b_m]^T$, a transformação linear de n variáveis aleatórias em m variáveis aleatórias é dada em (3.14):

$$\begin{aligned} Y_1 &= a_{11}X_1 + a_{12}X_2 + \dots + a_{1n}X_n + b_1 \\ Y_2 &= a_{21}X_1 + a_{22}X_2 + \dots + a_{2n}X_n + b_2 \\ &\vdots \\ Y_m &= a_{m1}X_1 + a_{m2}X_2 + \dots + a_{mn}X_n + b_m \end{aligned} \quad (3.14)$$

Na equação acima, cada $a_{ij} \in A$, com $i = 1, \dots, m$ e $j = 1, \dots, n$. Em notação matricial (3.14) é escrita como $Y = AX + b$. A equação (3.14) nos diz que como $X \sim \mathcal{N}(m_X, C_{XX})$, então $Y \sim \mathcal{N}(m_Y, C_{YY})$. Isso significa que Y tem distribuição normal multivariada com média m_Y e matriz de covariância C_{YY} . A média de Y está relacionada com a média de X segundo (3.15):

$$m_Y = E[Y] = E[AX + b] = A \cdot E[X] + b = Am_X + b \quad (3.15)$$

O valor esperado do k -ésimo elemento de Y é o produto interno da k -ésima linha de A com o vetor X mais o k -ésimo elemento de b :

$$E[Y_k] = E \left[\sum_{j=1}^n a_{kj}X_j \right] + b_k = b_k + \sum_{j=1}^n a_{kj}E[X_j] \quad (3.16)$$

Um caso especial ocorre *quando o vetor X tem média zero*. Deste modo:

$$m_Y = b \quad (3.17)$$

$$E[Y_k] = b_k \quad (3.18)$$

A matriz de covariância de Y é dada por:

$$\begin{aligned} C_{YY} &= E[(Y - m_Y)(Y - m_Y)^T] = E\{[A(X - m_X)][A(X - m_X)]^T\} \\ &= E[A(X - m_X)(X - m_X)^T A^T] = AE[(X - m_X)(X - m_X)^T]A^T \\ &= AC_{XX}A^T \end{aligned} \quad (3.19)$$

Supondo-se que os componentes de X sejam descorrelacionados e tenham $\sigma = 1$, tem-se que $C_{XX} = I$. Neste caso, a matriz de covariância C_{YY} é dada por:

$$C_{YY} = AC_{XX}A^T = AIA^T = AA^T \quad (3.20)$$

E a variância do k -ésimo elemento de Y é dada por:

$$Var[Y_k] = \sum_{j=1}^n a_{kj}^2 \quad (3.21)$$

Como será visto posteriormente no capítulo 5, as equações (3.17), (3.18), (3.20) e (3.21) são fundamentais para a metodologia proposta de alocação de medidores em redes de distribuição com medições correlacionadas.

3.3 Métodos para Descorrelacionar Variáveis Aleatórias Gaussianas

A função objetivo do problema de alocação de medidores é um índice probabilístico dependente da distribuição de probabilidade do vetor de estado estimado. Se os vetores de medições são correlacionados, então as distribuições de probabilidade do vetor de estado também serão correlacionadas. Este fato torna o cálculo da função objetivo mais complexo. Uma alternativa para eliminar esta dificuldade é obter uma transformação linear descorrelacionada que é equivalente ao vetor de medições correlacionado original. Desta forma, a função objetivo do problema de alocação de medidores pode ser estimada usando combinações lineares de variáveis aleatórias descorrelacionadas. Na verdade, são usadas duas transformações lineares: a primeira é obtida através da linearização do vetor de estado via série de Taylor e a segunda está

associada com o decorrelacionamento do vetor de medições. A linearização do vetor de estado via expansão de Taylor estabelecerá uma relação de sensibilidade linear entre o vetor de estado estimado e o vetor de medições. Devido a isso, a transformação linear de decorrelacionamento de medições será substituída na expansão de Taylor do vetor de estado para obter uma relação linear e decorrelacionada entre o estado e o vetor de medições. Desta forma, nesta seção será mostrado como combinações lineares de variáveis aleatórias correlacionadas são convertidas em combinações lineares de variáveis aleatórias decorrelacionadas.

3.3.1 Método de decomposição de Cholesky para decorrelacionar variáveis aleatórias gaussianas

O primeiro método para conversão de uma transformação linear correlacionada em uma transformação linear decorrelacionada é o método da decomposição de Cholesky da matriz de covariância \tilde{C}_{XX} .

Considera-se a transformação linear dada por (3.22):

$$Y = AX + B \quad (3.22)$$

em que X é um vetor normalmente distribuído com média \bar{X} e matriz de covariância \tilde{C}_{XX} . A transformação linear equivalente decorrelacionada associada a Y é obtida expressando-se o vetor X como uma função linear de um vetor gaussiano padronizado e decorrelacionado como se segue (Billinton e Li 1994; Li 2011):

$$X = DZ + \bar{X} \quad (3.23)$$

em que:

Z é um vetor de variáveis aleatórias gaussianas decorrelacionadas e padronizadas ($Z \sim \mathcal{N}(0, I)$);

D é a matriz triangular inferior da decomposição de Cholesky da matriz \tilde{C}_{XX} ($\tilde{C}_{XX} = DD^T$).

Substituindo-se (3.23) em (3.22), tem-se:

$$\begin{aligned}
Y &= AX + B \\
&= A(DZ + \bar{X}) + B \\
&= (AD)Z + (A\bar{X} + B) \\
&= A'Z + \bar{Y}'
\end{aligned} \tag{3.24}$$

em que $A' = AD$ e $\bar{Y}' = A\bar{X} + B$.

Desta forma, a média e a variância de cada componente de Y são dadas por:

$$E[Y_k] = \bar{Y}'_k = \sum_{j=1}^n a_{kj} \bar{X}_j + b_k = b_k + \sum_{j=1}^n a_{kj} E[X_j] \tag{3.25}$$

$$Var[Y_k] = \sum_{j=1}^n (a'_{kj})^2 \tag{3.26}$$

3.3.2 Método de decomposição em autovalores e autovetores para decorrelacionar variáveis aleatórias gaussianas

O segundo método para conversão de uma transformação linear correlacionada em uma transformação linear decorrelacionada é o método da decomposição em autovalores e autovetores da matriz de covariância \tilde{C}_{XX} .

Considerando-se a transformação linear (3.22), a transformação linear equivalente decorrelacionada associada a Y é obtida expressando-se o vetor X como uma função linear de um vetor gaussiano padronizado e decorrelacionado como se segue (L.-Garcia 2008; Miller e Childers 2012):

$$X = Q\sqrt{\Lambda}Z + \bar{X} \tag{3.27}$$

em que:

Z é um vetor de variáveis aleatórias gaussianas decorrelacionadas e padronizadas ($Z \sim \mathcal{N}(0, I)$);

Q é uma matriz ortogonal onde cada coluna está associada com um autovetor de \tilde{C}_{XX} ($\tilde{C}_{XX} = Q\Lambda Q^T$, pois \tilde{C}_{XX} é simétrica);

$\sqrt{\Lambda}$ é uma matriz diagonal associada com os autovalores de \tilde{C}_{XX} , ou seja, $\sqrt{\Lambda_{ii}} = \lambda_i$ é o i -ésimo autovalor de \tilde{C}_{XX} .

$\Sigma^{IP,k}$ é a matriz de covariância 2×2 associada com o k -ésimo medidor de injeções de potência ativa e reativa;

N_{IP} é o número de medidores de injeção de potência;

$$\Sigma_{11}^{IP,k} = (\sigma_{pp}^{IP,k})^2;$$

$$\Sigma_{22}^{IP,k} = (\sigma_{qq}^{IP,k})^2;$$

$$\Sigma_{12}^{IP,k} = \Sigma_{21}^{IP,k} = \rho_{pq}^{IP,k} \sigma_{pp}^{IP,k} \sigma_{qq}^{IP,k};$$

$\sigma_{pp}^{IP,k}$ e $\sigma_{qq}^{IP,k}$ são os desvios padrões associados com as medições de injeção de potência ativa e reativa no k -ésimo medidor de injeção de potência, respectivamente;

$\rho_{pq}^{IP,k}$ é o coeficiente de correlação associado com as medições de potência ativa e reativa no k -ésimo medidor de injeção de potência;

$$\Sigma^{FP,k} = \begin{bmatrix} \Sigma_{11}^{FP,k} & \Sigma_{12}^{FP,k} \\ \Sigma_{21}^{FP,k} & \Sigma_{22}^{FP,k} \end{bmatrix} \text{ para } k = 1, \dots, N_{FP};$$

$\Sigma^{FP,k}$ é a matriz de covariância 2×2 associada com o k -ésimo medidor de fluxos de potência ativa e reativa;

N_{FP} é o número de medidores de fluxo de potência;

$$\Sigma_{11}^{FP,k} = (\sigma_{pp}^{FP,k})^2;$$

$$\Sigma_{22}^{FP,k} = (\sigma_{qq}^{FP,k})^2;$$

$$\Sigma_{12}^{FP,k} = \Sigma_{21}^{FP,k} = \rho_{pq}^{FP,k} \sigma_{pp}^{FP,k} \sigma_{qq}^{FP,k};$$

$\sigma_{pp}^{FP,k}$ e $\sigma_{qq}^{FP,k}$ são os desvios padrões associados com as medições de fluxo de potência ativa e reativa no k -ésimo medidor de fluxo de potência, respectivamente;

$\rho_{pq}^{FP,k}$ é o coeficiente de correlação associado com as medições de potência ativa e reativa no k -ésimo medidor de fluxo de potência;

σ_k^V para $k = 1, \dots, N_V$ é o desvio padrão do k -ésimo medidor de magnitude das tensões

N_V é número de medidores de magnitudes das tensões;

A inversa de uma matriz diagonal por blocos é a inversa dos blocos que compõem a matriz. Para o problema analisado nesta dissertação, tem-se apenas blocos

de dimensão 2×2 , formados pelas medições de injeção/fluxo de potência ativa e reativa, e blocos 1×1 , formados por medições de magnitude de tensão. Deste modo, W^{corr} fica completamente definida pela inversão por blocos de R_z^{corr} . W^{corr} , então, terá a mesma estrutura de R_z^{corr} .

No algoritmo proposto na seção 2.4 precisa-se da decomposição de Cholesky de W . A decomposição de Cholesky de uma matriz diagonal por blocos é a decomposição de Cholesky dos blocos que compõem a matriz. Assim, a decomposição de Cholesky de W^{corr} fica completamente definida pela decomposição de Cholesky por blocos de W^{corr} .

Em resumo, cada iteração da estimação de estado via MQP utilizando a decomposição QR, com medições correlacionadas, consiste nos seguintes passos:

Passo #1: Determinar a estrutura da matriz Jacobiana $H(x)$;

Passo #2: Obter a matriz W^{corr} a partir da inversão por blocos da matriz de covariância de erros de medição R_z^{corr} ;

Passo #3: Obter a decomposição de Cholesky por blocos da matriz W^{corr} ($W = DD^T$);

Passo #4: Arbitrar uma estimativa inicial para o vetor de estados $\hat{x}^{(0)}$;

$k = 0$;

Passo #5: Calcular os valores numéricos de $\tilde{H} = D^T H(\hat{x}^{(k)})$ e $\Delta\tilde{z} = D^T [z - h(\hat{x}^{(k)})]$;

Passo #6: Fatorar a matriz $\tilde{H} = QR$;

Passo #7: Atribuir $\Delta z_q = Q^T \Delta\tilde{z}$ e resolver o sistema linear $R\Delta x^{(k)} = \Delta z_q$ por substituição regressiva;

Passo #8: Verificar a convergência: se $\max|\Delta x^{(k)}| \leq \epsilon$ (em geral $\epsilon = 10^{-4} pu$), parar o processo iterativo, caso contrário, atualizar o vetor de estados $\hat{x}^{(k+1)} = \hat{x}^{(k)} + \Delta x^{(k)}$.

Passo #9: Fazer $k = k + 1$. Se $k > N_{iter}$ (N_{iter} é o máximo número de iterações), parar o processo iterativo, caso contrário, voltar ao passo #5.

Os passos anteriores foram ilustrados no fluxograma da Figura 3.7.

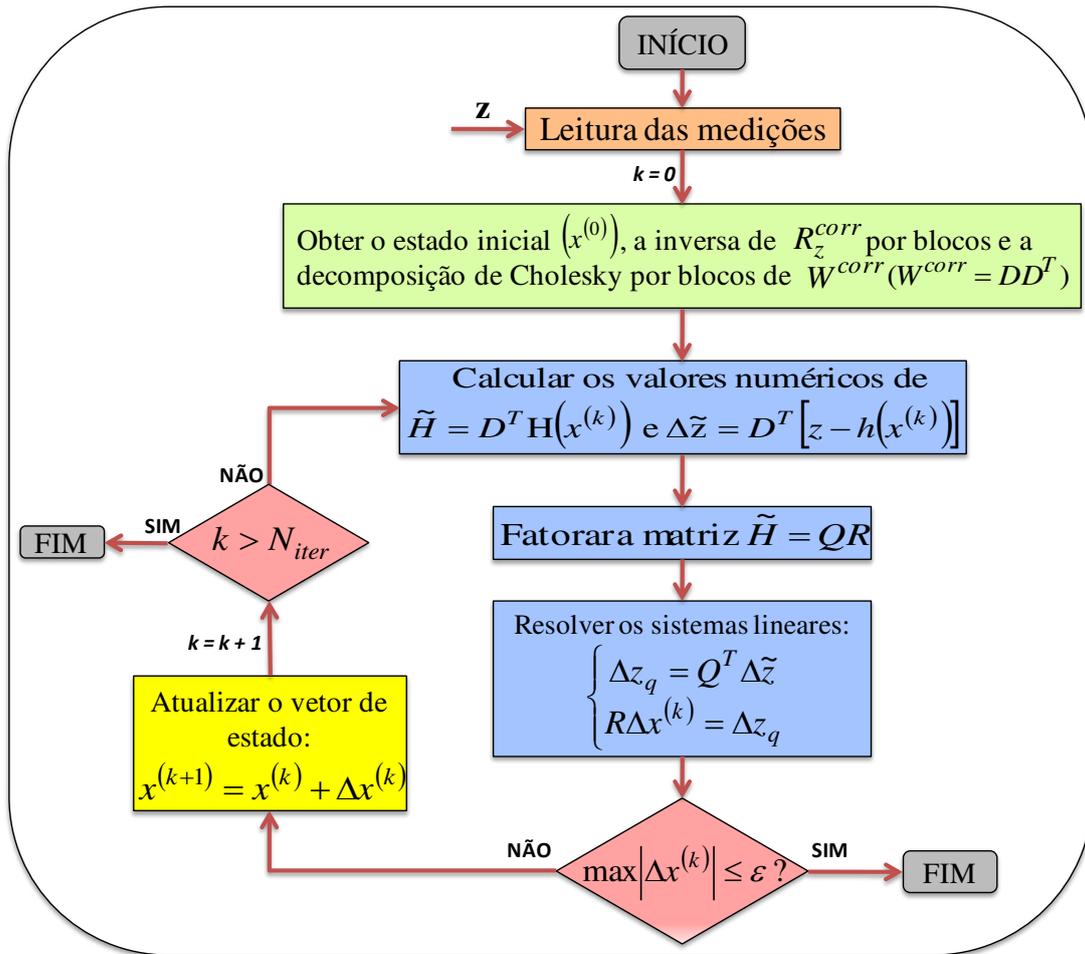


Figura 3.7: Método de Gauss-Newton para estimação de estado com medições correlacionadas.

ALGORITMO DE ALOCAÇÃO DE MEDIDORES EM REDES DE DISTRIBUIÇÃO BASEADO NO ÍNDICE DE PROBABILIDADE BIVARIADO

4.1 Introdução

Neste capítulo apresenta-se a metodologia de alocação de medidores que serve de base para as duas metodologias propostas para alocação de medidores em redes de distribuição.

O algoritmo proposto por Singh, Pal e Vinter (2009) utiliza a SMC não-linear (esta denominação é devido ao uso do MGN na estimação de estado) para estimar um índice de probabilidade bivariado associado à incerteza relativa do estado estimado. Por esta razão, antes de se descrever o método de Singh, Pal e Vinter (2009), doravante denominado *método SPV*, será feita uma breve revisão sobre a SMC.

4.2 Método de Simulação Monte Carlo

A SMC utiliza geradores de números aleatórios para modelar a ocorrência de eventos estocásticos (Brown 2009). Estes eventos estocásticos simulados são usados para gerar estados ou cenários (de t em t minutos, diário, semanal ou anual) de operação do sistema. Desta forma, dois estados ou cenários do sistema gerados via SMC, com os mesmos dados de entrada, não apresentam os mesmos resultados. A repetição da simulação irá produzir uma amostra de estados ou cenários do sistema a partir da qual podem ser calculadas estatísticas associadas com índices de interesse, tais como: média, variância, desvio padrão e distribuição de probabilidade.

Quando a SMC é aplicada na análise de sistemas de engenharia, geralmente o comportamento do sistema é analisado para um período específico de tempo, que,

tipicamente, corresponde a um ano. Como cada simulação tende a produzir um resultado diferente, muitas simulações são necessárias para se obter as estatísticas associadas com os índices de interesse. Teoricamente, o valor esperado da simulação, \bar{x} , pode ser calculado através da média dos resultados quando o número de simulações N tende a infinito (Brown 2009):

$$\bar{x} = \lim_{N \rightarrow \infty} \left(\frac{1}{N} \sum_{i=1}^N y_i \right) \quad (4.1)$$

em que y_i é o resultado da simulação i .

Um aspecto importante na SMC é a precisão das estimativas dos índices de interesse. A precisão das estimativas fornecidas pela SMC será demonstrada considerando-se que a indisponibilidade (probabilidade de falha) de um sistema é dada por Q e x_i é um indicador do estado do sistema, tal que:

$x_i = 0$, se o sistema não está em estado falho;

$x_i = 1$, se o sistema está em estado falho.

De acordo com (4.1), a estimativa da indisponibilidade do sistema é dada por:

$$\bar{Q} = \frac{1}{N} \sum_{i=1}^N x_i \quad (4.2)$$

na qual N é o número de amostras do estado do sistema.

Assim, a variância amostral é dada por:

$$V(x) = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{Q})^2 \quad (4.3)$$

Quando o tamanho da amostra é suficientemente grande, (4.3) pode ser aproximada por:

$$V(x) = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{Q})^2 \quad (4.4)$$

Como x é uma variável binária, assumindo ou 0 ou 1, tem-se:

$$\sum_{i=1}^N (x_i)^2 = \sum_{i=1}^N x_i \quad (4.5)$$

Substituindo as equações (4.2) e (4.5) em (4.4), tem-se:

$$\begin{aligned} V(x) &= \frac{1}{N} \sum_{i=1}^N (x_i)^2 - \frac{1}{N} \sum_{i=1}^N 2x_i \bar{Q} + \frac{1}{N} \sum_{i=1}^N \bar{Q}^2 \\ &= \bar{Q} - 2\bar{Q}^2 + \bar{Q}^2 \\ &= \bar{Q} - \bar{Q}^2 \end{aligned} \quad (4.6)$$

É importante notar que (4.2) fornece apenas uma estimativa da indisponibilidade do sistema. A incerteza em torno da estimativa pode ser mensurada através da variância da esperança do estado (Billinton e Li, 1994):

$$\begin{aligned} V(\bar{Q}) &= \frac{1}{N} V(x) \\ &= \frac{1}{N} (\bar{Q} - \bar{Q}^2) \end{aligned} \quad (4.7)$$

O nível de precisão da SMC pode ser expresso através de um coeficiente de variação β definido como:

$$\beta = \frac{\sqrt{V(\bar{Q})}}{\bar{Q}} \quad (4.8)$$

Substituindo (4.7) em (4.8), tem-se:

$$\beta = \sqrt{\frac{1 - \bar{Q}}{N\bar{Q}}} \quad (4.9)$$

É importante ressaltar que uma decisão importante ao utilizar a SMC é o número de simulações necessárias para obter uma precisão especificada. Caso o resultado requerido seja o valor esperado, deve-se realizar um número de simulações suficientes para que todos os resultados converjam para valores estáveis (Brown 2009). Para simulações em que se deseja obter um evento raro, o valor de N costuma ser bastante grande, o coeficiente de variação β pode ser utilizado para estimar o número mínimo de simulações necessárias para que todos os resultados converjam para valores estáveis (Billinton e Li, 1994). Reescrevendo (4.9), tem-se:

$$N = \frac{1 - \bar{Q}}{\beta^2 \bar{Q}} \quad (4.10)$$

A equação (4.10) indica que para um nível desejado de precisão β , o número requerido de amostras N depende da indisponibilidade do sistema, mas é independente do tamanho do sistema. Métodos de Monte Carlo são, portanto, aplicáveis a sistemas de grande porte para obtenção de um dado índice de interesse. Essa é uma importante vantagem da SMC quando comparada a técnicas de enumeração analítica (Billinton e Li, 1994). A grande desvantagem, sem dúvida, é o alto custo computacional da SMC, principalmente quando o valor de N é muito grande ou quando é necessário simular muitos eventos estocásticos para gerar estados ou cenários diários, semanais ou anuais de operação do sistema (Brown 2009). Um número elevado de simulações é requerido quando a probabilidade de um evento de interesse é muito pequena. Por exemplo, o número de simulações requerido para estimar uma probabilidade de 5% com $\beta = 5\%$ é dado por:

$$N = \frac{1 - 0,05}{0,05^2 0,05} = 7600$$

Este resultado demonstra que usar apenas 100 simulações pode resultar em valores muito imprecisos da probabilidade de interesse. Por exemplo, o evento de interesse pode não ocorrer em 100 simulações e a sua probabilidade seria nula. Consequentemente, estudos que usem esta estimativa da probabilidade tenderiam a superestimar a qualidade de um projeto se a probabilidade estiver relacionada com a violação de um valor crítico. Este tipo de efeito é denominado de mascaramento nesta dissertação. Todas as metodologias existentes de alocação de medidores estão sujeitas a problemas de mascaramento, pois elas realizam apenas 100 simulações para estimar a função objetivo do problema de alocação devido ao alto custo computacional da SMC não-linear.

A SMC pode ser aplicada de duas formas: sequencial e não sequencial. Ambas as técnicas são utilizadas em estudos probabilísticos. A SMC não-sequencial foi utilizada nesta dissertação para estimação do índice de probabilidade bivariado associado à incerteza relativa do estado estimado.

4.2.1 SMC não-sequencial

Quando não se precisa representar aspectos temporais do sistema (ou seja, o comportamento do sistema não depende de eventos passados), pode-se aplicar a técnica de SMC não-sequencial. Neste caso, as variáveis que representam as incertezas do sistema são amostradas aleatoriamente sem considerar a sua cronologia (dependência temporal).

Como exemplo de aplicação, simula-se a probabilidade de falha de dois componentes conectados em paralelo. Considera-se um sistema contendo dois componentes independentes A e B, conectados em paralelo de acordo com a Figura 4.1. Analiticamente, a probabilidade de ambos falharem é $Q_P = Q_A \cdot Q_B$. Considera-se que $Q_A = Q_B = 0,2$, logo a probabilidade do sistema falhar, ou seja, A e B estão simultaneamente indisponíveis, é de $Q_P = 0,04$ (Billinton e Allan, 1992).

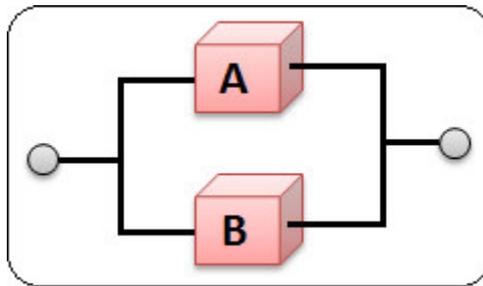


Figura 4.1: Sistema com dois componentes em paralelo.

Na prática, esses dados podem ser obtidos segundo um relatório de falta (banco de dados) ou através de testes experimentais de falha de cada componente.

A fim de aplicar a técnica de SMC à indisponibilidade do sistema com dois componentes independentes em paralelo, deve-se particionar o intervalo de números aleatórios uniformemente distribuídos em proporções que reflitam a chance da falha ocorrer. Em outras palavras, seja $u_A, u_B \in U(0,1)$, isto é, u_A e u_B são números uniformemente distribuídos no intervalo $(0,1)$, então uma das possíveis maneiras de dizer que o componente A falhou é se $u_A \in (0; 0,2]$. A ideia é sempre particionar o intervalo com um comprimento igual a indisponibilidade desejada. Para o caso deste

exemplo, u_A tem que estar definido em um intervalo de comprimento $Q_A = 0,2$. A mesma ideia se aplica ao componente B. A Figura 4.2 ilustra o desempenho da técnica de SMC aplicada à indisponibilidade do sistema com dois componentes independentes em paralelo. Utilizou-se $N = 2000$ simulações. Para confirmar a teoria de que dois estados ou cenários do sistema gerados via SMC, com os mesmos dados de entrada, não apresentam os mesmos resultados simulou-se a falha individual de A e B, e também a falha do sistema três vezes – curvas em azul são referentes à primeira SMC, curvas em vermelho são referentes à segunda SMC e as curvas em preto são referentes à terceira SMC. Contudo, a repetição da simulação irá produzir o valor esperado – linha em verde.

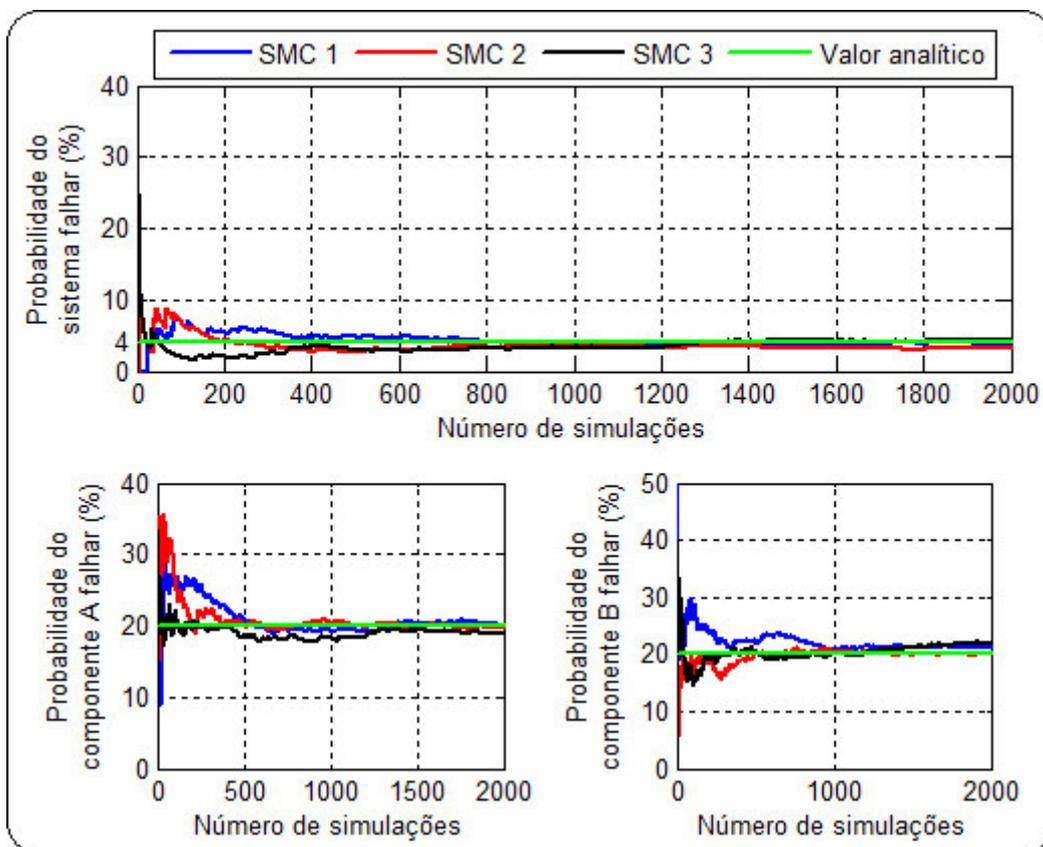


Figura 4.2: Técnica de SMC aplicada ao sistema com dois componentes independentes em paralelo.

4.3 Método SPV para Alocação de Medidor

Singh, Pal e Vinter (2009) propõem um algoritmo de alocação de medidores que minimiza a probabilidade do erro relativo entre os valores verdadeiros e estimados das

grandezas monitoradas ser menor ou igual a um valor especificado. Este índice de probabilidade bivariado é dado por:

$$P_i = \Pr \left\{ \left| \frac{\hat{V}^i - V_t^i}{V_t^i} \right| \leq \epsilon_V, \left| \frac{\hat{\theta}^i - \theta_t^i}{\theta_t^i} \right| \leq \epsilon_\theta \right\} \quad \text{para } i = 2, \dots, NB \quad (4.11)$$

em que V_t^i e θ_t^i são os valores verdadeiros do módulo e ângulo da tensão na i -ésima barra, respectivamente; \hat{V}^i e $\hat{\theta}^i$ são os valores estimados do módulo e ângulo da tensão na i -ésima barra, respectivamente; NB é o número de barras do sistema; ϵ_V e ϵ_θ são os valores estipulados para o erro relativo de magnitude e de fase da tensão, respectivamente, e a barra #1 é tomada como referência em módulo e fase de tensão.

A fim de reescrever o índice P_i define-se:

$$\mu^i = \begin{bmatrix} \mu_V^i \\ \mu_\theta^i \end{bmatrix} = E \begin{bmatrix} \hat{V}^i \\ \hat{\theta}^i \end{bmatrix} = \begin{bmatrix} V_t^i \\ \theta_t^i \end{bmatrix} \quad (4.12)$$

$$P_{V\theta}^i = E \left[\left(\begin{bmatrix} \hat{V}^i \\ \hat{\theta}^i \end{bmatrix} - \mu^i \right) \left(\begin{bmatrix} \hat{V}^i \\ \hat{\theta}^i \end{bmatrix} - \mu^i \right)^T \right] \quad (4.13)$$

$$\mu_{erro}^i = [\epsilon_V V_t^i \quad \epsilon_\theta |\theta_t^i|]^T \quad (4.14)$$

$$\hat{x}_{V\theta}^i = [\hat{V}^i \quad \hat{\theta}^i]^T \quad (4.15)$$

em que:

μ^i é o vetor constante que contém o valor verdadeiro do módulo e da fase da tensão na barra i ;

$P_{V\theta}^i$ é a matriz de covariância do erro do estado estimado na barra i ;

μ_{erro}^i é o vetor constante que contém o erro associado ao valor verdadeiro do módulo e da fase da tensão na barra i ;

$\hat{x}_{V\theta}^i$ é o vetor do estado estimado na barra i .

Usando-se as equações (4.12), (4.14) e (4.15), o índice de probabilidade bivariado P_i , definido em (4.11), assume a seguinte forma:

$$\begin{aligned}
P_i &= \Pr \left\{ -\mu_{erro}^i \leq \begin{bmatrix} \hat{V}^i - \mu_V^i \\ \hat{\theta}^i - \mu_\theta^i \end{bmatrix} \leq \mu_{erro}^i \right\} \\
&= \Pr \{ -\mu_{erro}^i \leq (\hat{x}_{V\theta}^i - \mu^i) \leq \mu_{erro}^i \} \\
&= 1 - \Pr \{ (\hat{x}_{V\theta}^i - \mu^i) > \mu_{erro}^i \text{ ou } (\hat{x}_{V\theta}^i - \mu^i) < -\mu_{erro}^i \}.
\end{aligned} \tag{4.16}$$

O índice de probabilidade P_i , definido em (4.16), pode ser melhorado através da redução do seguinte índice de probabilidade:

$$\begin{aligned}
R_i &= 1 - P_i \\
&= \Pr \{ (\hat{x}_{V\theta}^i - \mu^i) > \mu_{erro}^i \text{ ou } (\hat{x}_{V\theta}^i - \mu^i) < -\mu_{erro}^i \}.
\end{aligned} \tag{4.17}$$

Desde que $(P_{V\theta}^i)^{-1} \mu_{erro}^i \geq 0$, pode-se aplicar a desigualdade de Chebyshev em (4.17) (Singh, Pal e Vinter, 2009):

$$\sup_{\hat{x}_{V\theta}^i \sim \mathcal{N}(\mu^i, P_{V\theta}^i)} R_i = \min \left(1, \frac{1}{(\mu_{erro}^i)^T (P_{V\theta}^i)^{-1} \mu_{erro}^i} \right). \tag{4.18}$$

Se $1/(\mu_{erro}^i)^T (P_{V\theta}^i)^{-1} \mu_{erro}^i \geq 1$, o resultado de (4.18) é igual a 1, porque o índice de probabilidade R_i não pode exceder a unidade. Para $1/(\mu_{erro}^i)^T (P_{V\theta}^i)^{-1} \mu_{erro}^i < 1$, a probabilidade R_i em (4.18) é limitada por:

$$\begin{aligned}
R_i &= \Pr \{ (\hat{x}_{V\theta}^i - \mu^i) > \mu_{erro}^i \text{ ou } (\hat{x}_{V\theta}^i - \mu^i) < -\mu_{erro}^i \} \\
&\leq \frac{1}{(\mu_{erro}^i)^T (P_{V\theta}^i)^{-1} \mu_{erro}^i}.
\end{aligned} \tag{4.19}$$

Desta forma, associar o problema a redução da probabilidade R_i através da desigualdade de Chebyshev resulta em uma solução factível.

Os autores consideraram três tipos de medição. As medições de tensão e fluxo de potência foram tomadas como medições reais. Barras de injeção nula, com baixa variância (10^{-8}), foram modeladas como medições fictícias. As cargas foram modeladas como pseudo-medições. Para uma dada percentagem do erro máximo (ϵ_μ^{max}) sobre a média μ_{zmed} , o desvio padrão das medições foi computado através de (4.20):

$$\sigma_{zmed} = \frac{\mu_{zmed} \times \epsilon_\mu^{max}}{3 \times 100} \tag{4.20}$$

Tomando a média μ_{zmed} como o valor verdadeiro de uma medição obtido a partir do caso base (solução do fluxo de potência), então uma medição sorteada para um cenário da SMC é dada por:

$$z_{med}^{sort} = \mu_{zmed} + \sigma_{zmed} \cdot z \quad (4.21)$$

em que z é um número normalmente distribuído com média zero e desvio padrão unitário ($z \in \mathcal{N}(0,1)$).

O número aleatório com distribuição normal padronizada utilizado em (4.21) pode ser obtido a partir de diversas técnicas, como por exemplo, através do método da transformação inversa *aproximada* ou do método Box-Müller (Billinton e Li, 1994). Nesta dissertação utilizou-se o tradicional método Box-Müller. Este método consiste nos seguintes passos (Billinton e Li, 1994):

Passo #1: Gere dois números aleatórios com distribuição uniforme U_1 e U_2 ($U_1, U_2 \in [0,1]$);

Passo #2: Obtenha dois números aleatórios com distribuição normal padronizada (média zero e desvio padrão unitário) z_1 e z_2 como:

$$z_1 = \sqrt{-2 \ln(U_1)} \cos(2\pi U_2) \quad (4.22)$$

$$z_2 = \sqrt{-2 \ln(U_1)} \sin(2\pi U_2) \quad (4.23)$$

O número z utilizado em (4.21) pode ser obtido segundo (4.22) ou (4.23).

Em suma, o método SPV pode ser visto como um problema de otimização *min max*, em que os erros relativos de tensão e ângulo são minimizados alocando-se medidores no sistema, melhorando, assim, a função objetivo definida em (4.11). O método SPV simplifica o problema de alocação de medidores, transformando-o em um problema de redução de probabilidade, com a ajuda da desigualdade de Chebyshev. Uma solução direta é proposta para este último problema, com base na consideração de 2- σ elipse do erro. O índice P_i definido em (4.11) é melhorado a partir da redução da área da elipse do erro. A área da elipse do erro é definida em (4.24), em que P é a matriz inversa da matriz de covariância de erro (do estado estimado ou do fluxo de potência estimado) e $c = \mu_{zmed}^T P^{-1} \mu_{zmed}$.

$$A = c\pi\sqrt{\det(P)} \quad (4.24)$$

A técnica de alocação de medidores segundo o método SPV é sumarizada seguindo os passos abaixo e o fluxograma é ilustrado na Figura 4.3.

Passo #1: Executar o MQP sobre um conjunto de Simulações Monte Carlo e observar os erros relativos das tensões e ângulos a cada simulação em todas as barras.

Passo #2: Se em mais de 95% dos casos os erros relativos das tensões e fases estão abaixo dos valores especificados, isto é, $\epsilon_V \leq 1\%$ (para magnitude da tensão) e $\epsilon_\theta \leq 5\%$ (para fase da tensão), PARAR; caso contrário, ir para o passo #3.

Passo #3: Se somente os erros relativos nas tensões estimadas satisfazem o critério no passo #2, ir para o passo #6; caso contrário, ir para o passo #4.

Alocação de medidores de tensão:

Passo #4: Extrair as submatrizes correspondendo a tensão e fase em cada barra a partir da matriz de covariância de erro do estado estimado.

Passo #5: Para cada barra computar a área da elipse do erro a partir do determinante da submatriz e identificar a barra com maior área e, então, alocar um medidor de tensão nesta barra. Se já existe medidor de tensão nesta barra, escolher uma barra com maior área. Ir para o passo #1.

Alocação de medidores de fluxo de potência:

Passo #6: Extrair as submatrizes correspondendo ao fluxo de potência ativa e reativa em cada linha a partir da matriz de covariância de erro do fluxo (ativo e reativo) estimado.

Passo #7: Para cada linha computar a área da elipse do erro a partir do determinante da submatriz e identificar a barra com maior área e, então, alocar um medidor de fluxo nesta linha. Se já existe medidor de fluxo nesta linha, escolher uma linha com maior área. Ir para o passo #1.

No método SPV, a SMC é usada para gerar uma amostra de medições com base nas distribuições de probabilidade (normal ou gaussiana) dos erros de medição e nos valores verdadeiros das grandezas medidas. Em seguida, o estado estimado para cada elemento desta amostra é obtido usando-se o MGN, então, a amostra de estados

estimados é usada para calcular a função objetivo de um plano de medição candidato a solução do problema de alocação.

Uma desvantagem da SMC não-linear é a necessidade se resolver um problema de estimação de estado não-linear para cada elemento da amostra. Consequentemente, um problema associado a esses métodos é o custo computacional elevado, ficando mais acentuado em sistemas mais robustos devido ao alto número de consumidores instalados. Neste contexto, métodos que abordem a SMC linear podem ser uma alternativa para contornar as deficiências apontadas pelas técnicas apresentadas na literatura técnica (Strbac et al. 2005; Muscas et al. 2006; Muscas et al. 2009; Singh et al. 2009; Singh et al. 2011; Liu et al. 2014) para alocação de medidores em sistemas de distribuição.

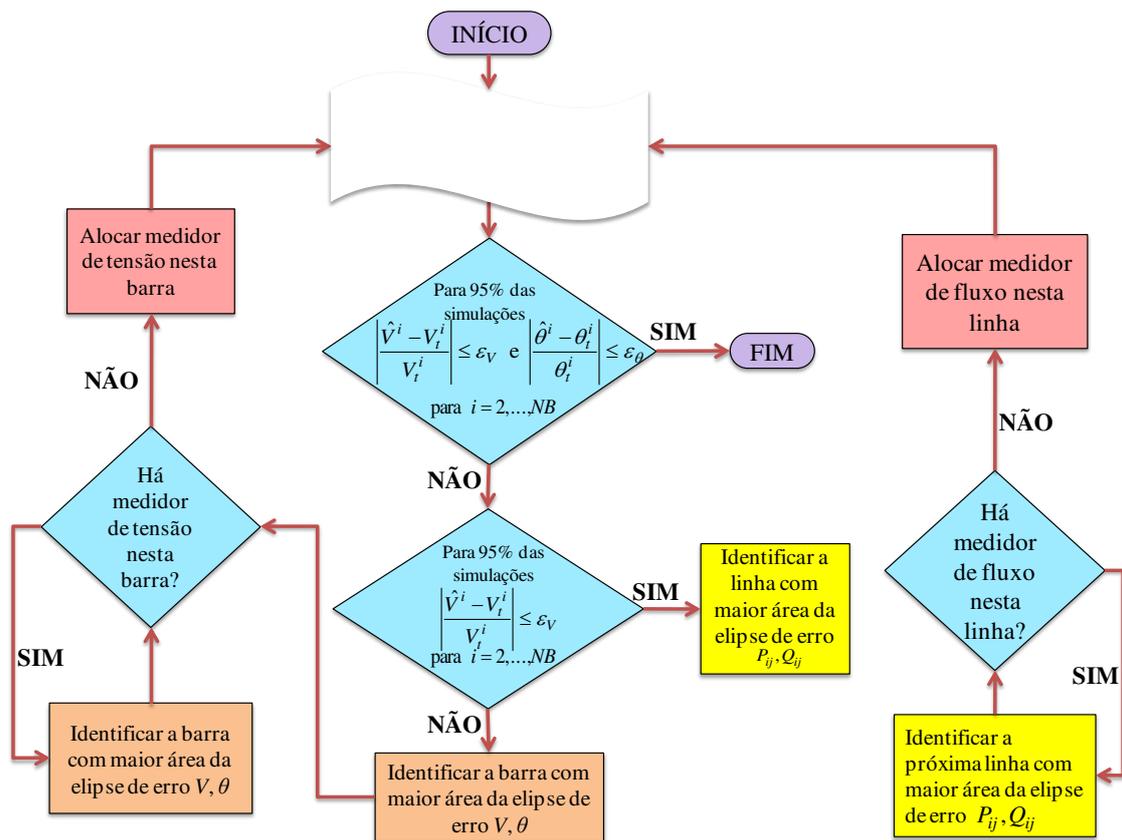


Figura 4.3: Fluxograma do método SPV (Adaptado de Singh, Pal e Vinter (2009)).

PROPOSTA DE ALOCAÇÃO DE MEDIDORES EM REDES DE DISTRIBUIÇÃO

5.1 Introdução

Neste capítulo apresentam-se as duas metodologias propostas para alocação de medidores em redes de distribuição. Uma baseada na SMC linear e a outra baseada na distribuição de probabilidade das variáveis de estado, denominada de método analítico. Ambas as técnicas têm como referência o método SPV descrito no capítulo anterior e utilizam a correlação entre medições de injeção de potência ativa e reativa, e entre medições de fluxo de potência ativa e reativa.

5.2 Alocação de Medidores via SMC Linear

Como foi visto, o custo computacional do algoritmo proposto por Singh, Pal e Vinter (2009) é elevado devido ao uso da SMC não-linear para estimar a função objetivo do problema de alocação de medidores. Visando minimizar o esforço computacional, substitui-se o MGN do *passo #1* para estimar o estado do sistema por uma relação de sensibilidade linear entre o estado estimado e os erros nas medições. O processo de linearização do estimador de estado, com medições correlacionadas, é descrito a seguir.

Sabe-se que no ponto de mínimo \hat{x} associado com a função objetivo do estimador de estado $J(\hat{x})$, as condições de primeira ordem são dadas por (5.1):

$$\frac{\partial J(\hat{x})}{\partial x} = H^T(\hat{x})(R_z^{corr})^{-1}[z - h(\hat{x})] = 0 \quad (5.1)$$

Assumindo que $H(\hat{x})$ é insensível a pequenas mudanças em \hat{x} e linearizando $h(\hat{x})$ em torno de x_{true} , tem-se (Debs 1990):

$$h(\hat{x}) \approx h(x_{true}) + H(x_{true})(\hat{x} - x_{true}) \quad (5.2)$$

no qual x_{true} é o valor verdadeiro do vetor de estado. Lembrando que $z = h(x) + e_z$ (Equação (2.1)), com $e_z \sim \mathcal{N}(0, R_z^{corr})$, e substituindo (5.2) em (5.1), obtém-se:

$$H^T (R_z^{corr})^{-1} [e_z - H(\hat{x} - x_{true})] = 0 \quad (5.3)$$

Isso implica que:

$$\hat{x} = x_{true} + \underbrace{[(H^T W^{corr} H)^{-1} H^T W^{corr}]}_A e_z \quad (5.4)$$

Nas considerações acima usou-se a aproximação $H(\hat{x}) \approx H(x_{true}) \approx H$ (Debs 1990).

Analisando (5.4) uma questão que surge é a obtenção da matriz A . A matriz A é o produto de G^{-1} com as matrizes H^T e W^{corr} . A matriz W^{corr} já está bem definida. O grande problema é a obtenção de G^{-1} devido ao alto custo computacional no processo de inversão de matriz e ao possível mal condicionamento de G devido ao grande número de pseudo-medidas e medidas virtuais. Visando mitigar estes custos, utiliza-se a mesma estratégia realizada no processo de obtenção do estado estimado: o uso da fatoração QR. Inicialmente, não se constrói G . Um segundo passo é obter G^{-1} por partes, isto é, obtém-se cada coluna de G^{-1} separadamente.

Considera-se a seguinte estrutura de G^{-1} :

$$G^{-1} = [G_{*1}^{inv} \quad G_{*2}^{inv} \quad \dots \quad G_{*k}^{inv} \quad \dots \quad G_{*n}^{inv}]$$

em que G_{*k}^{inv} é a k -ésima coluna de G^{-1} . Sabe-se que $GG^{-1} = I$. Expressando I da forma:

$$I = [e_1 \quad e_2 \quad \dots \quad e_k \quad \dots \quad e_n]$$

em que e_k é um vetor canônico tendo 1 na posição k , que representa a k -ésima coluna da matriz identidade.

Pode-se obter a inversa por partes de G a partir de (5.5):

$$\underbrace{(H^T W^{corr} H)}_G \cdot G_{*k}^{inv} = e_k \quad (5.5)$$

Como W^{corr} é simétrica e positiva definida por blocos, logo W^{corr} pode ser fatorada pela decomposição de Cholesky, com $W^{corr} = DD^T$. A fim de aplicar a

fatoração ortogonal para a obtenção da inversa de G por partes, (5.5) é reescrita na forma compacta:

$$\underbrace{\tilde{P}^T \tilde{P}}_G \cdot G_{*k}^{inv} = e_k \quad (5.6)$$

em que:

$$\tilde{P} = D^T H \quad (5.7)$$

Fatorando \tilde{P} através da decomposição QR, tem-se $\tilde{P} = QR$. Usando a propriedade $QQ^T = I$, (5.6) pode ser transformada sucessivamente em:

$$\begin{aligned} \tilde{P}^T \tilde{P} \cdot G_{*k}^{inv} &= e_k \\ R^T Q Q^T R \cdot G_{*k}^{inv} &= e_k \\ R^T R \cdot G_{*k}^{inv} &= e_k \end{aligned} \quad (5.8)$$

G_{*k} é obtido, então, por substituição regressiva/progressiva como segue:

$$\begin{cases} R^T \cdot w = e_k \\ R \cdot G_{*k}^{inv} = w \end{cases} \quad (5.9)$$

Em suma, em cada iteração do algoritmo de otimização para alocação de medidores, a obtenção da inversa de G por partes, utilizando a decomposição QR, consiste nos seguintes passos:

Passo #1: Obter a decomposição de Cholesky da matriz W^{corr} ($W^{corr} = DD^T$);

Passo #2: Obter a matriz \tilde{P} ($\tilde{P} = D^T H$);

Passo #3: Fatorar a matriz $\tilde{P} = QR$;

$k = 1$;

Passo #4: Resolver o sistema linear $R^T \cdot w = e_k$ por substituição;

Passo #5: Obter a k -ésima coluna de G^{-1} resolvendo-se o sistema linear $R \cdot G_{*k}^{inv} = w$ por substituição;

Passo #6: Regra de parada: se $k = n$, parar a inversão parcial, caso contrário, fazer $k = k + 1$ e voltar ao passo #4.

Os passos do algoritmo de inversão parcial são ilustrados no fluxograma da Figura 5.1.

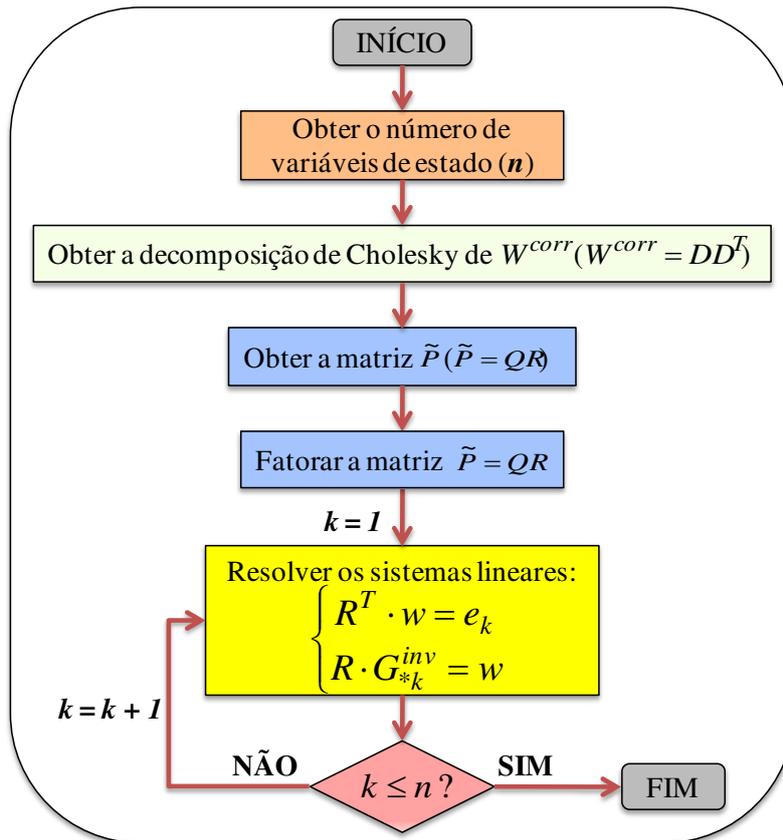


Figura 5.1: Fluxograma para a inversão parcial de G^{-1} .

A equação (5.4) estabelece que para se obter o estado estimado para um plano de medição específico, basta *sortear* um vetor de erro de medição e_z , multiplicá-lo pela matriz A e adicionar o resultado do produto ao vetor de estado verdadeiro. Isso ocorre, porque a matriz A *permanece constante para um plano de medição específico*. Devido a isto, o estado estimado para um conjunto de medições sorteado não requer um método iterativo, tal como o MGN. Em outras palavras, a estimação de estado é realizada por um modelo linear. De posse destas considerações, o algoritmo de alocação de medidores baseado na SMC com estimador linear, doravante denominado de *método SMCLIN*, segue os mesmos passos do método SPV, exceto o *passo #1*. Portanto, tem-se o seguinte algoritmo para a SMCLIN:

Passo #1: Obter o plano de medição. Construir a matriz A . Obter o estado estimado a partir de (5.4) sobre um conjunto de Simulações Monte Carlo do vetor de erro de medição e_z e observar os erros relativos das tensões e ângulos a cada simulação em todas as barras.

Passo #2: Se em mais de 95% dos casos os erros relativos das tensões e fases estão abaixo dos valores especificados, isto é, $\epsilon_V \leq 1\%$ (para magnitude da tensão) e $\epsilon_\theta \leq 5\%$ (para fase da tensão), PARAR; caso contrário, ir para o passo #3.

Passo #3: Se somente os erros relativos nas tensões estimadas satisfazem o critério no passo #2, ir para o passo #6; caso contrário, ir para o passo #4.

Alocação de medidores de tensão:

Passo #4: Extrair as submatrizes correspondendo a tensão e fase em cada barra a partir da matriz de covariância de erro do estado estimado.

Passo #5: Para cada barra computar a área da elipse do erro a partir do determinante da submatriz e identificar a barra com maior área e, então, alocar um medidor de tensão nesta barra. Se já existe medidor de tensão nesta barra, escolher uma barra com maior área. Ir para o passo #1.

Alocação de medidores de fluxo de potência:

Passo #6: Extrair as submatrizes correspondendo ao fluxo de potência ativa e reativa em cada linha a partir da matriz de covariância de erro do fluxo (ativo e reativo) estimado.

Passo #7: Para cada linha computar a área da elipse do erro a partir do determinante da submatriz e identificar a barra com maior área e, então, alocar um medidor de fluxo nesta linha. Se já existe medidor de fluxo nesta linha, escolher uma linha com maior área. Ir para o passo #1.

O algoritmo de alocação de medidores baseado na SMCLIN é ilustrado no fluxograma da Figura 5.2.

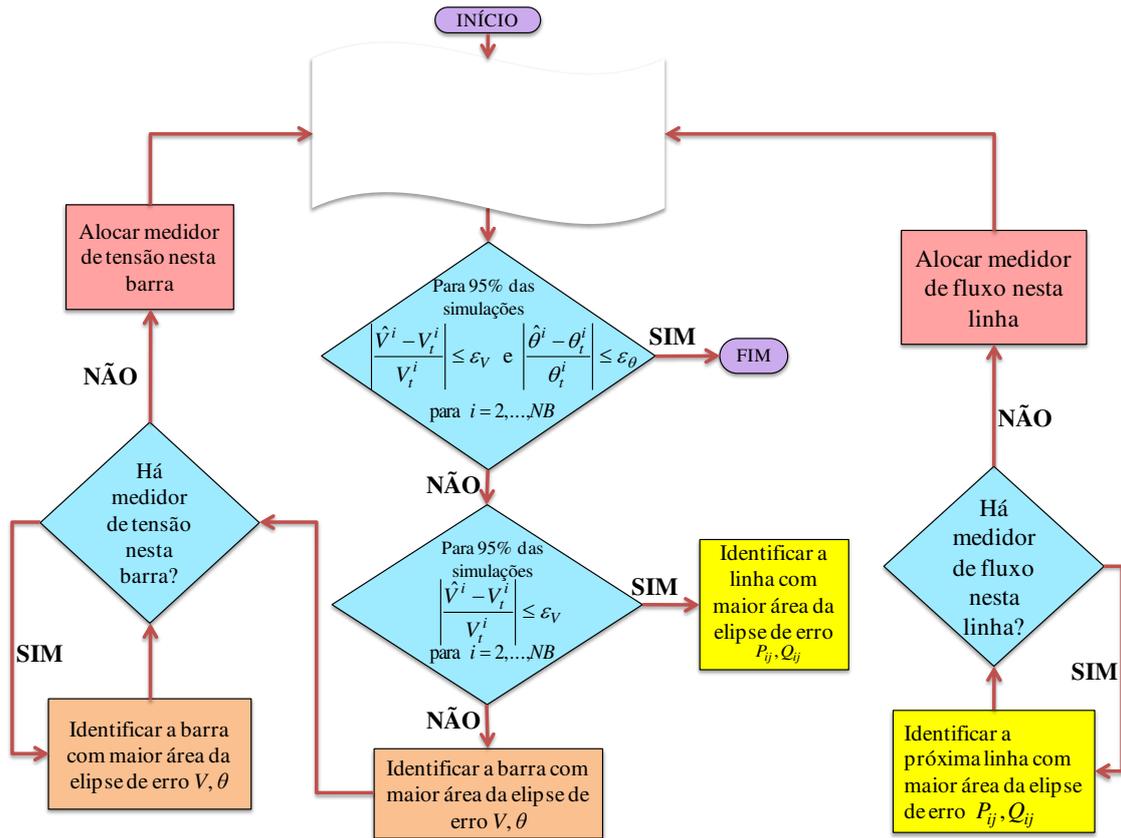


Figura 5.2: Fluxograma do método SMCLIN.

A seção seguinte descreve a principal contribuição deste trabalho.

5.3 Alocação de Medidores via Método Analítico

A proposta de uma metodologia de alocação de medidores em redes de distribuição através do método analítico é denominada, a partir desta seção, de *método ANA2PDF*. O método ANA2PDF se baseia na linearização de (5.2). Todavia, o método dispensa a técnica de SMC para estimar estatísticas amostrais associadas com o estado estimado. Ao invés disso, o ANA2PDF gera a função densidade de probabilidade do vetor de estado estimado. A partir desta função, pode-se estimar qualquer índice probabilístico associado com o estado estimado. O cálculo do índice de probabilidade bivariado, P_i , utiliza as funções densidade de probabilidade de $\hat{\theta}_i$ e \hat{V}_i .

A Equação (5.4) tem a mesma forma da transformação linear correlacionada $Y = AX + B$ (equação (3.22)) vista na seção 3.3. Isso porque as medições de injeção ou fluxo de potência são correlacionadas, isto é, $e_z \sim \mathcal{N}(0, R_z^{corr})$. Desta forma, fica inviável obter a média e a variância do estado estimado \hat{x} ($\hat{\theta}_i$ e $\hat{V}_i \forall i = 2, \dots, NB$). Por conseguinte, não se pode definir a PDF do estado estimado. Uma maneira de contornar este problema é utilizar alguma técnica de conversão de uma transformação linear correlacionada ($\hat{x} = x_{true} + Ae_z$) em uma transformação linear descorrelacionada equivalente. Tendo-se uma transformação linear descorrelacionada, pode-se utilizar (3.25) e (3.26) ou (3.29) e (3.30) para se encontrar a média e a variância de \hat{x} .

Na seção 3.3 foram apresentados dois métodos para descorrelacionar variáveis aleatórias correlacionadas consoantes a uma transformação linear: o método da decomposição de Cholesky e o método da decomposição ortogonal baseado em autovalores e autovetores. Alguns autores como Morales et al. (2010) e Caro et al. (2011) fazem uso da decomposição de Cholesky para descorrelacionar as medições de injeção ou fluxo de potência. Os dois métodos levam aos mesmos resultados. Além disso, o custo computacional de ambos os métodos é similar, pois pode-se obter fórmulas analíticas fechadas para a decomposição de Cholesky e para autovalores/autovetores de matrizes de ordem 2×2 . Desta forma, a decomposição ortogonal baseado em autovalores e autovetores foi aplicada nesta dissertação para obter a média e a variância de \hat{x} com base em (5.4).

Segundo (3.27), a transformação linear equivalente descorrelacionada associada a \hat{x} é obtida expressando-se o vetor $e_z \sim \mathcal{N}(0, R_z^{corr})$ como uma função linear de um vetor gaussiano padronizado e descorrelacionado (L.-Garcia 2008; Miller e Childers, 2012):

$$e_z = Q\sqrt{\Lambda}Z + \bar{X} = Q\sqrt{\Lambda}Z \quad (5.10)$$

em que:

Z é um vetor de variáveis aleatórias gaussianas descorrelacionadas e padronizadas ($Z \sim \mathcal{N}(0, I)$);

Q é uma matriz ortogonal onde cada coluna está associada com um autovetor de R_z^{corr} ($R_z^{corr} = Q\Lambda Q^T$, pois R_z^{corr} é simétrica);

$\sqrt{\Lambda}$ é uma matriz diagonal associada com os autovalores de R_z^{corr} , ou seja, $\sqrt{\Lambda_{ii}} = \lambda_i$ é o i -ésimo autovalor de R_z^{corr} .

Substituindo-se (5.10) em (5.4), tem-se:

$$\begin{aligned}
\hat{x} &= Ae_z + x_{true} \\
&= A(Q\sqrt{\Lambda}Z) + x_{true} \\
&= (AQ\sqrt{\Lambda})Z + x_{true} \\
&= A''Z + x_{true}
\end{aligned} \tag{5.11}$$

em que $A'' = AQ\sqrt{\Lambda}$.

Aplicando-se (3.29) e (3.30), a média e a variância de cada componente de \hat{x} são dadas por:

$$E[\hat{x}] = x_{true} \tag{5.12}$$

$$Var[\hat{x}_k] = \sum_{j=1}^{NM} (a''_{kj})^2 \tag{5.13}$$

no qual NM é o número de medições disponíveis.

Visto que $Z \sim \mathcal{N}(0, I)$, então a matriz de covariância do estado estimado, $C_{\hat{x}}^{V\theta}$, segundo o método ANA2PDF é dada por:

$$\begin{aligned}
C_{\hat{x}}^{V\theta} &= E[(\hat{x} - E[\hat{x}])(\hat{x} - E[\hat{x}])^T] \\
&= E[(A''Z + x_{true} - x_{true})(A''Z + x_{true} - x_{true})^T] \\
&= E[A''ZZ^T(A'')^T] = A''E[ZZ^T](A'')^T \\
&= A''I(A'')^T \\
&= A''(A'')^T
\end{aligned} \tag{5.14}$$

As equações (5.12) e (5.13) definem uma distribuição de probabilidade normal bivariada com média $x_{true}^{\theta_k V_k}$ e matriz de covariância $[A''_{\theta_k V_k}][A''_{\theta_k V_k}]^T$ (equação (3.20)), associadas ao ângulo e a magnitude da tensão para cada barra k do sistema, conforme (5.15):

$$\hat{x}_k^{\theta V} \sim \mathcal{N}\left(x_{true}^{\theta_k V_k}, [A''_{\theta_k V_k}][A''_{\theta_k V_k}]^T\right) \tag{5.15}$$

O índice de probabilidade bivariado P_i é computado considerando-se que tanto o erro relativo de ângulo quanto o de magnitude da tensão são menores ou iguais a um limiar (ϵ_V e ϵ_θ). A estimação destes índices terá como base as seguintes hipóteses:

- i) A magnitude e a fase da tensão estimada para cada barra do sistema tem distribuição normal;
- ii) A magnitude e a fase da tensão estimada para cada barra do sistema são variáveis aleatórias descorrelacionadas.

A validade destas hipóteses será verificada posteriormente na seção de resultados usando-se testes estatísticos adequados para normalidade e correlação. Assumindo-se que as hipóteses (i) e (ii) são válidas, o índice bivariado P_i pode ser calculado através do produto das probabilidades de violações dos limites para a magnitude e fase da tensão estimada em cada barra de acordo com (5.16):

$$P_i = P_i^V \cdot P_i^\theta \quad \text{para } i = 2, \dots, NB \quad (5.16)$$

Em que:

$$P_i^V = \Pr\left(\left|\frac{\hat{V}^i - V_t^i}{V_t^i}\right| \leq \epsilon_V\right) \quad \text{para } i = 2, \dots, NB \quad (5.17)$$

$$P_i^\theta = \Pr\left(\left|\frac{\hat{\theta}^i - \theta_t^i}{\theta_t^i}\right| \leq \epsilon_\theta\right) \quad \text{para } i = 2, \dots, NB \quad (5.18)$$

A probabilidade P_i^V pode ser reescrita como segue:

$$\begin{aligned} P_i^V &= \Pr\left(\left|\frac{\hat{V}^i - V_t^i}{V_t^i}\right| \leq \epsilon_V\right) \\ &= \Pr(|\hat{V}^i - V_t^i| \leq \epsilon_V |V_t^i|) \\ &= \Pr(-\epsilon_V V_t^i \leq \hat{V}^i - V_t^i \leq \epsilon_V V_t^i) \\ &= \Pr[V_t^i(1 - \epsilon_V) \leq \hat{V}^i \leq V_t^i(1 + \epsilon_V)] \end{aligned} \quad (5.19)$$

O índice de probabilidade P_i^V tem distribuição normal com média V_t^i e variância dada por (5.13). A Figura 5.3 ilustra a região de interesse para P_i^V .

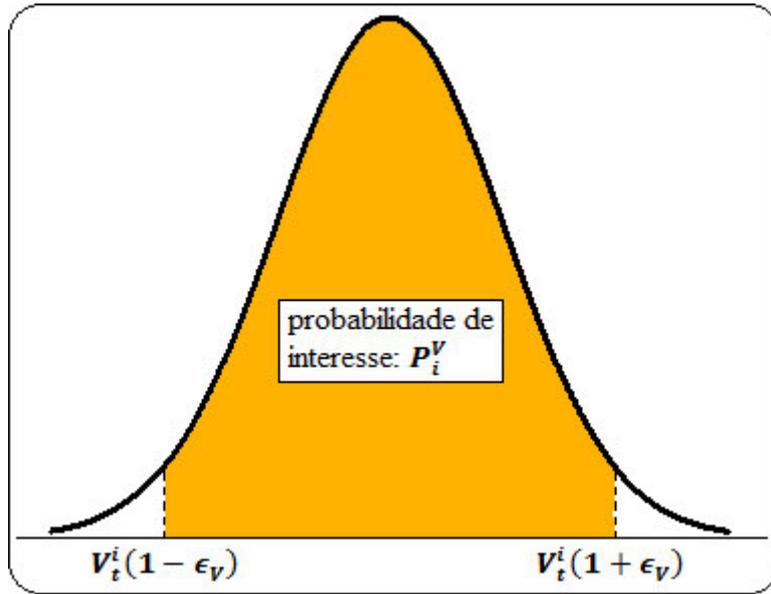


Figura 5.3: Visualização gráfica do índice de probabilidade P_i^V .

A probabilidade P_i^θ pode ser reescrita como segue:

$$\begin{aligned}
 P_i^\theta &= \Pr\left(\left|\frac{\hat{\theta}^i - \theta_t^i}{\theta_t^i}\right| \leq \epsilon_\theta\right) \\
 &= \Pr(|\hat{\theta}^i - \theta_t^i| \leq \epsilon_\theta |\theta_t^i|) \\
 &= \Pr(-\epsilon_\theta |\theta_t^i| \leq \hat{\theta}^i - \theta_t^i \leq \epsilon_\theta |\theta_t^i|) \\
 &= \Pr[\theta_t^i - \epsilon_\theta |\theta_t^i| \leq \hat{\theta}^i \leq \theta_t^i + \epsilon_\theta |\theta_t^i|]
 \end{aligned} \tag{5.20}$$

O índice de probabilidade P_i^θ tem distribuição normal com média θ_t^i e variância dada por (5.13). A Figura 5.4 ilustra a região de interesse para P_i^θ .

Deve-se ressaltar que as probabilidades P_i^V e P_i^θ foram computadas através da função nativa do MATLAB *normcdf* (Mathworks™ 2004).

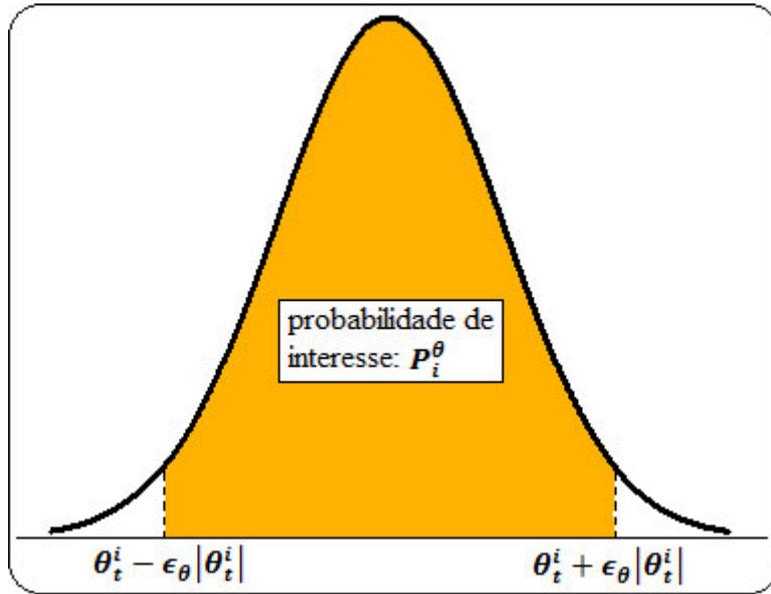


Figura 5.4: Visualização gráfica do índice de probabilidade P_i^θ .

A última etapa do ANA2PDF é obter a matriz de covariância associada ao erro de fluxo estimado de potência ativa e reativa. Esta matriz de covariância é obtida a partir da análise de sensibilidade da matriz $\frac{\partial \hat{z}}{\partial z}$, ou seja, a variação nos valores calculados dos fluxos com relação às perturbações associadas com os erros de medições.

Considera-se que o estado estimado já foi calculado segundo (5.11). A análise de sensibilidade é inicialmente usada para determinar o impacto de uma variação no estado estimado sobre os valores estimados dos fluxos nos circuitos. Neste caso, a matriz de sensibilidade $\frac{\partial \hat{z}}{\partial \hat{x}}$ é dada por (Monticelli 1999):

$$\frac{\partial \hat{z}}{\partial \hat{x}} = H^{FP} \Rightarrow \Delta \hat{z} = H^{FP} \Delta \hat{x} \quad (5.21)$$

Em que H^{FP} é a partição da matriz H associada com os fluxos de potência.

A partir de (5.11), tem-se:

$$\hat{x} = A''Z + x_{true} \Rightarrow \hat{x} - x_{true} = A''Z \Rightarrow \Delta \hat{x} = A''Z \quad (5.22)$$

No qual $\Delta \hat{x} = \hat{x} - x_{true}$.

Substituindo-se (5.22) em (5.21), tem-se:

$$\begin{aligned}\Delta\hat{z} &= H^{FP}\Delta\hat{x} \\ &= (H^{FP}A'')Z\end{aligned}\quad (5.23)$$

Um resultado importante da teoria de probabilidade é que se $y = Fv$, com $Cov(v) = M$, então $Cov(y) = FMF^T$. Aplicando esta informação ao nosso problema, tem-se a matriz de covariância associada ao erro de fluxo estimado de potência ativa e reativa, C_{PQ}^{fluxo} , dada por:

$$\begin{aligned}Cov(\Delta\hat{z}) &= C_{PQ}^{fluxo} = (H^{FP}A'')Cov(Z)(H^{FP}A'')^T \\ &= (H^{FP}A'')I(H^{FP}A'')^T \\ &= H^{FP}(A'')(A'')^T(H^{FP})^T\end{aligned}\quad (5.24)$$

O método ANA2PDF, diferentemente dos métodos SPV e SMCLIN, não exige que seja estimado o estado do sistema a fim de computar o índice de probabilidade bivariado P_i . A grande vantagem do ANA2PDF é calcular este índice de forma direta (sem o uso da SMC) a partir da probabilidade do estado estimado estar dentro de um intervalo pré-especificado.

A técnica de alocação de medidores segundo o método ANA2PDF é resumizada seguindo os passos abaixo e o fluxograma é ilustrado na Figura 5.5.

Passo #1: Obter cada desvio padrão associado ao plano de medição. Obter W^{corr} a partir da inversão por blocos da matriz R_z^{corr} . Obter a matriz $A = (H^T W^{corr} H)^{-1} H^T W^{corr}$ a partir de (5.4). Obter a matriz $A'' = AQ\sqrt{\Lambda}$ segundo (5.11).

Passo #2: Para $i = 2, \dots, NB$, calcular P_i^V e P_i^θ de acordo com (5.18) e (5.20), respectivamente. Obter $P_i = P_i^V \cdot P_i^\theta$. Se em cada barra i , $P_i \geq 95\%$ para $\epsilon_V \leq 1\%$ (para magnitude da tensão) e $\epsilon_\theta \leq 5\%$ (para fase da tensão), PARAR; caso contrário, ir para o passo #3.

Passo #3: Se somente $P_i^V \geq 95\%$, ir para o passo #6; caso contrário, ir para o passo #4.

Alocação de medidores de tensão:

Passo #4: Extrair as submatrizes correspondendo a tensão e fase em cada barra a partir da matriz de covariância de erro do estado estimado, $C_{\hat{x}}^{V\theta}$, conforme (5.14).

Passo #5: Para cada barra computar a área da elipse do erro a partir do determinante da submatriz e identificar a barra com maior área e, então, alocar um medidor de tensão

nesta barra. Se já existe medidor de tensão nesta barra, escolher uma barra com maior área. Ir para o passo #1.

Alocação de medidores de fluxo de potência:

Passo #6: Extrair as submatrizes correspondendo ao fluxo de potência ativa e reativa em cada linha a partir da matriz de covariância de erro do fluxo (ativo e reativo) estimado, C_{PQ}^{fluxo} , conforme (5.24).

Passo #7: Para cada linha computar a área da elipse do erro a partir do determinante da submatriz e identificar a barra com maior área e, então, alocar um medidor de fluxo nesta linha. Se já existe medidor de fluxo nesta linha, escolher uma linha com maior área. Ir para o passo #1.

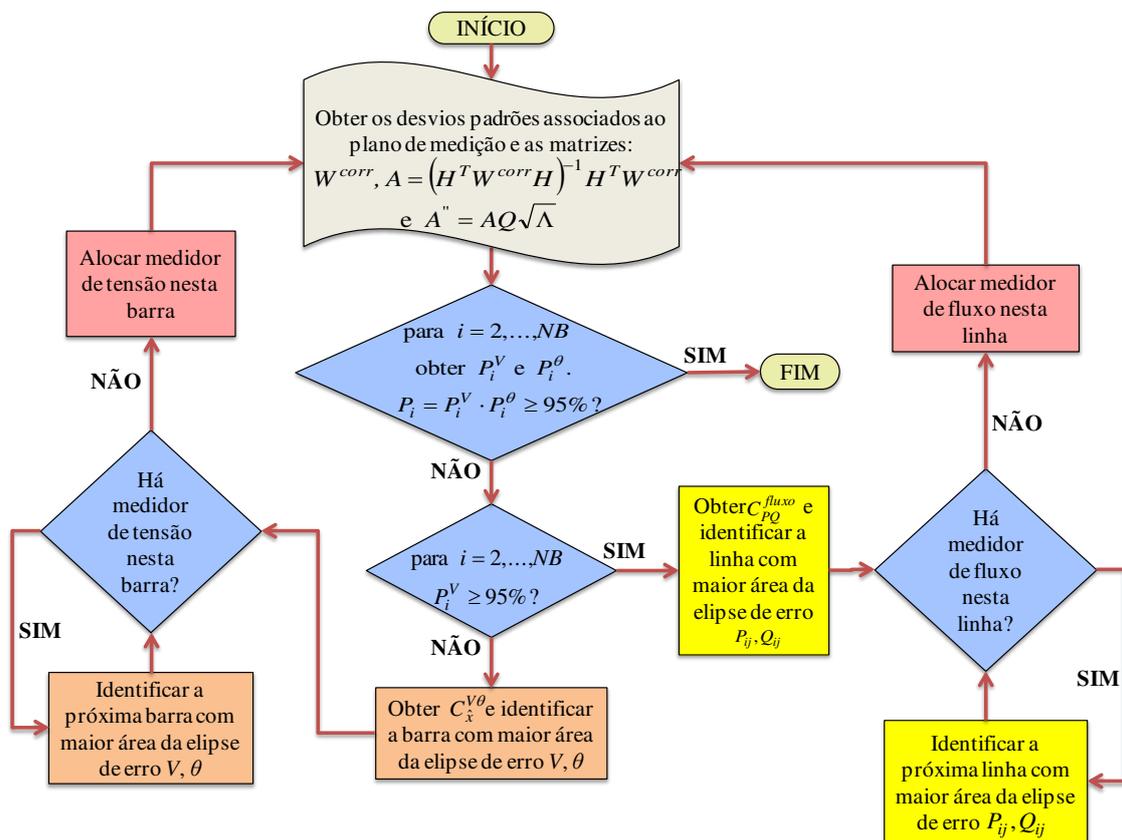


Figura 5.5: Fluxograma do método ANA2PDF.

RESULTADOS DOS TESTES

6.1 Introdução

Neste capítulo apresentam-se os resultados dos testes com a metodologia de alocação de medidores proposta por Singh, Pal e Vinter (2009) e as duas metodologias propostas nesta dissertação, o método SMCLIN e o método ANA2PDF. Todas as metodologias foram implementadas usando o MATLAB. As simulações foram realizados em PC com processador Intel Core i5-4570 CPU, 3.20 GHz com 8 GB de RAM e aplicadas no sistema UKGDS de 95 barras (Pal 2015), doravante denominado de STD_UKGDS95. Todos os testes foram realizados considerando-se dois aspectos: o modelo de sequência positiva dos sistemas e o carregamento nominal de cada sistema. O principal objetivo deste capítulo é validar as duas metodologias de alocação propostas no capítulo 5. Serão também apresentados os resultados de testes estatísticos para legitimar as hipóteses usadas na simplificação do cálculo do índice P_i .

Nas seções seguintes serão apresentados os ganhos das duas metodologias propostas em relação ao método SPV. Os resultados apresentados nas próximas seções são organizados do seguinte modo:

1. A seção 6.2 apresenta uma descrição do sistema teste STD_UKGDS95;
2. Na seção 6.3 apresentam-se considerações referentes aos testes, tais como modelagem de cargas, geradores e da rede de distribuição;
3. Testes estatísticos para validar as hipóteses usadas no cálculo de P_i são realizados na seção 6.4;
4. A seção 6.5 apresenta e compara os resultados das três metodologias de alocação de medidores;
5. Uma análise de sensibilidade do método SPV considerando-se a ocorrência de eventos raros é realizada na seção 6.6, isto é, será investigado o problema de mascaramento dos métodos baseados em SMC com amostras pequenas.

6.2 Descrição do Sistema Teste

O sistema teste utilizado para validação das metodologias propostas para alocação de medidores em redes de distribuição foi proposto por Singh, Pal e Vinter (2009). Embora o STD_UKGDS95 seja um sistema de distribuição, somente os dados de sequência positiva são fornecidos. O STD_UKGDS95 é parte de um sistema real de distribuição britânico. Os dados do sistema STD_UKGDS95 podem ser obtidos em (Pal 2015). As principais características deste sistema são resumidas na Tabela 6.1.

Tabela 6.1: Principais dados do STD_UKGDS95.

Dados gerais do STD_UKGDS95	
Número de barras	95
Número de ramos	94
Carga ativa total	3576 kW
Carga reativa total	2201 kVAr
Tensão primária	11 kV
Número de pontos de carga	55
Número de geradores	2

O STD_UKGDS95 possui 95 barras, sendo 55 pontos de carga, além de duas GD, localizadas nas barras #18 e #95. Cada GD foi modelada como potência constante. A potência complexa produzida por cada GD é igual a $750 \text{ kW} + j221,9 \text{ kVAr}$ (Shafiu et al. 2005). O diagrama unifilar do STD_UKGDS95 é mostrado na Figura 6.1. Para facilitar a visualização, as barras de carga foram destacadas com um círculo cheio (preto) e as barras de injeção nula foram destacadas com um círculo vazio (branco).

Excluindo-se a barra da subestação (barra #1), os 55 pontos de carga e as duas GD, o restante do STD_UKGDS95 é composto de 37 barras de injeção nula, o que corresponde a quase 40% de todas as barras do sistema.

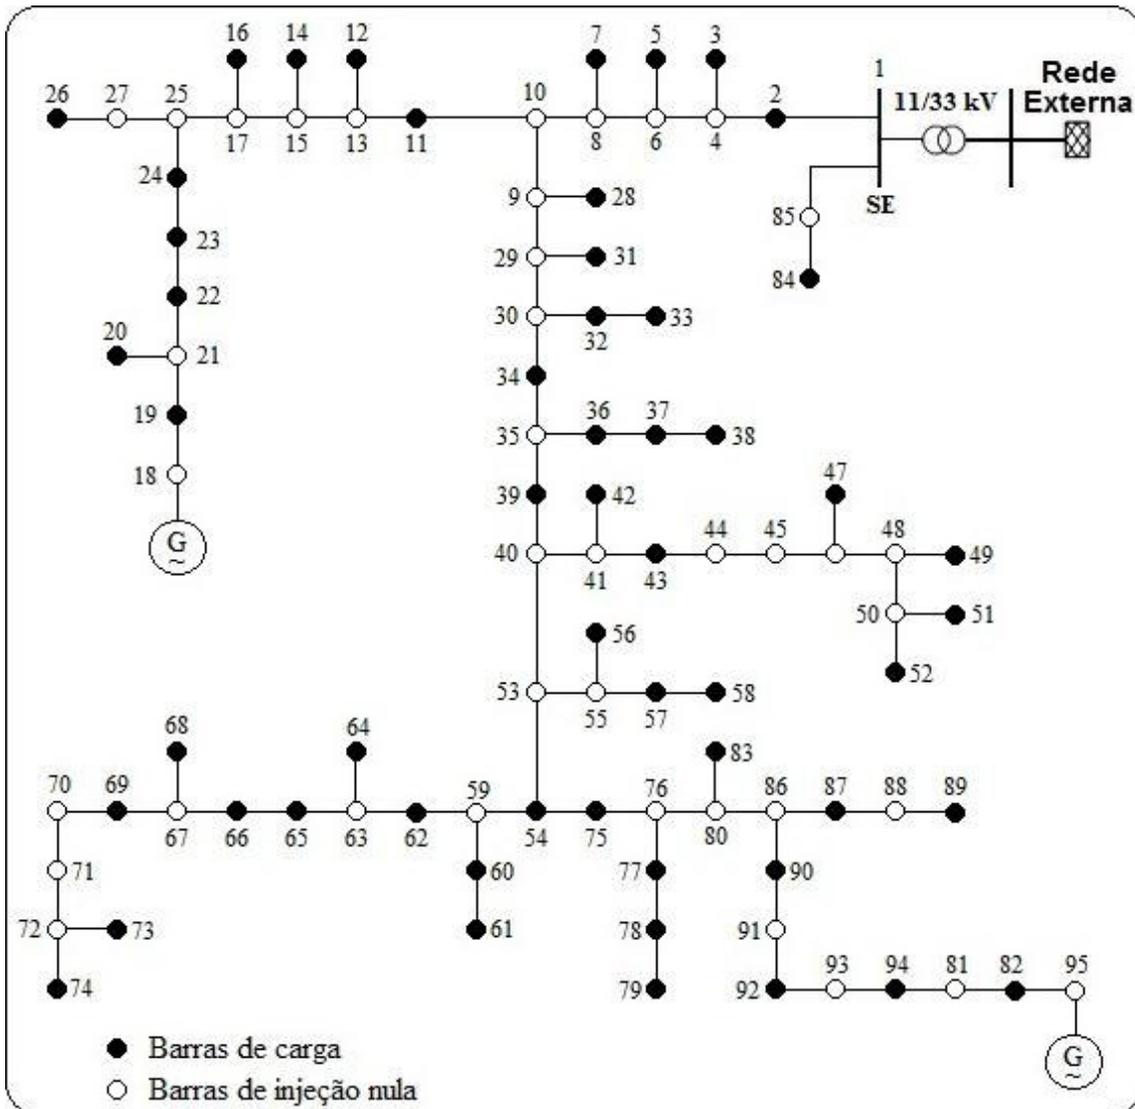


Figura 6.1: Diagrama unifilar do STD_UKGDS95 (Adaptado de Singh, Pal e Vinter (2009)).

6.3 Dados das Simulações

Para as simulações realizadas no sistema STD_UKGDS95 considerou-se que:

- 1) O tamanho da amostra, para todos os métodos baseados na SMC, é igual 100 (cem), exceto na seção 6.6 na qual será investigado o problema de mascaramento dos métodos baseados em SMC com amostras pequenas. Este tamanho de amostra foi especificado para permitir uma comparação com o método SPV e reduzir o custo computacional dos métodos de alocação baseados na SMC;

- 2) A barra da subestação, barra #1 para o STD_UKGDS95, é a barra de referência ($V\theta$) para todos os métodos de alocação. Nesta barra o valor especificado da tensão é $1\angle 0^\circ$ p.u.;
- 3) No fluxo de potência as cargas são modeladas como potência constante;
- 4) Os erros relativos especificados de tensão e de ângulo são, respectivamente, $\epsilon_V \leq 1\%$ e $\epsilon_\theta \leq 5\%$.

Com base nos itens 1 e 2, as magnitudes e as fases das tensões no sistema STD_UKGDS95 são ilustradas na Figura 6.2.

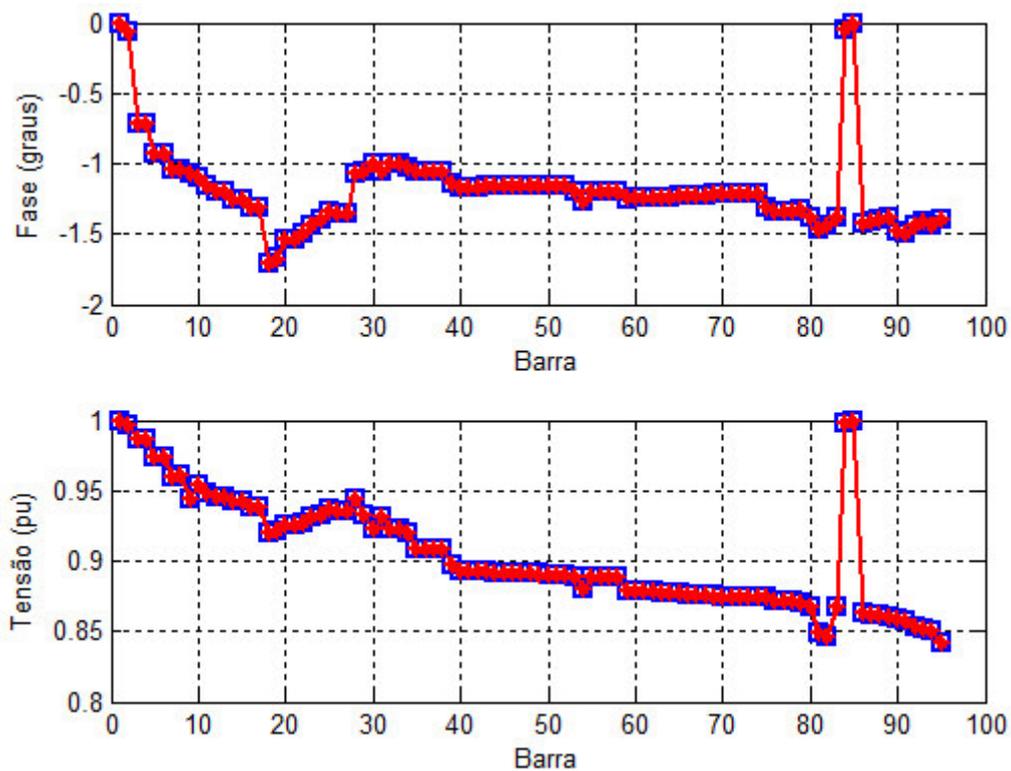


Figura 6.2: Magnitudes e fases das tensões no sistema STD_UKGDS95.

6.4 Testes Estatísticos para Validar as Hipóteses Usadas no Cálculo de P_i

Esta seção destina-se a verificar estatisticamente algumas hipóteses assumidas na metodologia de alocação de medidores em redes de distribuição. Mais precisamente, descreve-se aqui toda teoria utilizada no cálculo do índice de probabilidade bivariado

P_i . O índice P_i exige que se saiba se o módulo e a fase da tensão em cada barra do sistema possuem correlação ou não. Isto se faz necessário devido a dois fatores: I) a correlação introduzida na matriz de covariância de medições (R_z) implica em uma correlação *forte* entre as variáveis de estado?; II) o custo computacional para computar P_i aumenta caso o módulo e a fase da tensão em uma barra qualquer sejam correlacionados, pois utiliza-se métodos iterativos no cálculo de integrais definidas bivariadas. Para se investigar a correlação entre variáveis aleatórias bivariadas é necessário supor que ambas sejam normalmente distribuídas.

Muitos testes podem ser empregados para investigar a normalidade de uma variável aleatória, cada um com a sua peculiaridade. Nesta dissertação emprega-se o teste de Kolmogorov-Smirnov.

6.4.1 Teste de aderência de Kolmogorov-Smirnov

Os testes de aderência, também designados por testes de qualidade do ajuste, servem para testar a hipótese de que uma determinada amostra aleatória tenha sido extraída de uma população com distribuição especificada. O teste de Kolmogorov-Smirnov, doravante denominado neste texto de KS-Teste, pode ser aplicado apenas quando a distribuição indicada na hipótese nula, H_0 , está completamente especificada. Ou seja, fazem-se inferências com relação à média e ao desvio padrão da distribuição. Para uma variável aleatória X , o KS-Teste baseia-se na análise do ajuste entre a função de distribuição populacional admitida em H_0 , F_0 , e a função de distribuição empírica, \hat{F}_n . Assim, sendo F a função de distribuição desconhecida da população, as hipóteses a testar são:

$$H_0: F(x) = F_0(x), -\infty < x < \infty;$$

$$H_1: F(x) \neq F_0(x).$$

em que F_0 é a função de distribuição proposta, contínua e completamente especificada.

No KS-Teste considera-se a estatística:

$$D_n = \sup_{-\infty < x < \infty} |F_n(x) - F_0(x)| \quad (6.1)$$

como uma medida de discrepância entre a função de distribuição da amostra F_n e a função de distribuição proposta F_0 . D_n , definido em (6.1), representa a distância vertical máxima entre as imagens da função de distribuição da amostra, $F_n(x)$, e da função de distribuição proposta $F_0(x)$, dando uma ideia de aderência, como se pretendia. A regra de decisão do KS-Teste é rejeitar H_0 se a estatística do teste, definida por (6.1) e denominada $D_{critico}$, é maior do que o quartil $1 - \alpha$. Onde α é o nível de significância do teste e $D_{critico}$ é obtido da tabela do KS-Teste. O quartil $1 - \alpha$ é chamado de valor-p_{critico} (Virgilito 2007).

Para o problema analisado nesta dissertação, o interesse é saber se o módulo e a fase da tensão em cada barra do STD_UKGDS95 (exceto a subestação) tem distribuição normal. Excluindo-se a barra da subestação, o sistema tem 188 variáveis de estado para analisar a hipótese de normalidade e três possíveis valores para o coeficiente de correlação ρ das medições foram empregados nos testes. Isto resulta em 564 casos para se analisar, ficando inviável relatar todos eles neste documento. Em vista disso, optou-se por demonstrar apenas o resultado referente às barras com GD (barras #18 e #95 – sendo a barra #95 a mais distante da subestação), à barra mais próxima da subestação (barra #2) e à barra #39. Os resultados foram computados para o mínimo e o máximo valor do coeficiente de correlação entre as medições de potência ativa e reativa, isto é, $\rho = 0,8$ e $\rho = 0,95$. A normalidade foi checada utilizando-se a função nativa do MATLAB *kstest* (MathworksTM 2004) para os 100 elementos da amostra, com $\alpha = 5\%$ (valor-p_{critico} = 95%) e $D_{critico} = 0,134$.

Para um coeficiente de correlação $\rho = 0,8$, a função *kstest* retornou as respectivas estatísticas mostradas na Tabela 6.2.

Tabela 6.2: Estatísticas fornecidas pela função *kstest* para $\rho = 0,8$.

Variável	D_n	valor-p (%)
θ_2	0,0571	11,8451
V_2	0,0595	15,0353
θ_{18}	0,0811	49,9890
V_{18}	0,0800	48,3015
θ_{39}	0,0769	43,2234
V_{39}	0,0987	73,4740
θ_{95}	0,0918	91,8721
V_{95}	0,0770	92,9931

A partir dos resultados mostrados na Tabela 6.2 não se pode rejeitar a hipótese nula H_0 , ou seja, as variáveis θ_2 , V_2 , θ_{18} , V_{18} , θ_{39} , V_{39} , θ_{95} e V_{95} possuem distribuição normal para $\rho = 0,8$.

A Figura 6.3 indica qualitativamente que as distribuições de θ_{95} e V_{95} são normais. Esta hipótese foi comprovada através do KS-Teste e os resultados são ilustrados no gráfico de probabilidade normal da Figura 6.4. Os pontos em azul na Figura 6.4 representam os 100 elementos da amostra. Quanto mais próximo da linha vermelha mais tendência a distribuição proposta tem em ser normal.

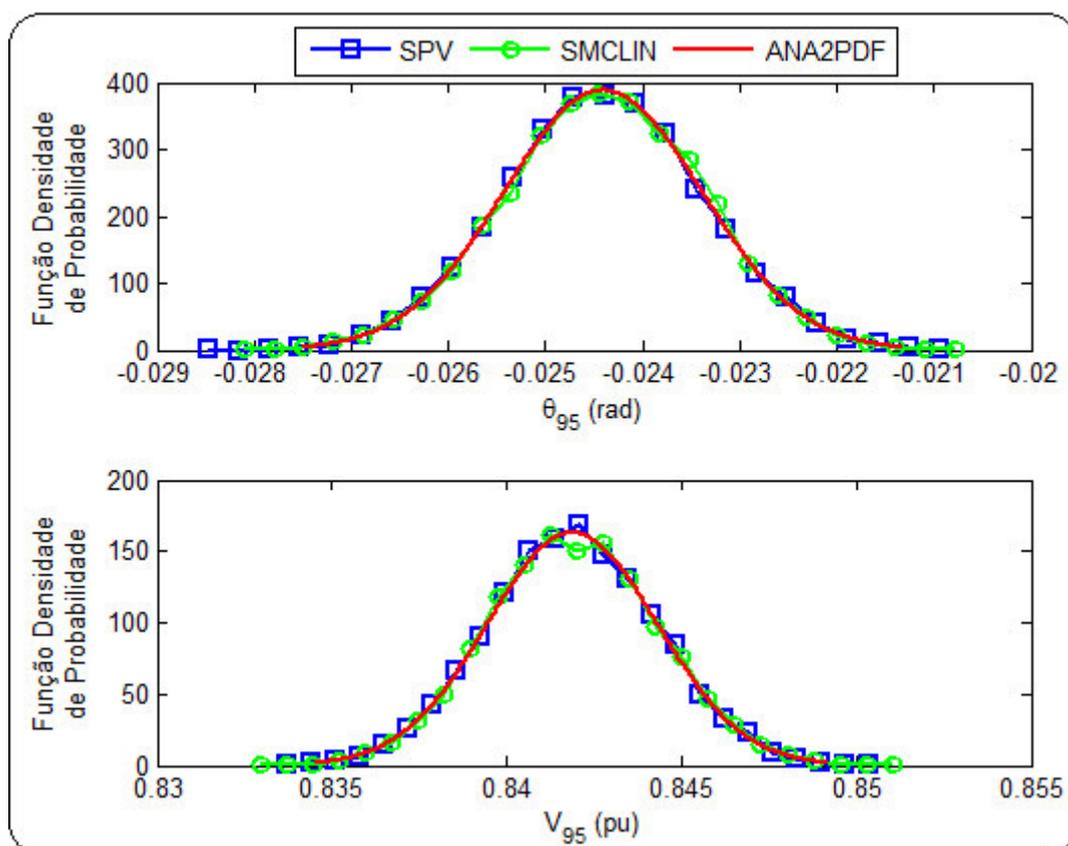


Figura 6.3: Histogramas para a barra #95 (módulo e fase da tensão) do sistema UKGDS para correlação entre medições de potência ativa e reativa $\rho = 0,8$.

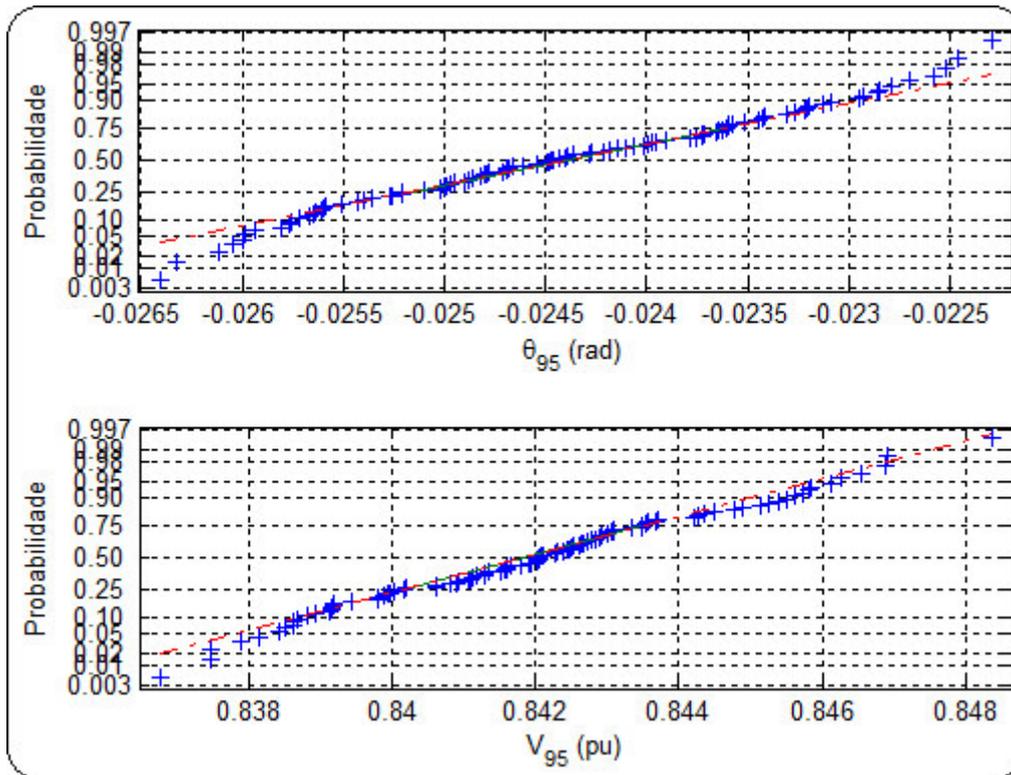


Figura 6.4: Gráfico de probabilidade normal para θ_{95} e V_{95} para correlação entre medições de potência ativa e reativa $\rho = 0,8$.

Para um coeficiente de correlação $\rho = 0,95$, a função *kstest* retornou as respectivas estatísticas mostradas na Tabela 6.3.

Tabela 6.3: Estatísticas fornecidas pela função *kstest* para $\rho = 0,95$.

Variável	D_n	valor-p (%)
θ_2	0,0527	7,0184
V_2	0,0679	27,9541
θ_{18}	0,0858	57,0045
V_{18}	0,0971	71,6866
θ_{39}	0,0672	26,8385
V_{39}	0,0550	9,3796
θ_{95}	0,0737	37,7858
V_{95}	0,0701	31,7515

A partir dos resultados mostrados na Tabela 6.3 não se pode rejeitar a hipótese nula H_0 , ou seja, as variáveis θ_2 , V_2 , θ_{18} , V_{18} , θ_{39} , V_{39} , θ_{95} e V_{95} possuem distribuição normal para $\rho = 0,95$.

Os histogramas de θ_{95} e V_{95} para $\rho = 0,95$ são ilustrados na Figura 6.5 e o gráfico de probabilidade normal na Figura 6.6.

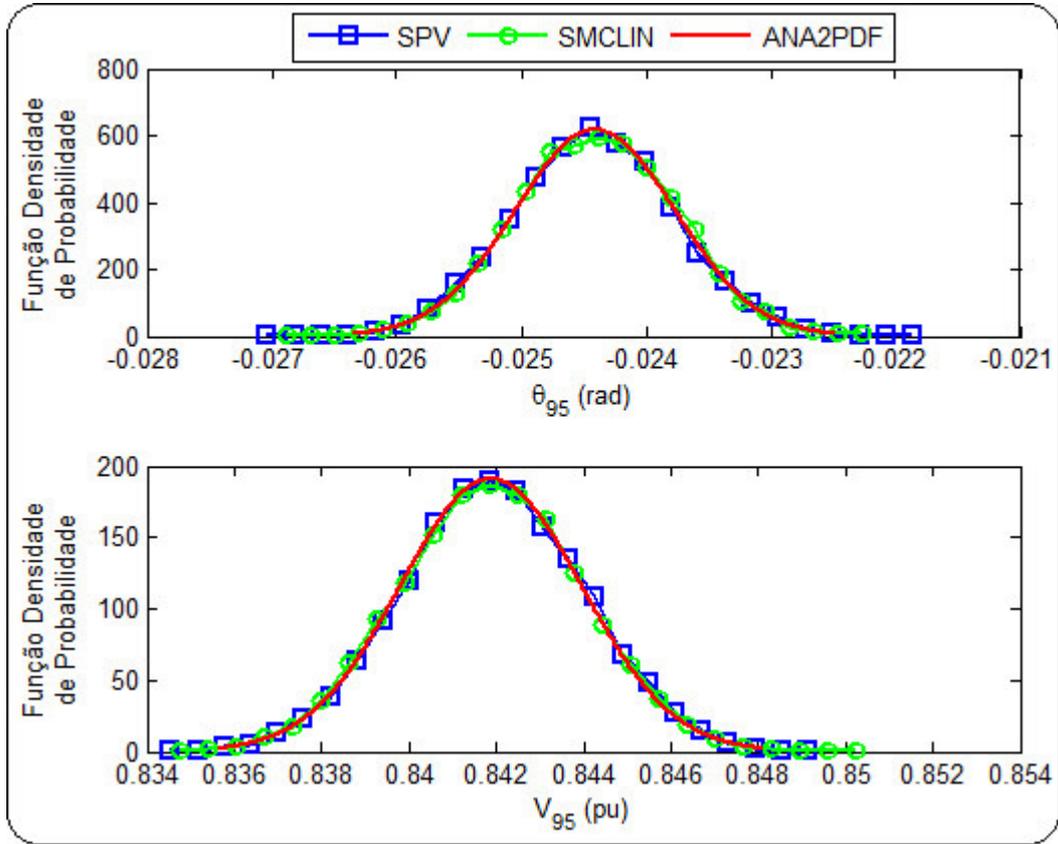


Figura 6.5: Histogramas para a barra #95 (módulo e fase da tensão) do sistema UKGDS para correlação entre medições de potência ativa e reativa $\rho = 0,95$.

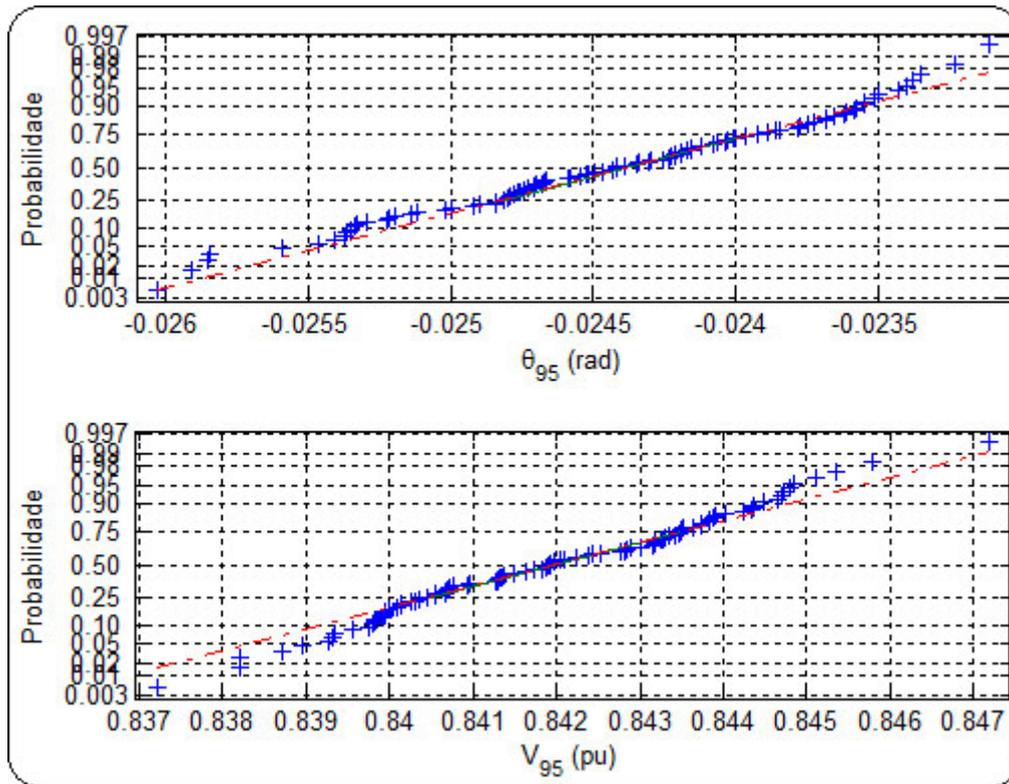


Figura 6.6: Gráfico de probabilidade normal para θ_{95} e V_{95} para correlação entre medições de potência ativa e reativa $\rho = 0,95$.

6.4.2 Testes de hipóteses para o coeficiente de correlação populacional

De posse dos resultados da subseção anterior, pode-se determinar a significância de um coeficiente de correlação populacional r . Um teste de hipótese para r pode ser mono ou bicaudal. Neste trabalho usa-se o teste monocaudal, devido ao tamanho da amostra (100 indivíduos oriundos da SMC). Para amostras grandes ($N \geq 25$) consideram-se as seguintes hipóteses (Montgomery e Runger, 2011):

$$H_0: \rho = \rho_0 \text{ (a correlação é próxima ou equivalente a } \rho_0\text{);}$$

$$H_1: \rho \neq \rho_0 \text{ (a correlação não é próxima ou não equivale a } \rho_0\text{).}$$

e utiliza-se a estatística dada por (6.2) para avaliar as hipóteses:

$$Z_0 = \frac{Z - \mu_Z}{\sigma_Z} \tag{6.2}$$

em que:

$$Z = \frac{1}{2} \ln \left(\frac{1+r}{1-r} \right), \mu_Z = \frac{1}{2} \ln \left(\frac{1+\rho_0}{1-\rho_0} \right) \text{ e } \sigma_Z = \frac{1}{\sqrt{N-3}} \quad (6.3)$$

A estatística Z_0 é normalmente distribuída com média μ_Z e desvio padrão σ_Z .

A regra de decisão do teste é rejeitar H_0 se $|Z_0| > Z_{critico}$. Onde $Z_{critico} = z_{\alpha/2}$ é obtido da tabela de valores da distribuição normal padronizada e α é o nível de confiança do teste.

Para o problema analisado nesta dissertação, o interesse é saber se o módulo e a fase da tensão em cada barra do STD_UKGDS95 (exceto a subestação) tem correlação entre si. Desse modo, o teste de correlação populacional de (6.2) foi aplicado ao STD_UKGDS95. Considerou-se uma amostra de 100 elementos devido a SMC. Excluindo-se a barra da subestação, o sistema tem 94 conjuntos bivariados para analisar a hipótese de correlação e três possíveis valores para o coeficiente de correlação ρ que foram empregados nos testes. Isto resulta em 282 casos a serem analisados, ficando inviável relatar todos neste documento. Em vista disso, optou-se por demonstrar apenas o resultado referente à barra mais distante da subestação (distância elétrica), a barra #95, levando-se em conta o mínimo e o máximo valor para o coeficiente de correlação entre as medições de potência ativa e reativa, isto é, $\rho = 0,8$ e $\rho = 0,95$.

Para $\rho = 0,8$, deseja-se saber se a correlação amostral r é tão pequena quanto $\rho_0 = 0$. Com nível de confiança $\alpha = 0,001\%$, tem-se $Z_{critico} = 4,4171$ e as 100 simulações resultaram em uma correlação amostral $r = 0,4078$. Deste modo, $Z_0 = 4,2637$. Como $|Z_0| < Z_{critico}$, não se pode rejeitar a hipótese $H_0: \rho = \rho_0 = 0$, ou seja, pode-se assumir que θ_{95} e V_{95} são descorrelacionadas. A Figura 6.7 ilustra esse resultado.

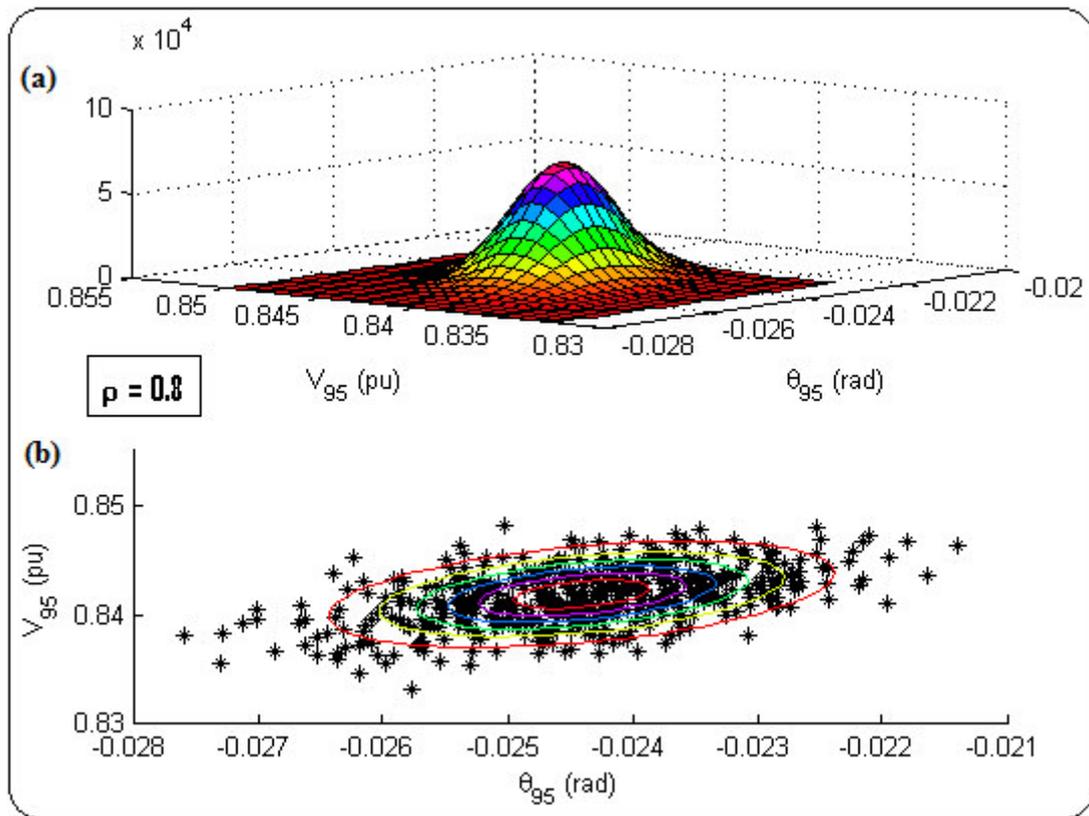


Figura 6.7: (a) PDF da distribuição bivariada de θ_{95} e V_{95} . (b) Diagrama de dispersão e as curvas de nível da PDF bivariada de θ_{95} e V_{95} para correlação entre medições de potência ativa e reativa $\rho = 0,8$.

Do mesmo modo, para $\rho = 0.95$, deseja-se saber se a correlação amostral r é tão pequena quanto $\rho_0 = 0$. Com nível de confiança $\alpha = 0,001\%$, tem-se $Z_{critico} = 4,4171$ e as 100 simulações resultaram em uma correlação amostral $r = 0,3418$. Deste modo, $Z_0 = 3,5069$. Como $|Z_0| < Z_{critico}$, não se pode rejeitar a hipótese $H_0: \rho = \rho_0 = 0$, ou seja, pode-se assumir que θ_{95} e V_{95} são descorrelacionadas. A Figura 6.8 ilustra esse resultado.

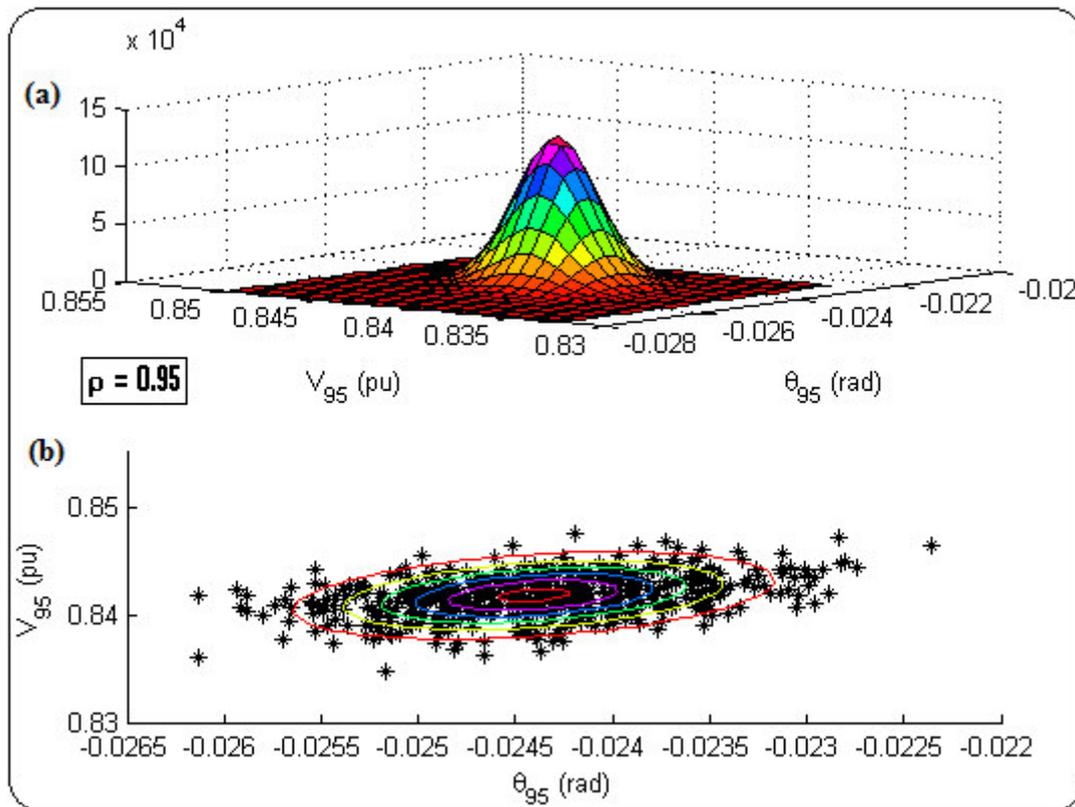


Figura 6.8: (a) PDF da distribuição bivariada de θ_{95} e V_{95} . (b) Diagrama de dispersão e as curvas de nível da PDF bivariada de θ_{95} e V_{95} para correlação entre medições de potência ativa e reativa $\rho = 0,95$.

Os resultados obtidos acima validam as hipóteses assumidas no capítulo 5 para o cálculo do índice de probabilidade P_i . Isto é, para computar o índice P_i basta multiplicar as probabilidades individuais dos erros relativos de magnitude e fase da tensão na barra i .

6.5 Análise dos Métodos SPV, SMCLIN e ANA2PDF na Alocação de Medidores em Redes de Distribuição

Para a análise de desempenho dos métodos de alocação de medidores SPV, SMCLIN e ANA2PDF adotaram-se os seguintes estudos de caso:

- 1) **Caso #1:** Considerou-se a correlação entre as medições de injeção/fluxo de potência ativa e reativa igual a $\rho = 0,8$;

- 2) **Caso #2:** Considerou-se a correlação entre as medições de injeção/fluxo de potência ativa e reativa igual a $\rho = 0,9$;
- 3) **Caso #3:** Considerou-se a correlação entre as medições de injeção/fluxo de potência ativa e reativa igual a $\rho = 0,95$.

Os coeficientes de correlação dos Casos #1 e #2 são comumente utilizados na literatura técnica (Morales et al. 2010; Muscas et. al. 2013; Valverde, Saric e Terzija 2013) e o coeficiente de correlação do Caso #3 foi extraído da subseção 3.2.2, que analisou a correlação entre a demanda de potência ativa e reativa do STD_UKGDS95.

Para cada caso, considerou-se quatro combinações entre os erros máximos de medição real e de pseudo-medição. Os erros de medição real igual a 1% e de pseudo-medição igual a 20% são designados pela letra **A**; erros de medição real igual a 3% e de pseudo-medição igual a 20% são denominados pela letra **B**; erros de medição real igual a 1% e de pseudo-medição igual a 50% são denominados pela letra **C**, e; erros de medição real igual a 3% e de pseudo-medição igual a 50% são denominados pela letra **D**.

Para os subcasos **A** e **B**, os métodos SPV, SMCLIN e ANA2PDF não alocaram medidor no STD_UKGDS95 em todos os estudos de caso. Isso significa que para um erro máximo de pseudo-medição igual a 20% e uma variação entre 1% e 3% no erro máximo de medição real os erros relativos ϵ_V e ϵ_θ , em 95% dos casos, foram menores ou iguais ao limite estabelecido.

Os resultados da aplicação das técnicas de alocação de medidores propostas nesta dissertação, para todos os coeficientes de correlação entre medições de injeção/fluxo de potência ativa e reativa, são avaliados de acordo com três critérios: custo computacional (tempo de execução), número de medidores alocados e qualidade da solução segundo o mínimo índice de probabilidade bivariado P_i .

Nas tabelas referentes ao critério do número de medidores alocados, abreviou-se medidor de tensão, medidor de fluxo e total de medidores por **MT**, **MF** e **TT**, respectivamente.

Para o STD_UKGDS95 já encontram-se previamente alocados medidores de tensão na subestação e nas GDs (barras #1, #18 e #95, respectivamente) e medidores de fluxo de potência na subestação e nas GDS (ramos 1/2, 19/18 e 82/95, respectivamente).

6.5.1 Resultados do Caso #1

A Tabela 6.4 mostra o desempenho dos métodos em relação aos índices P_i e R_i . A partir da Tabela 6.4, pode-se perceber que, embora os métodos SMCLIN e ANA2PDF sejam baseados na aproximação de primeira ordem (linearização de H em torno do valor verdadeiro) das funções não-lineares associadas às medições, os valores dos índices de probabilidade P_i e R_i fornecidos por ambos os métodos são muito próximos daqueles calculados pelo SPV que se baseia na SMC não-linear.

Tabela 6.4: Valores mínimo e máximo dos índices P_i e R_i para o Caso #1.

Erros de medição			Índices P_i^{min} e R_i^{max} (%)					
Medição Real (%)	Pseudo – Medição (%)	SPV			SMCLIN		ANA2PDF	
		P_i^{min}	R_i^{max}	P_i^{min}	R_i^{max}	P_i^{min}	R_i^{max}	
A	1	20	100,0	0,0	100,0	0,0	99,7480	0,2520
B	3	20	97,0	3,0	97,0	3,0	97,2730	2,7270
C	1	50	99,0	1,0	98,0	2,0	98,3660	1,6340
D	3	50	99,0	1,0	97,0	3,0	97,1085	2,8915

O número de medidores alocados segundo os métodos SPV, SMCLIN e ANA2PDF é apresentado na Tabela 6.5.

Tabela 6.5: Comparação entre o número de medidores alocados para o Caso #1.

Erros de medição			Medidores alocados								
Medição Real (%)	Pseudo – Medição (%)	SPV			SMCLIN			ANA2PDF			
		MT	MF	TT	MT	MF	TT	MT	MF	TT	
A	1	20	0	0	0	0	0	0	0	0	0
B	3	20	0	0	0	0	0	0	0	0	0
C	1	50	0	1	1	0	1	1	0	1	1
D	3	50	0	2	2	0	2	2	0	2	2

Como mostrado na Tabela 6.5, tanto o método de referência, SPV, quanto os propostos, SMCLIN e ANA2PDF, alocaram a mesma quantidade de medidores. Para o Caso #1-C, os métodos SPV, SMCLIN e ANA2PDF alocaram 1 medidor de fluxo de

potência no mesmo local do sistema, o ramo 2/4, como pode ser visto na Figura 6.9.

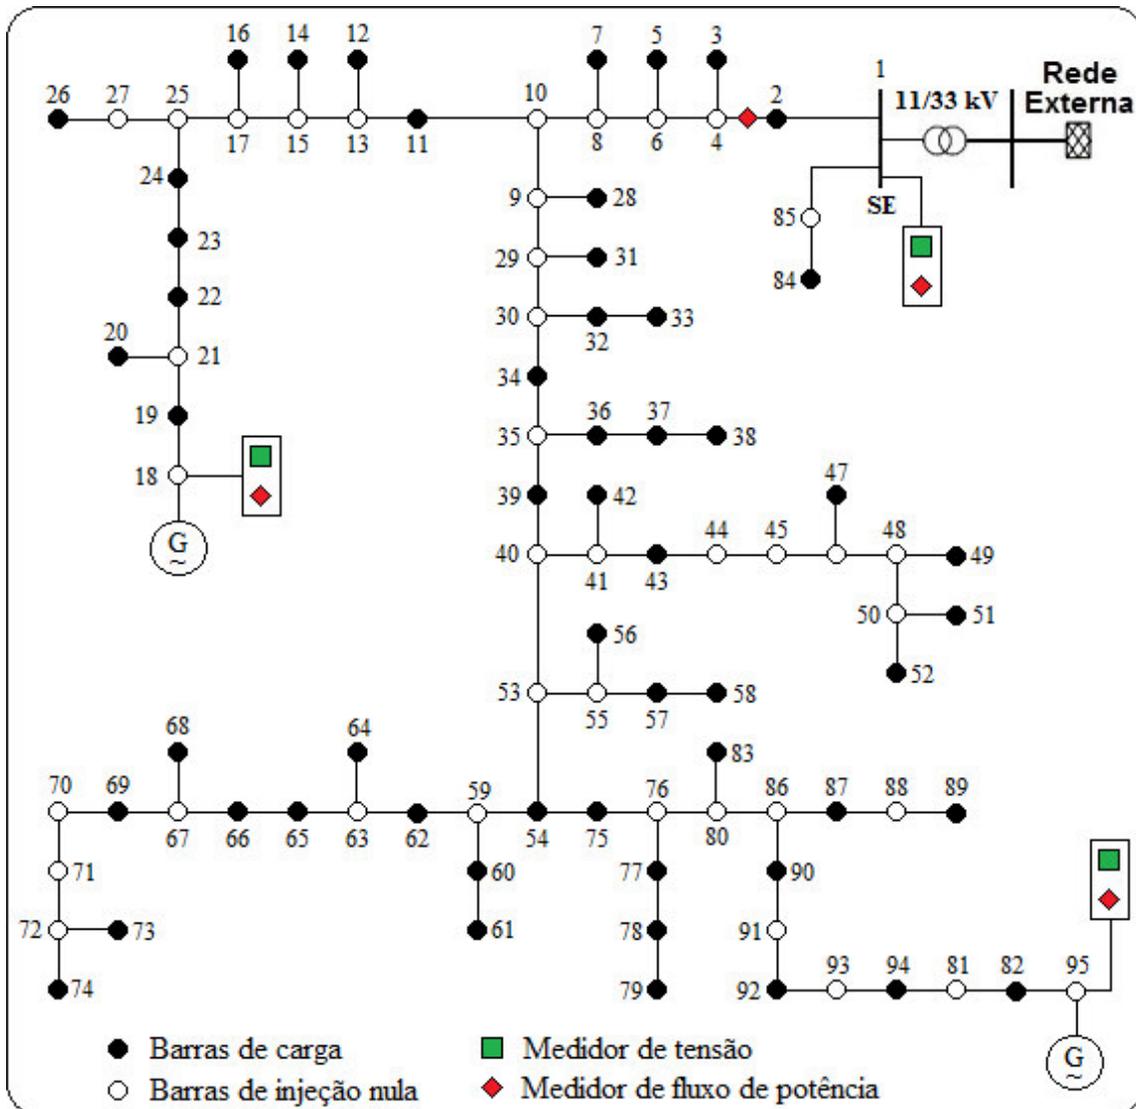


Figura 6.9: Alocações dos medidores obtidas pelos métodos SPV, SMCLIN e ANA2PDF para o Caso #1-C.

A Figura 6.10 ilustra o comportamento dos erros relativos na magnitude da tensão estimada segundo o método SPV para o Caso #1-C. Nesta figura, os gráficos plotados com símbolo “+” estão associados com o valor médio dos erros. Como pode ser visto na Figura 6.10(a), a ausência de medidores no sistema não afeta significativamente a precisão da magnitude da tensão estimada considerando-se um erro máximo de 50% para pseudo-medições. Este resultado é devido ao caso base já possuir três medidores de tensão instalados: dois nas barras de GD e um na subestação.

Entretanto, após a alocação de 1 medidor de fluxo, os erros relativos estimados de magnitude da tensão ficaram bem abaixo de 0,5%, como pode ser visto na Figura 6.10(b).

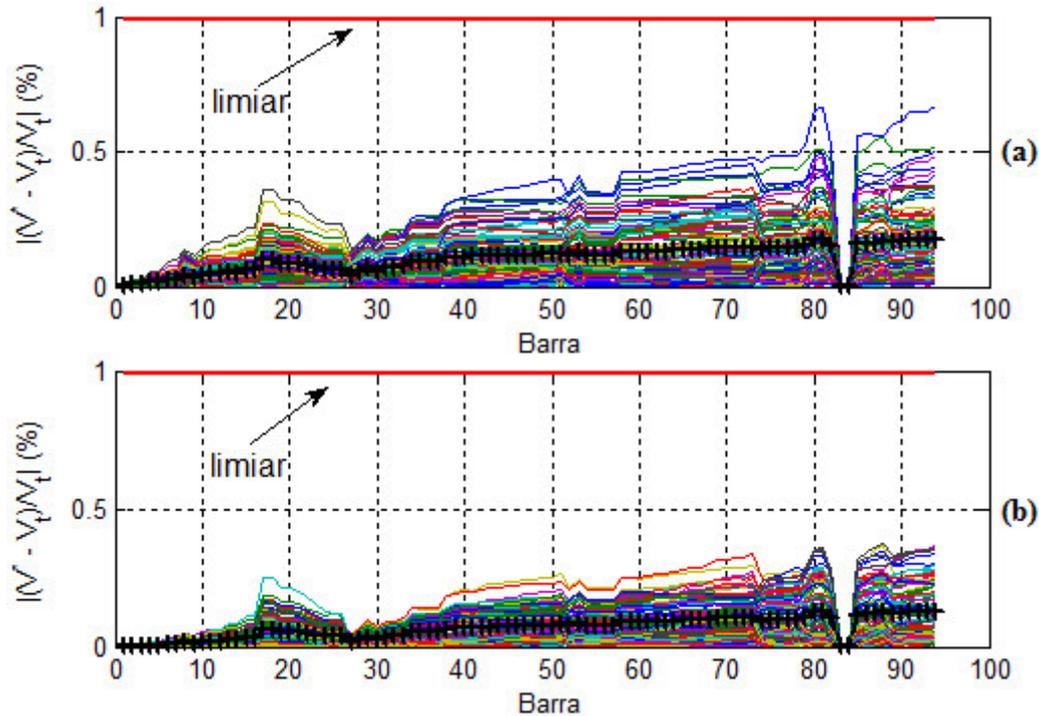


Figura 6.10: Erros relativos na magnitude estimada da tensão obtidos pelo SPV. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.

A Figura 6.11 demonstra o comportamento dos erros relativos na fase da tensão estimada segundo o método SPV para o Caso #1-C. Diferentemente da magnitude da tensão, a Figura 6.11(a) indica que a ausência de medidores no sistema afeta significativamente a precisão da fase da tensão estimada considerando-se um erro máximo de 50% para pseudo-medições. Entretanto, após a alocação de 1 medidor de fluxo, os erros relativos estimados de fase da tensão superaram em apenas uma simulação o limiar pré-estabelecido de máximo erro relativo de fase ($\epsilon_\theta \leq 5\%$), como pode ser visto na Figura 6.11(b). Isso significa que dos 100 elementos da amostra gerada pelo método SPV, 99 estão com o erro relativo na fase estimada da tensão abaixo do limiar especificado. Ou seja, o critério de 95% dos elementos da amostra é satisfeito.

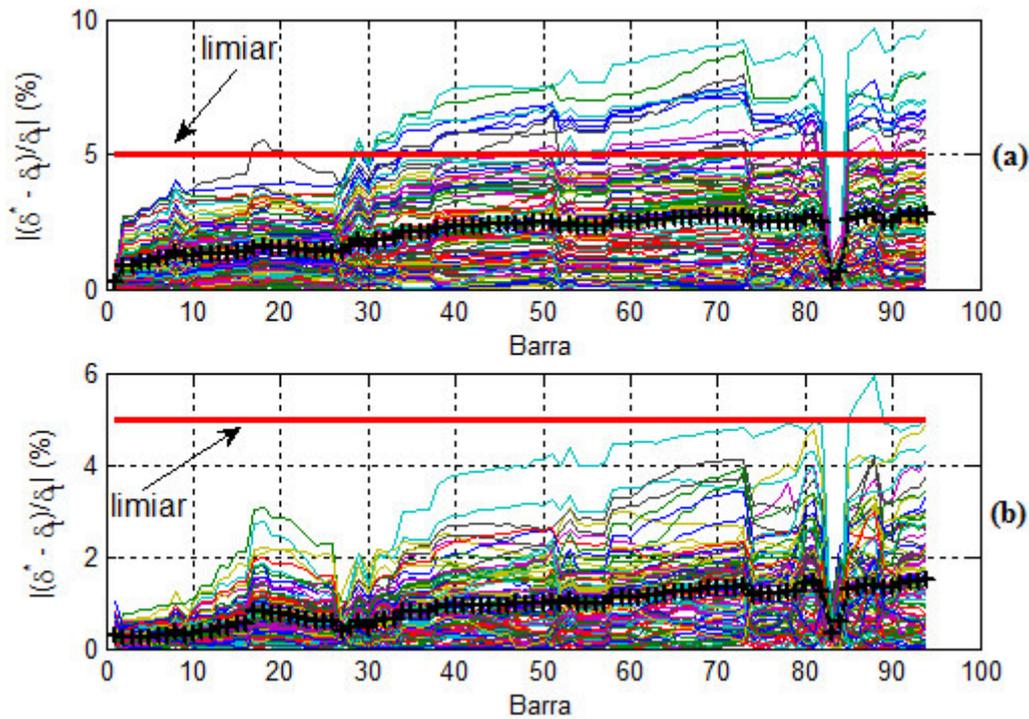


Figura 6.11: Erros relativos na fase estimada da tensão obtidos pelo SPV. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.

A Figura 6.12 ilustra o comportamento dos índices de probabilidade bivariados P_i e R_i segundo o método SPV para o Caso #1-C. Como pode ser visto na Figura 6.12(a), a ausência de medidores no sistema fornece um R_i máximo de 20% para um erro máximo de 50% de pseudo-medições. Este valor está bem acima dos 5% estipulados como índice máximo (equação (4.16)). Após a alocação de 1 medidor de fluxo, o risco máximo, R_i , não ultrapassou 1% como mostrado na Figura 6.12(b).

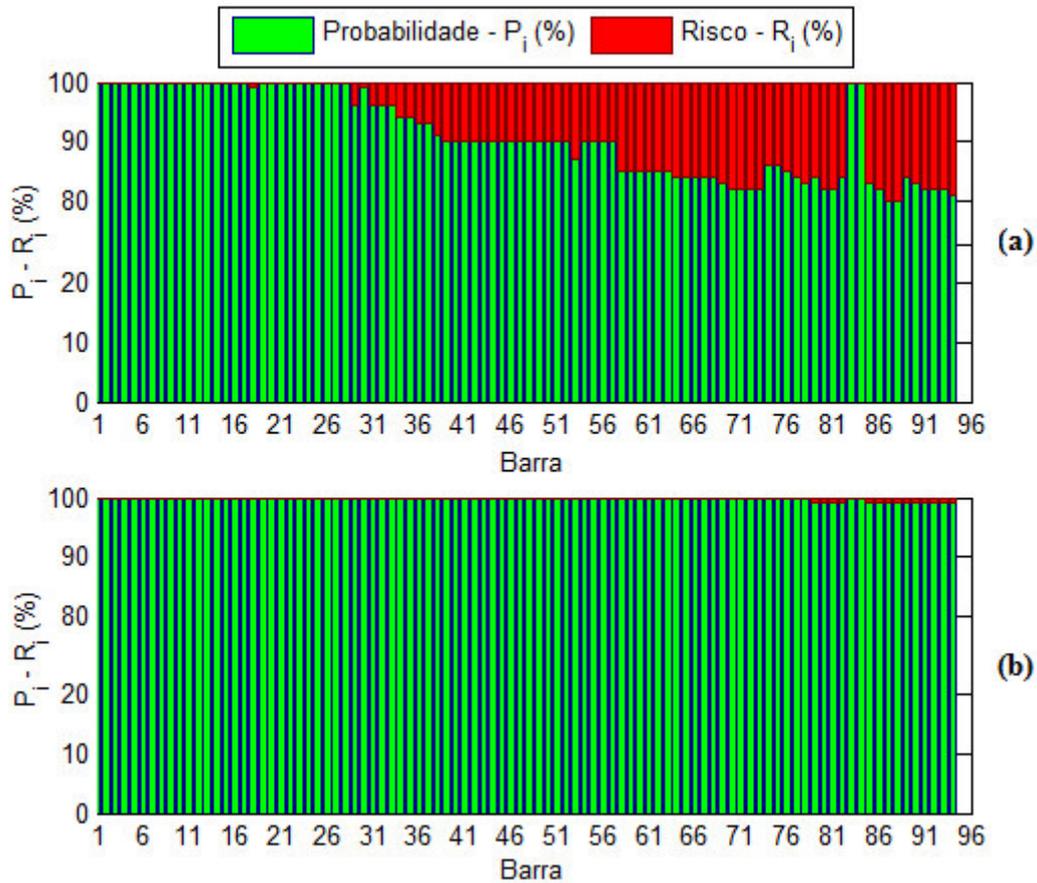


Figura 6.12: Comparação entre P_i e R_i obtidos pelo SPV para o Caso #1-C. (a) sem a presença de medidor (b) com a alocação de 1 medidor.

A Figura 6.13 ilustra o comportamento dos erros relativos na magnitude da tensão estimada segundo o método SMCLIN para o Caso #1-C. Os valores médios dos erros estão associados com o gráfico plotado com o símbolo “+”. Assim como para o método SPV, a ausência de medidores no sistema não afeta a precisão da magnitude da tensão estimada considerando-se um erro máximo de 50% para pseudo-medições, como pode ser visto na Figura 6.13(a).

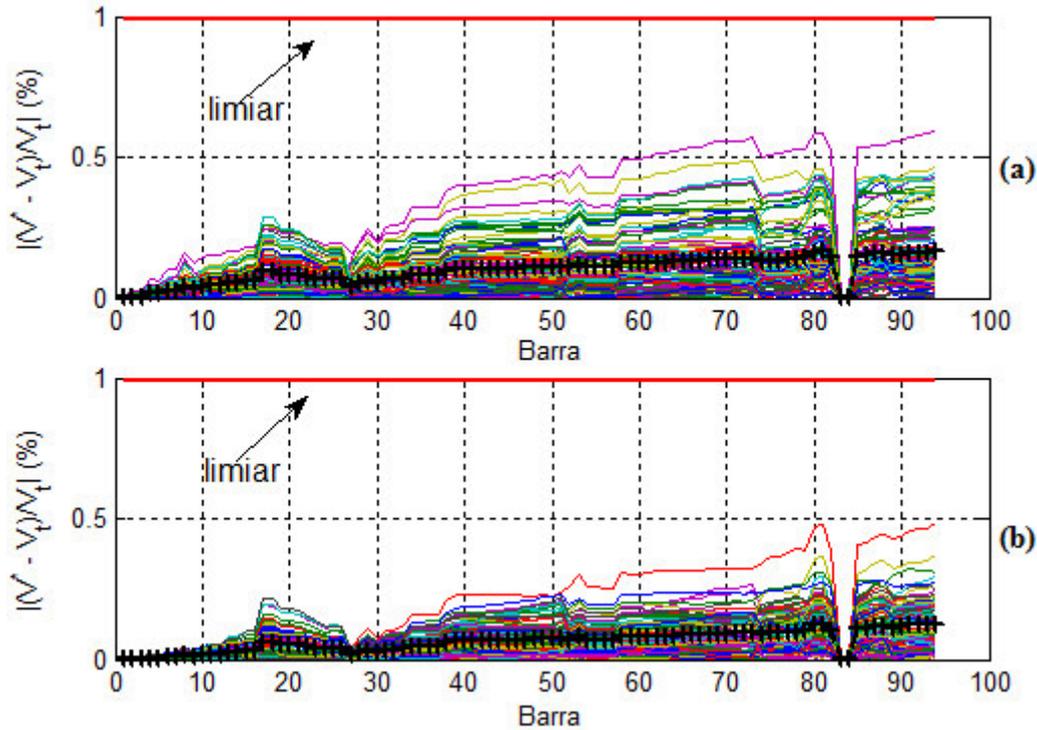


Figura 6.13: Erros relativos na magnitude estimada da tensão calculados com o SMCLIN para o Caso #1-C. (a) sem a presença de medidores (b) com a alocação de 1 medidor no sistema.

A Figura 6.14 mostra o comportamento dos erros relativos na fase da tensão estimada segundo o método SMCLIN para o Caso #1-C. A curva plotada nesta figura com o símbolo “+” corresponde ao valor médio dos erros. Diferentemente da magnitude da tensão, a Figura 6.14(a) indica que a ausência de medidores no sistema afeta significativamente a precisão da fase da tensão estimada considerando-se um erro máximo de 50% para pseudo-medições. Entretanto, assim como no método SPV, após a alocação de 1 medidor de fluxo, os erros relativos estimados de fase da tensão superaram em apenas dois elementos da amostra o limiar pré-estabelecido de máximo erro relativo de fase ($\epsilon_{\theta} \leq 5\%$), como pode ser visto na Figura 6.14(b). Isso significa que em 98% dos elementos da amostra o erro relativo na fase estimada da tensão está abaixo do limiar especificado. Conseqüentemente, o critério de 95% da amostra é atendido.

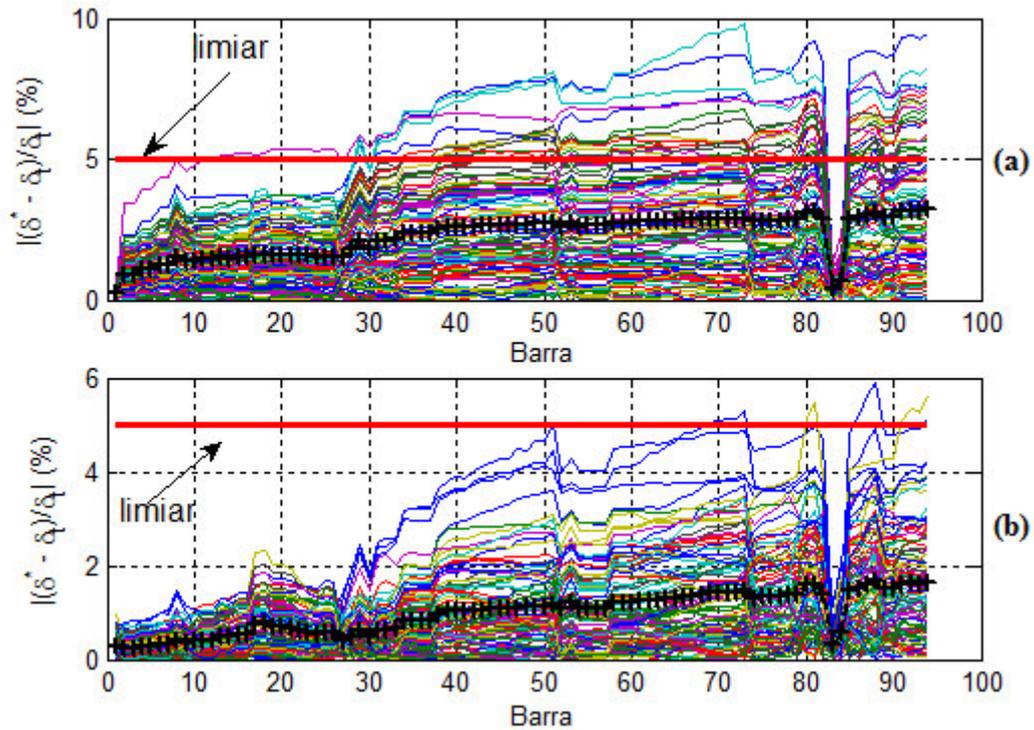


Figura 6.14: Erros relativos na fase estimada da tensão calculados pelo SMCLIN para o Caso #1-C. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.

A Figura 6.15 ilustra o comportamento dos índices de probabilidade bivariados P_i e R_i calculados pelo método SMCLIN para o Caso #1-C. Como pode ser visto na Figura 6.15(a), a ausência de medidores no sistema fornece um R_i máximo de 24% para um erro máximo de 50% de pseudo-medições. Este valor está bem acima dos 5% especificados como valor máximo do índice R_i (equação (4.16)). Contudo, após a alocação de 1 medidor de fluxo, o risco máximo, R_i , não ultrapassou 2%, como mostra a Figura 6.15(b).

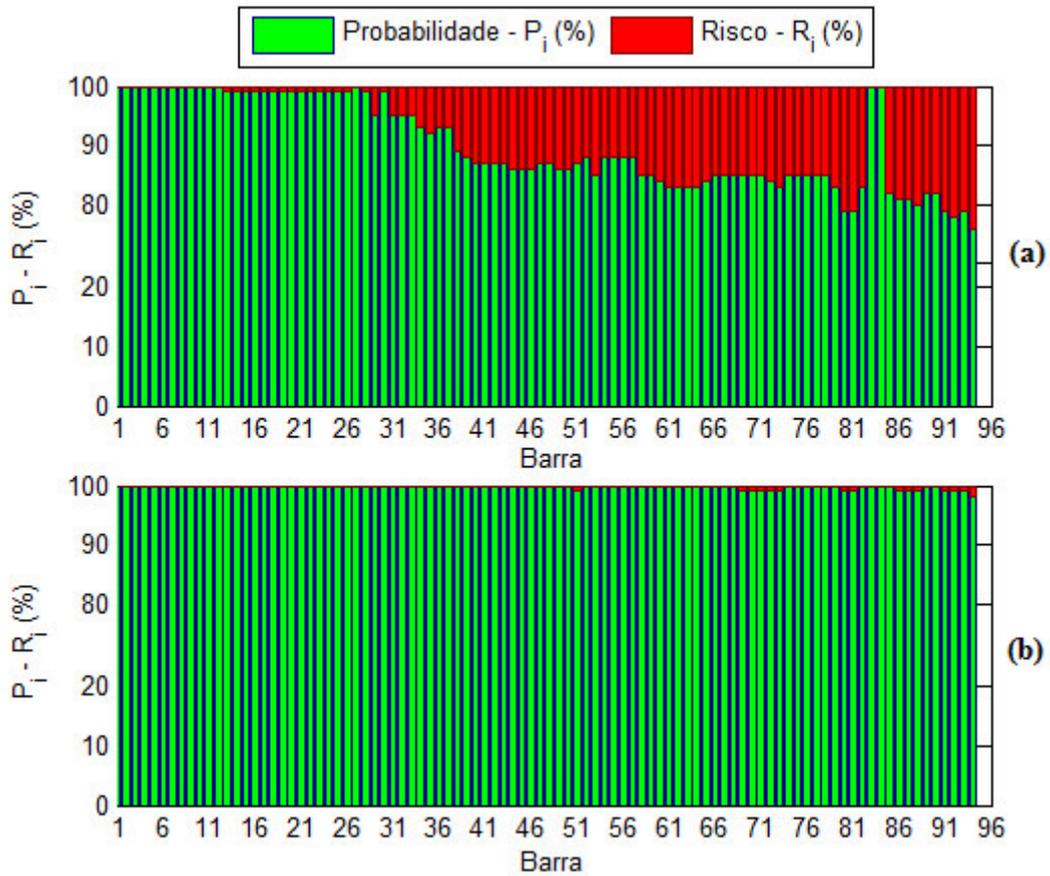


Figura 6.15: Comparação entre P_i e R_i calculados pelo SMCLIN para o Caso #1-C. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.

Para o Caso #1-D, os métodos SPV e SMCLIN alocaram dois medidores de fluxo de potência no mesmo ponto do sistema, os ramos 2/4 e 54/75, como pode ser visto na Figura 6.16. Entretanto, o método ANA2PDF alocou dois medidores de fluxo de potência nos ramos 2/4 e 40/53, como pode ser visto na Figura 6.17.

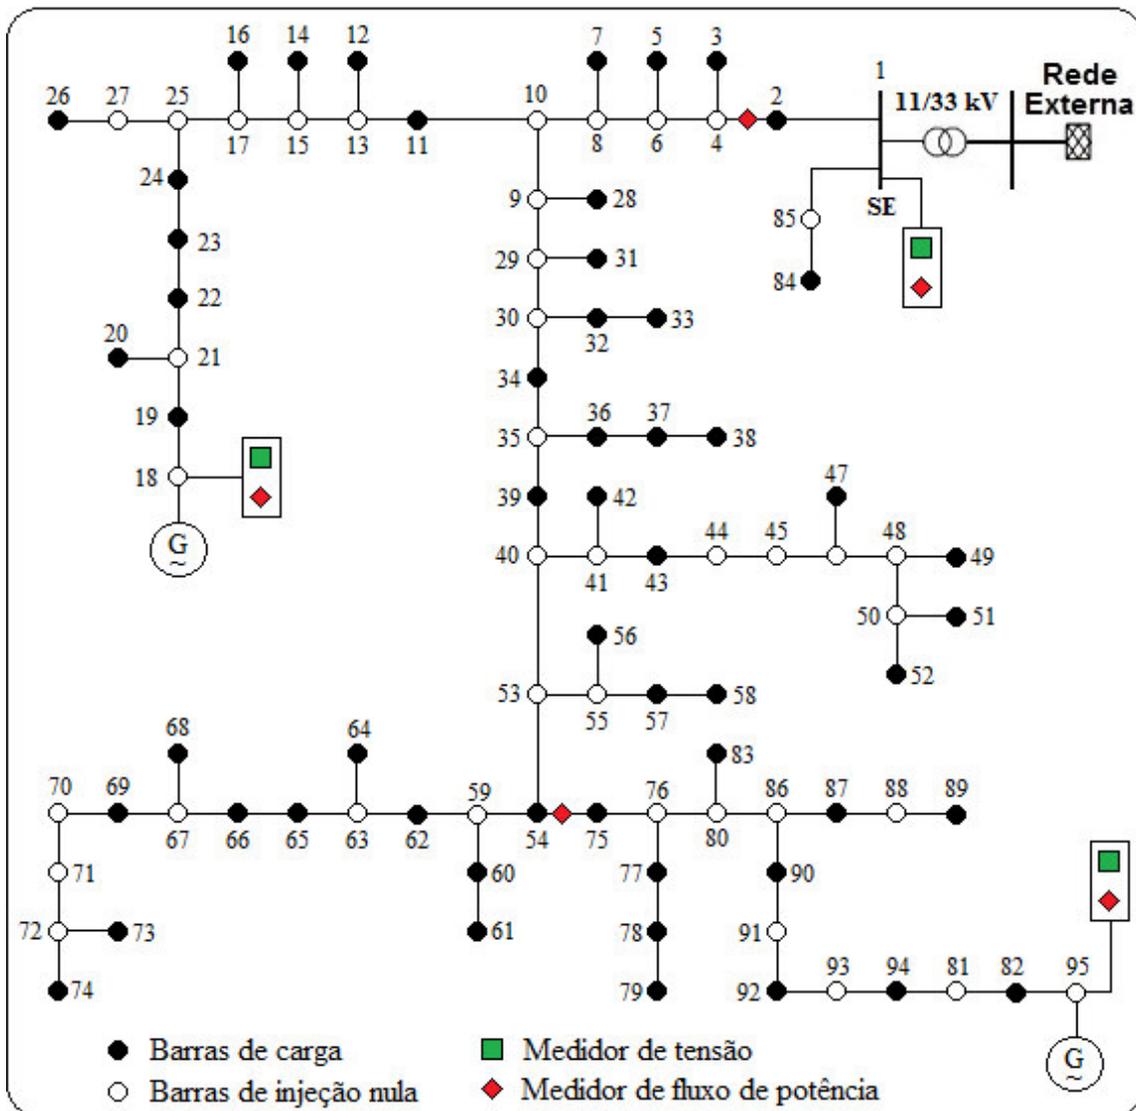


Figura 6.16: Alocação dos medidores segundo os métodos SPV e SMCLIN para o Caso #1-D.

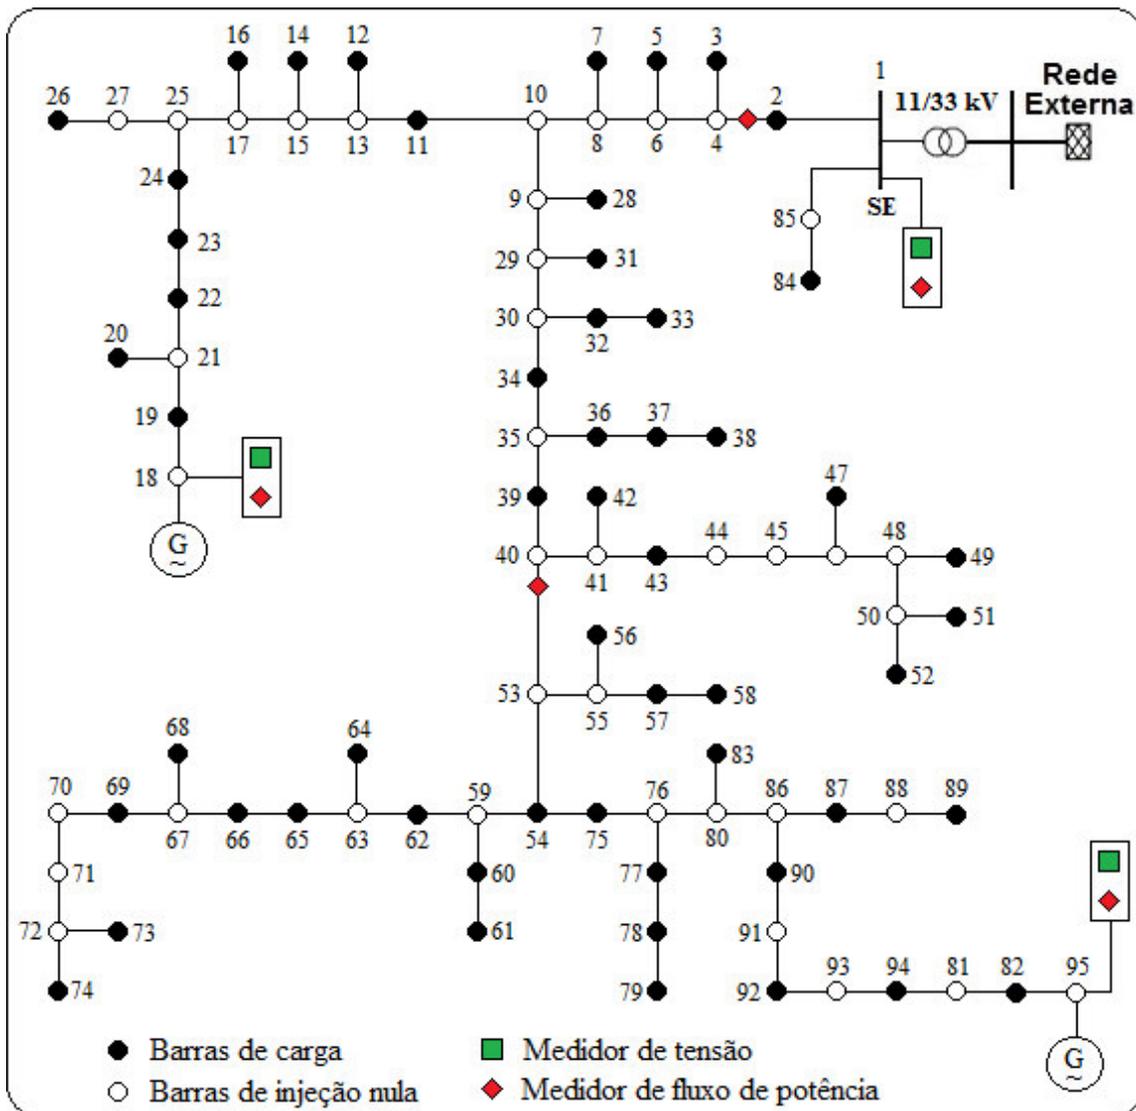


Figura 6.17: Alocação dos medidores obtida pelo método ANA2PDF para o Caso #1-D.

Com base nos resultados das Tabelas 6.4 e 6.5, nos gráficos dos riscos e erros relativos; pode-se concluir que desconsiderar os termos de alta ordem na expansão de Taylor de $h(\hat{x})$ (equação (5.2)) não prejudicou o desempenho dos métodos, em relação ao método de referência SPV. Isto pode ser verificado tanto do ponto de vista econômico, pois as técnicas alocaram a mesma quantidade de medidores e, quanto do ponto de vista do processo de otimização da função objetivo, pois o índice P_i ficou bem próximo do índice fornecido pelo método SPV.

A Tabela 6.6 apresenta o tempo computacional dos três métodos de alocação de medidores.

Tabela 6.6: Comparação entre o tempo computacional dos métodos de alocação para o Caso #1.

	Erros de medição		Tempo computacional (s)		
	Medição Real (%)	Pseudo – Medição (%)	SPV	SMCLIN	ANA2PDF
A	1	20	2,704109	1,333933 (0,4933/50,6701%)	0,139819 (0,0517/94,8294%)
B	3	20	2,965219	1,300684 (0,4386/56,1353%)	0,144616 (0,0488/95,1229%)
C	1	50	5,158829	2,300268 (0,4459/55,4110%)	0,180028 (0,0349/96,5103%)
D	3	50	7,540370	3,294365 (0,4369/56,3103%)	0,203078 (0,0269/97,3068%)

Esta tabela também mostra os ganhos absolutos e as variações percentuais dos tempos de execução (valores entre parênteses à esquerda e direita da barra, respectivamente) dos métodos propostos em relação ao método SPV. Pode-se perceber que ambos os métodos propostos são mais eficientes, computacionalmente, do que o método SPV. Como o método SMCLIN tem embarcado a SMC, ele foi cerca de 2 (duas) vezes mais rápido, reduzindo, em média, um pouco mais do que 50% do tempo de execução do método SPV. Já o método analítico ANA2PDF, como não possui a SMC, produziu resultados bem mais expressivos. Na média, o ANA2PDF foi cerca de 27 (vinte e sete) vezes mais rápido do que o método de referência SPV, com um pouco mais de 4% do tempo computacional deste método no processo de alocação de medidor. No pior cenário, o Caso #1-D, os métodos SMCLIN e ANA2PDF produziram um desempenho bem mais satisfatório do que o SPV. É importante lembrar que todos os métodos alocaram a mesma quantidade de medidores. Neste cenário, o método ANA2PDF foi cerca de 37 (trinta e sete) vezes mais rápido do que o SPV, com uma economia de tempo da ordem de 97% do tempo que o SPV precisaria para alocar os dois medidores.

A Figura 6.18 fornece uma indicação gráfica do custo computacional dos métodos de alocação de medidores. Como já demonstrado pela Tabela 6.6, as barras correspondendo ao método ANA2PDF, em verde, permanecem praticamente constante mesmo com o incremento dos máximos erros de medição real e de pseudo-medição. Diferentemente do ANA2PDF, o SPV mostrou-se mais sensível ao incremento dos máximos erros de medição real e de pseudo-medição, assemelhando-se a um

comportamento polinomial ou exponencial.

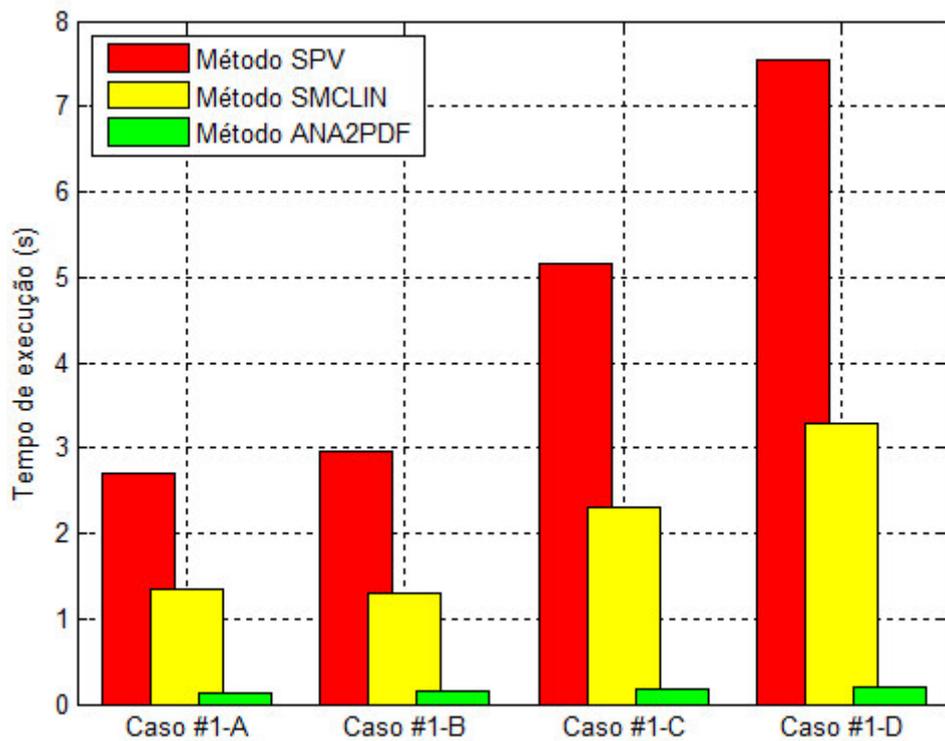


Figura 6.18: Comparação entre o tempo computacional dos métodos de alocação para o Caso #1.

6.5.2 Resultados do Caso #2

A Tabela 6.7 mostra o desempenho dos métodos em relação ao índice P_i e R_i para um coeficiente de correlação entre medições de injeção/fluxo de potência igual a 0,9. A partir da Tabela 6.7, pode-se perceber que tanto o SMCLIN quanto o ANA2PDF fornecem quantidades bem próximas para os índices de probabilidade P_i e R_i quando comparados ao método SPV. O número de medidores alocados no STD_UKGDS95 pelos métodos SPV, SMCLIN e ANA2PDF é apresentado na Tabela 6.8.

Tabela 6.7: Valores mínimo e máximo dos índices P_i e R_i para o Caso #2.

Erros de medição		Índices P_i^{min} e R_i^{max} (%)						
Medição Real (%)	Pseudo – Medição (%)	SPV		SMCLIN		ANA2PDF		
		P_i^{min}	R_i^{max}	P_i^{min}	R_i^{max}	P_i^{min}	R_i^{max}	
A	1	20	100,0	0,0	100,0	0,0	99,9893	0,0107
B	3	20	100,0	0,0	100,0	0,0	99,5722	0,4278
C	1	50	100,0	0,0	100,0	0,0	99,9917	0,0083
D	3	50	98,0	2,0	98,0	2,0	97,6906	2,3094

Tabela 6.8: Comparação entre o número de medidores alocados para o Caso #2.

Erros de medição		Medidores alocados									
Medição Real (%)	Pseudo – Medição (%)	SPV			SMCLIN			ANA2PDF			
		MT	MF	TT	MT	MF	TT	MT	MF	TT	
A	1	20	0	0	0	0	0	0	0	0	0
B	3	20	0	0	0	0	0	0	0	0	0
C	1	50	0	1	1	0	1	1	0	1	1
D	3	50	0	1	1	0	1	1	0	1	1

Conforme mostrado na Tabela 6.8, tanto o método de referência, SPV, quanto os propostos, SMCLIN e ANA2PDF, alocaram a mesma quantidade de medidores. Para o Caso #2-C, os métodos SPV, SMCLIN e ANA2PDF alocaram 1 medidor de fluxo de potência nos ramos 29/30, 2/4 e 10/9, respectivamente. Para cada método, as alocações dos medidores no sistema STD_UKGDS95 podem ser vistas nas Figuras 6.19, 6.20 e 6.21.

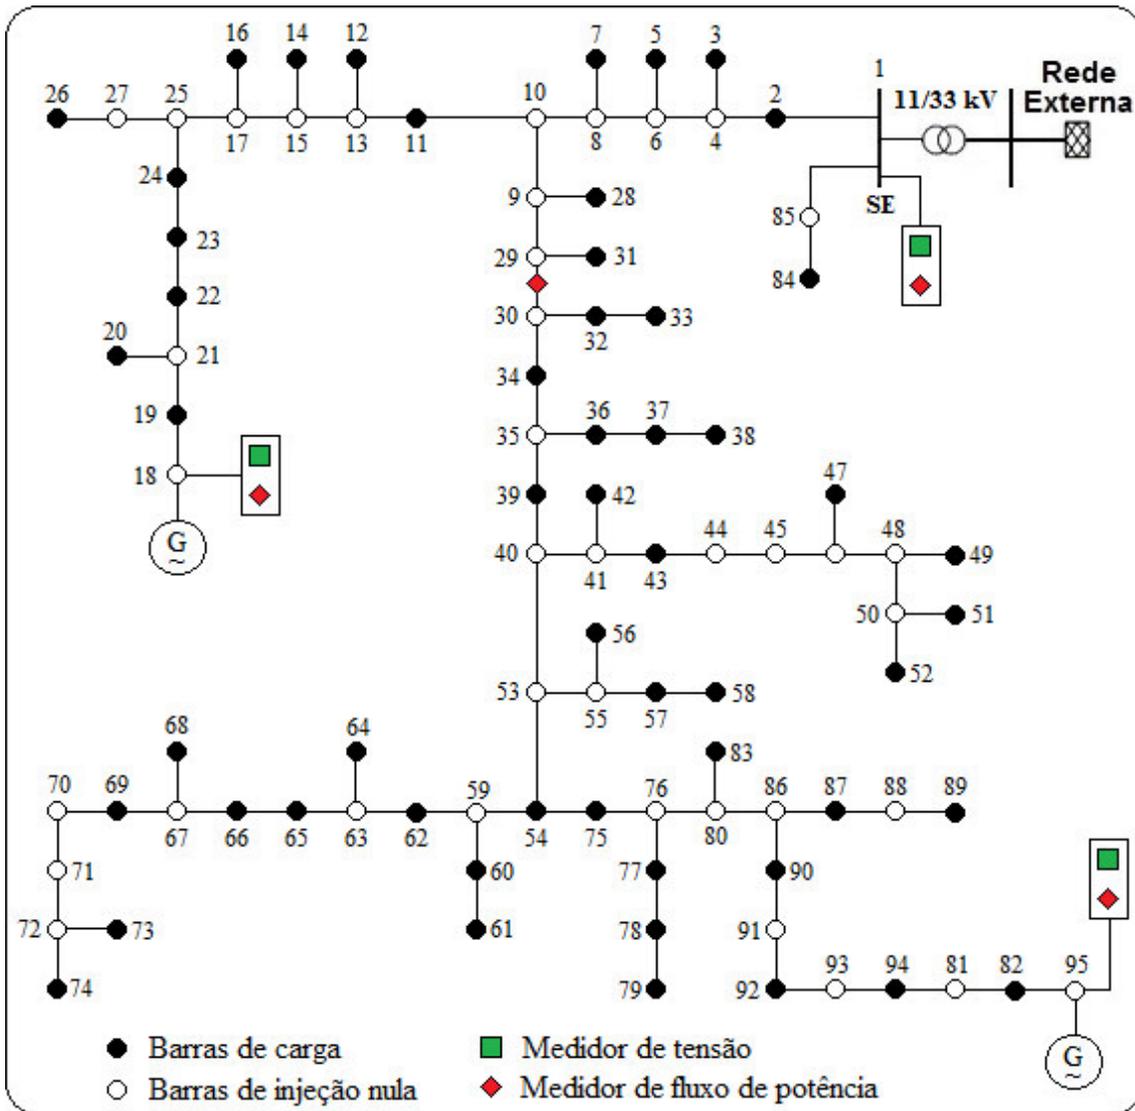


Figura 6.19: Alocação dos medidores obtida pelo método SPV para o Caso #2-C.

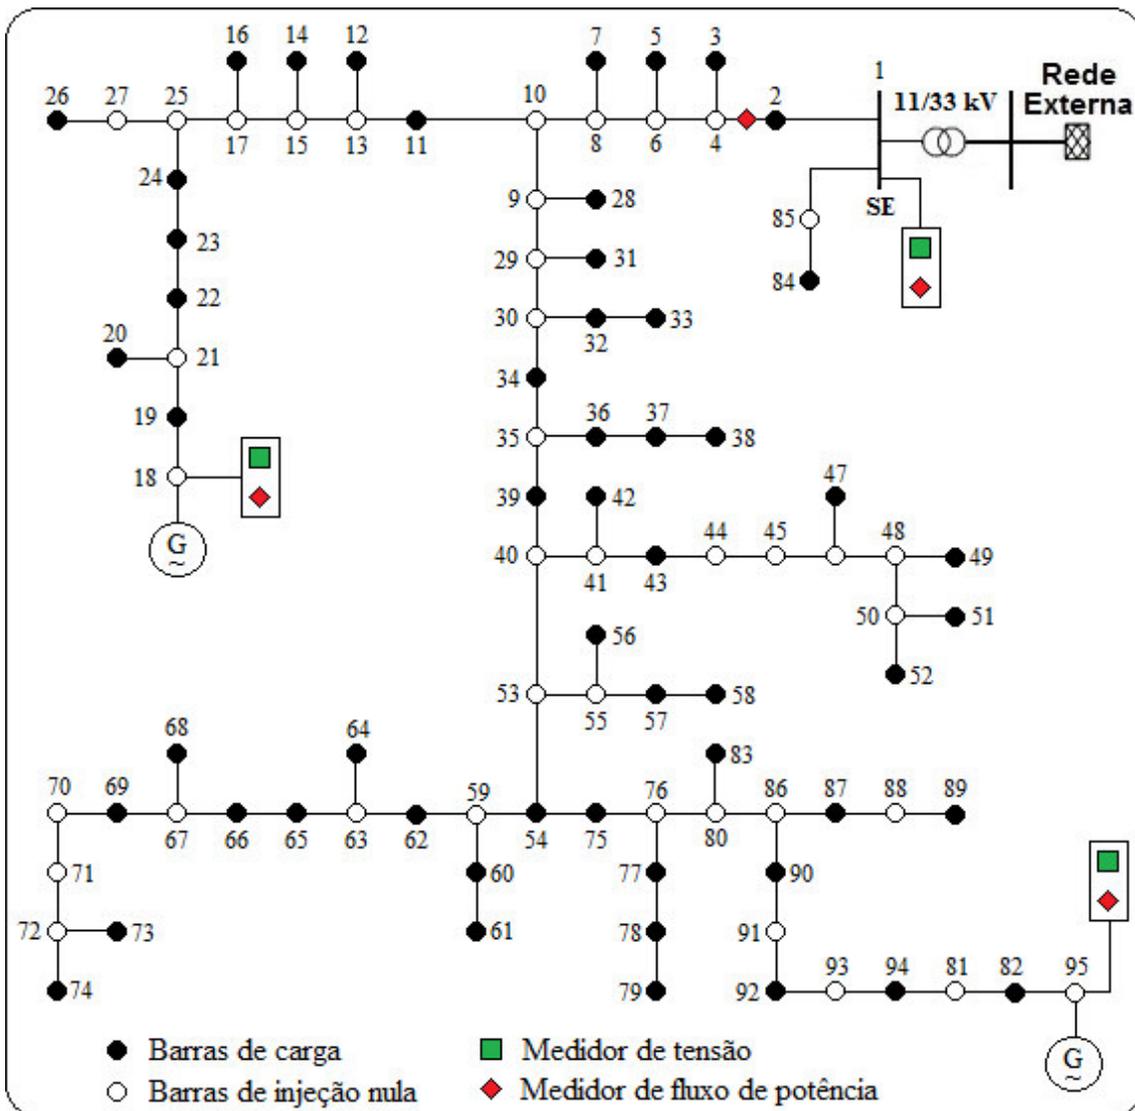


Figura 6.20: Alocação dos medidores obtida pelo método SMCLIN para o Caso #2-C.

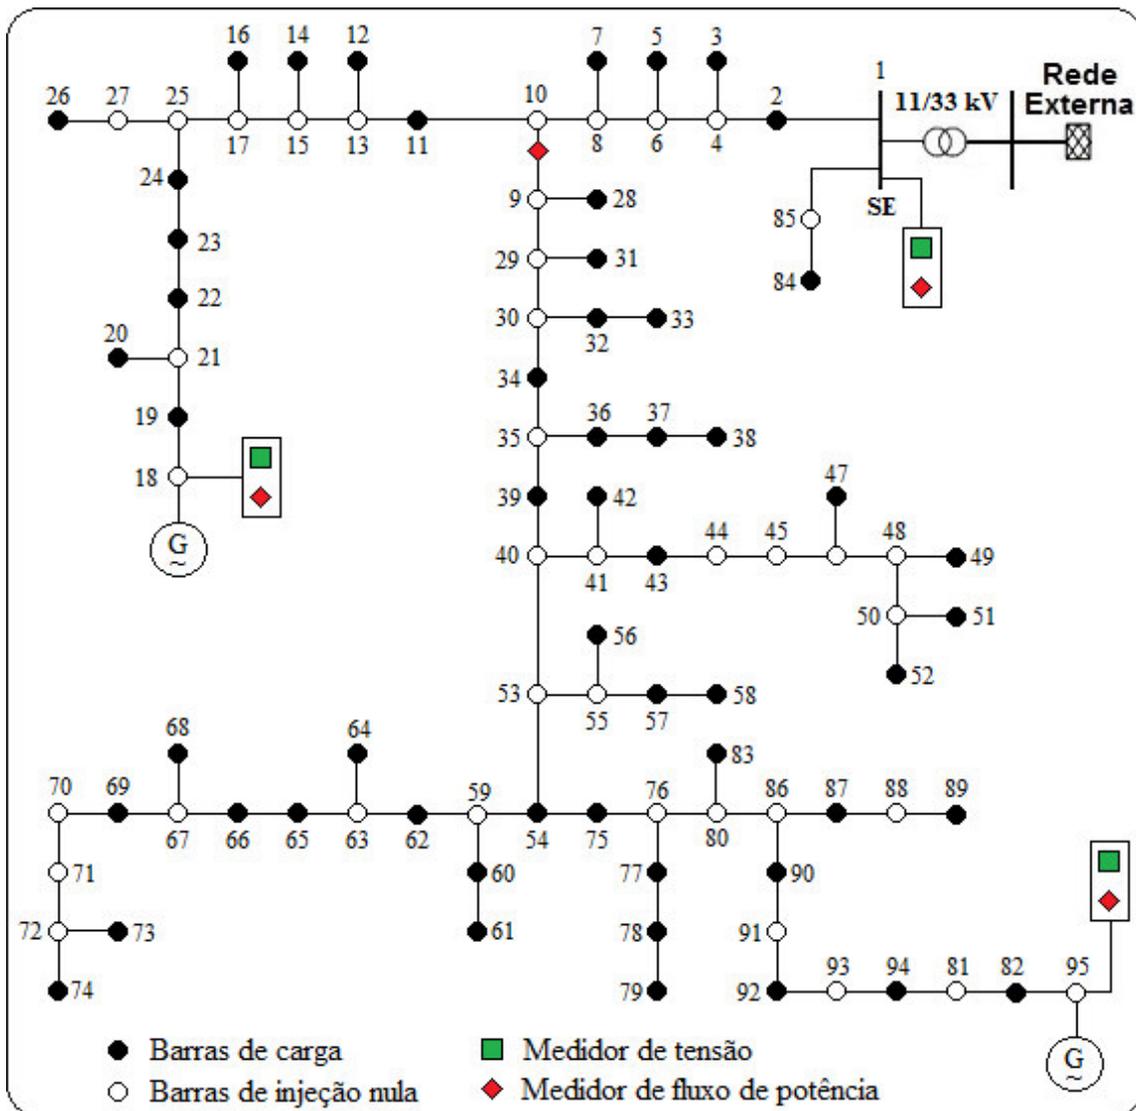


Figura 6.21: Alocação dos medidores obtida pelo método ANA2PDF para o Caso #2-C.

Para o Caso #2-D, os métodos SPV, SMCLIN e ANA2PDF alocaram 1 medidor de fluxo de potência no mesmo local do sistema, o ramo 2/4, como pode ser visto na Figura 6.22.

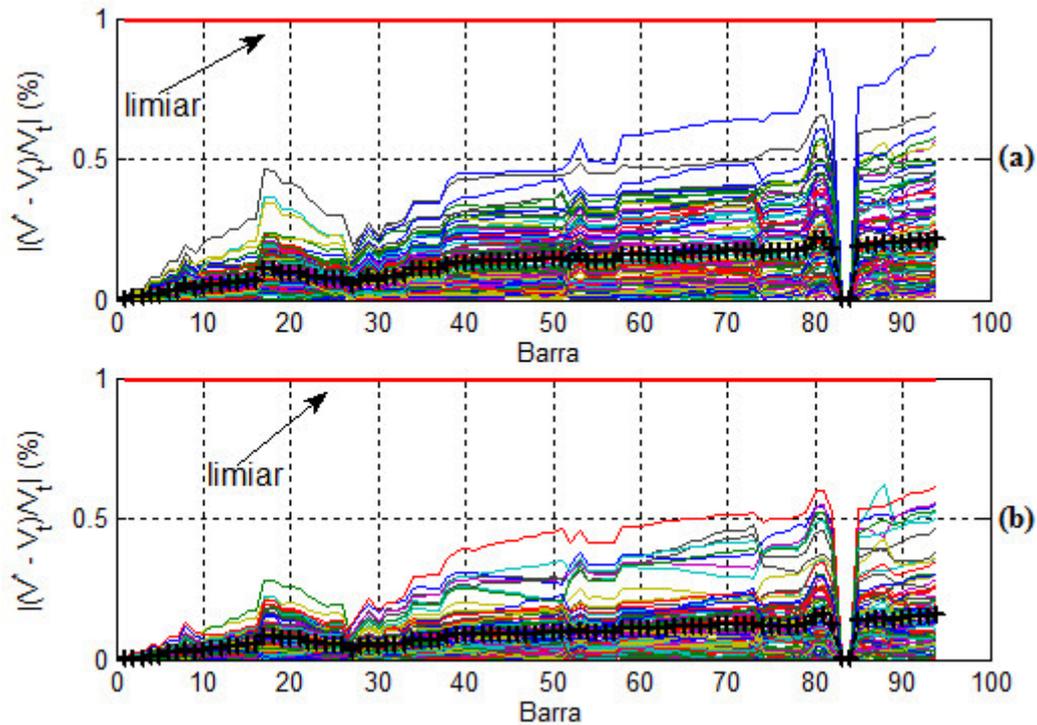


Figura 6.23: Erros relativos na magnitude estimada da tensão calculados pelo método SPV para o Caso #2-D. (a) sem a presença de medidores (b) com a alocação de 1 medidor no sistema.

O comportamento dos erros relativos na fase da tensão estimada segundo o método SPV para o Caso #2-D é mostrado na Figura 6.24, na qual a curva com símbolo “+” representa o valor médio. Diferentemente da magnitude da tensão, a Figura 6.24(a) indica que a ausência de medidor no sistema afeta significativamente a precisão da fase da tensão estimada considerando-se um erro máximo de 50% para pseudo-medições. Entretanto, após a alocação de 1 medidor de fluxo, os erros relativos estimados de fase da tensão superaram em apenas duas simulações o limiar pré-estabelecido de máximo erro relativo de fase ($\epsilon_\theta \leq 5\%$), como pode ser visto na Figura 6.24(b). Isso significa que dos 100 elementos da amostra geradas pelo método SPV, 98 possuem erro relativo na fase estimada da tensão abaixo do limiar especificado, ou seja, atendem ao critério dos 95% das simulações.

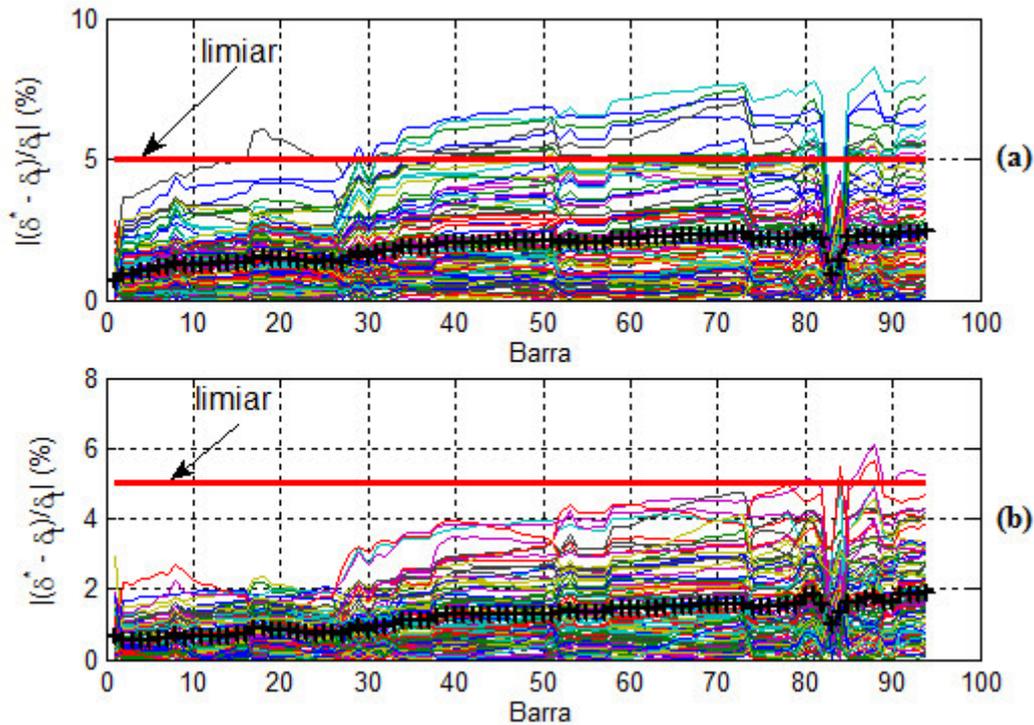


Figura 6.24: Erros relativos na fase estimada da tensão calculados pelo método SPV para o Caso #2-D. (a) sem a presença de medidor (b) com a alocação de 1 medidor no sistema.

A Figura 6.25 ilustra o comportamento dos índices de probabilidade bivariados P_i e R_i segundo o método SPV para o Caso #2-D. Como pode ser visto na Figura 6.25(a), a ausência de medidores no sistema fornece um R_i máximo de 14% para um erro máximo de 3% para medições reais e de 50% para pseudo-medições. Este valor está bem acima dos 5% estipulados como índice máximo de aceitação (equação (4.16)). Todavia, após a instalação de um medidor de fluxo, o risco máximo, R_i , não ultrapassou 2% conforme ilustrado na Figura 6.25(b).

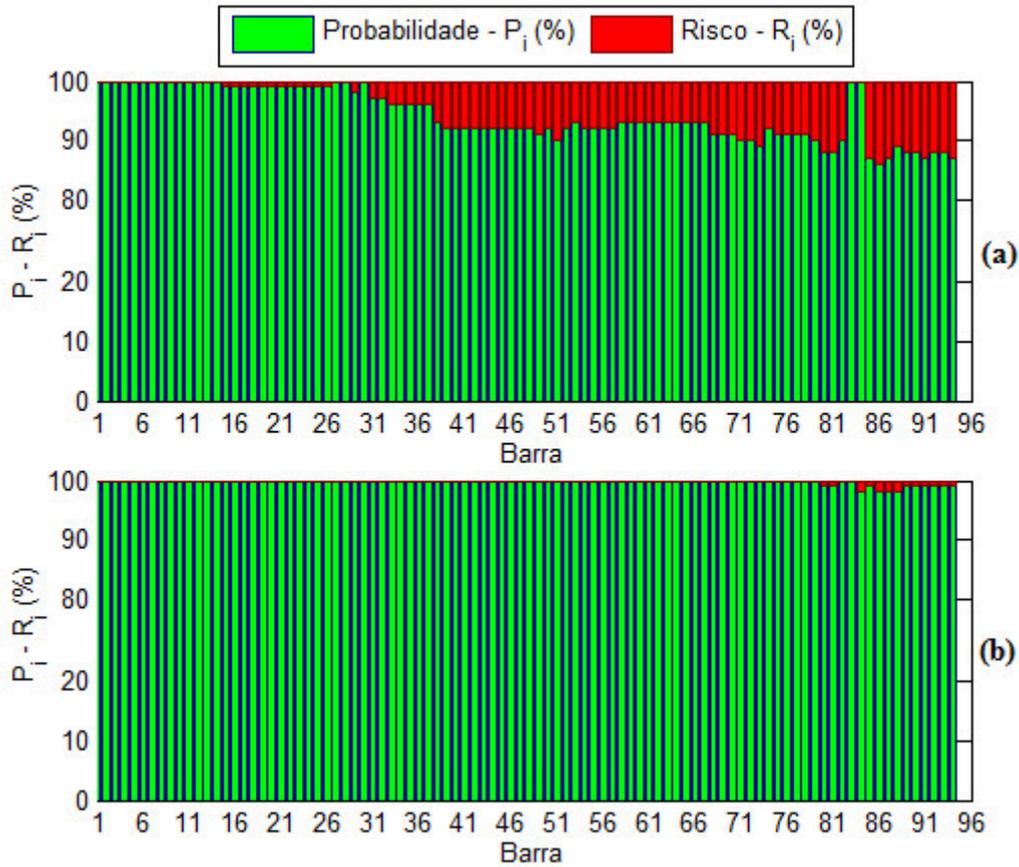


Figura 6.25: Comparação entre P_i e R_i calculados pelo método SPV para o Caso #2-D. (a) sem a presença de medidor (b) com a instalação de um medidor.

O comportamento dos erros relativos na magnitude da tensão estimada segundo o método SMCLIN para o Caso #2-D é ilustrado na Figura 6.26, na qual o gráfico plotado com o sinal “+” indica o valor médio. Assim como para o método SPV, a ausência de medidores no sistema não afeta a precisão da magnitude da tensão estimada considerando-se um erro máximo de 3% para medições reais e de 50% para pseudo-medições, como pode ser visto na Figura 6.26(a).

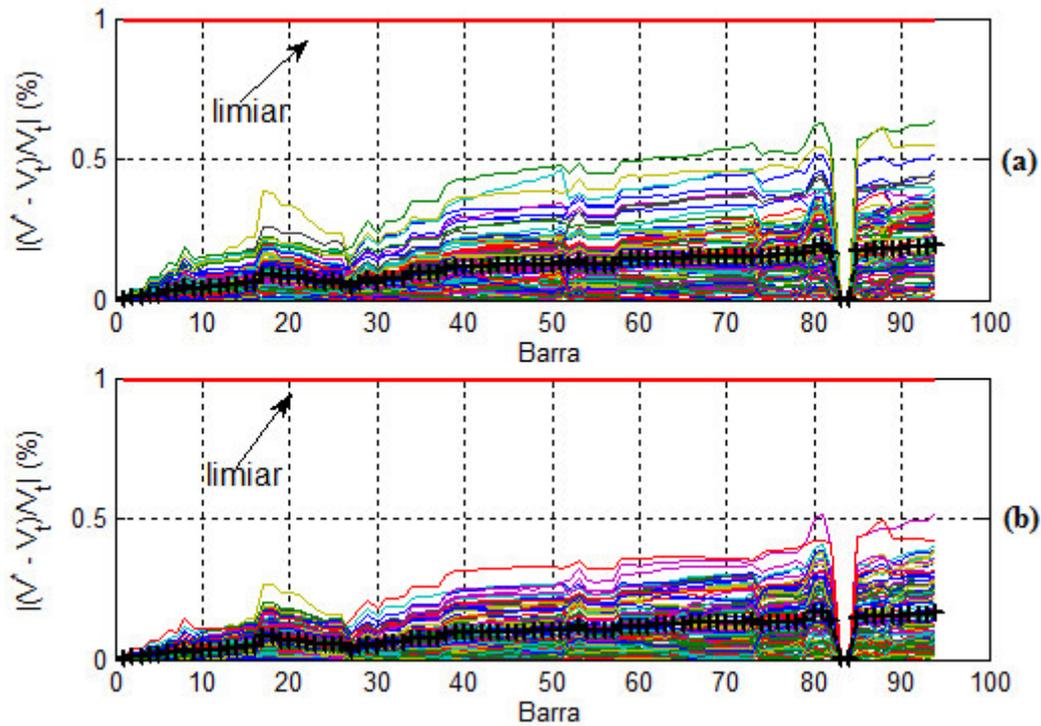


Figura 6.26: Erros relativos na magnitude estimada da tensão calculados pelo método SMCLIN para o Caso #2-D. (a) sem a presença de medidores (b) com a alocação de 1 medidor.

A Figura 6.27 demonstra o comportamento dos erros relativos na fase da tensão estimada segundo o método SMCLIN, após 100 SMC, para o Caso #2-D. Diferentemente da magnitude da tensão, a Figura 6.27(a) indica que a ausência de medidores no sistema afeta significativamente a precisão da fase da tensão estimada. Considerando-se um erro máximo de 3% para medições reais e de 50% para pseudo-medições, os erros relativos na fase da tensão estimada podem chegar a ordem de 10%, o dobro do limite permitido ϵ_θ . Entretanto, assim como no método SPV, após a alocação de 1 medidor de fluxo, os erros relativos estimados de fase da tensão superaram em apenas duas amostras o limiar pré-estabelecido para o valor máximo do erro relativo de fase ($\epsilon_\theta \leq 5\%$), como pode ser visto na Figura 6.27(b). Isso significa que dos 100 elementos da amostra sorteada realizadas pelo método SMCLIN, 98 estão com o erro relativo na fase estimada da tensão abaixo do limiar especificado, isto é, atendendo o critério dos 95% da amostra.

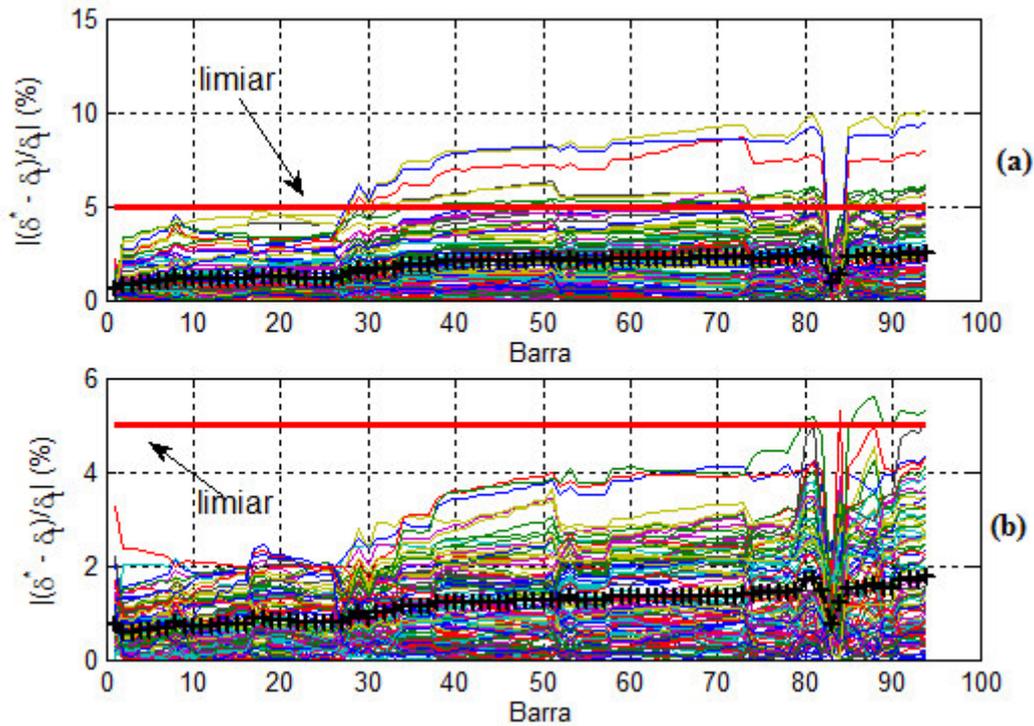


Figura 6.27: Erros relativos na fase estimada da tensão obtidos com a SMCLIN para o Caso #2-D. (a) sem a presença de medidor (b) com a alocação de 1 medidor.

A Figura 6.28 ilustra o comportamento dos índices de probabilidade bivariados P_i e R_i segundo o método SMCLIN para o Caso #2-D. Como pode ser visto na Figura 6.28(a), a inexistência de medidores no sistema fornece um R_i máximo de 12% para um erro máximo de 3% para medições reais e de 50% para pseudo-medições. Este valor está bem acima dos 5% especificados como índice máximo (equação (4.16)). Entretanto, após a instalação de um medidor de fluxo, o risco máximo, R_i , não ultrapassou 2% das simulações conforme ilustrado na Figura 6.28(b).

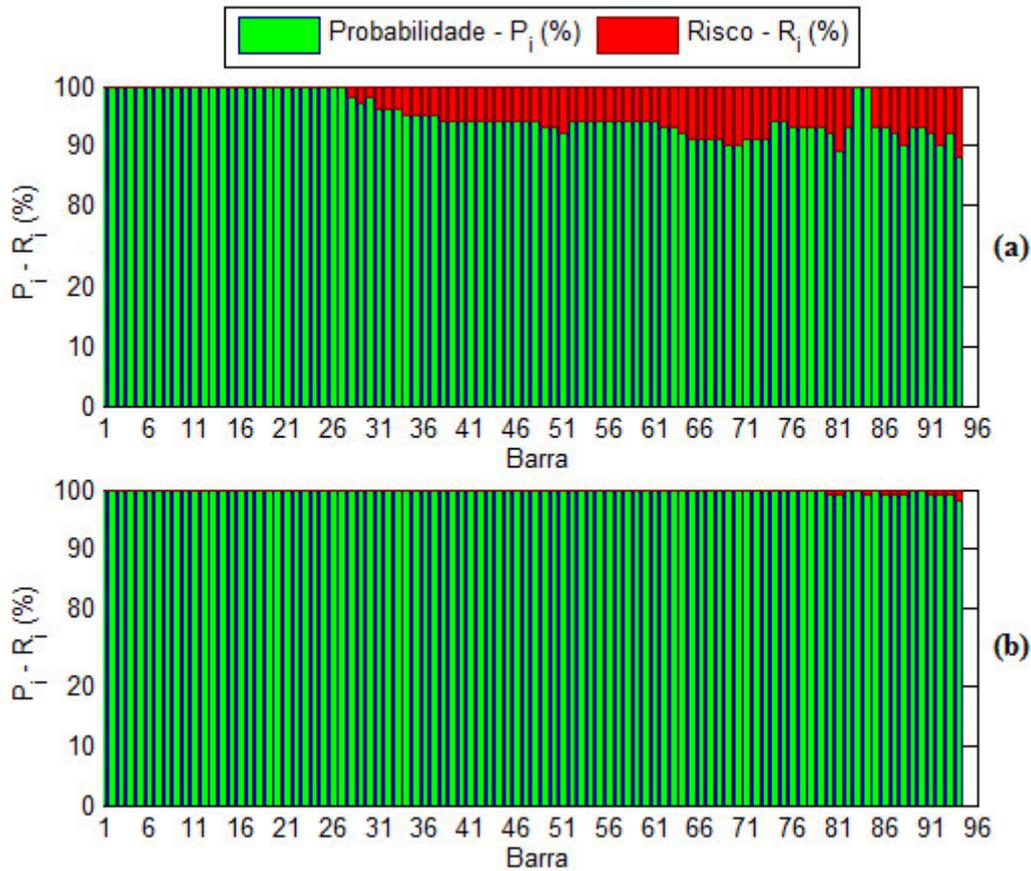


Figura 6.28: Comparação entre P_i e R_i obtidos pelo método SMCLIN para o Caso #2-D. (a) sem a presença de medidores (b) com a alocação de 1 medidor.

Analogamente ao Caso #1, os resultados das Tabelas 6.5 e 6.6 demonstram que desconsiderar os termos de alta ordem na expansão de Taylor de $h(\hat{x})$ (Equação (5.2)) não prejudicou o desempenho dos métodos aproximados, em relação ao método de referência SPV. Isto ocorreu tanto do ponto de vista econômico, pois as técnicas alocaram a mesma quantidade de medidores e, quanto do ponto de vista do processo de otimização da função objetivo, pois o índice P_i ficou bem próximo do índice fornecido pelo método SPV.

A Tabela 6.9 apresenta o tempo computacional dos três métodos de alocação de medidores para o Caso #2. Esta tabela também mostra os ganhos absolutos e as variações percentuais dos tempos de execução dos métodos propostos em relação ao método SPV (valores à esquerda e a direita da barra, respectivamente). Pode-se perceber que ambos os métodos propostos são mais eficientes do que o método SPV. Como o método SMCLIN tem embarcado a SMC, os ganhos foram da ordem de 2.3 vezes,

economizando, na média, um pouco mais do que 55% do tempo de execução em relação ao método SPV.

Tabela 6.9: Comparação entre o tempo computacional dos métodos de alocação para o Caso #2.

	Erros de medição		Tempo computacional (s)		
	Medição Real (%)	Pseudo – Medição (%)	SPV	SMCLIN	ANA2PDF
A	1	20	2,699780	1,225486 (0,4539/54,6079%)	0,110968 (0,0411/95,8897%)
B	3	20	2,794997	1,210623 (0,4331/56,6861%)	0,111879 (0,0400/95,9972%)
C	1	50	5,116565	2,171121 (0,4243/57,5668%)	0,145419 (0,0284/97,1579%)
D	3	50	5,088962	2,204400 (0,4332/56,6827%)	0,145866 (0,0287/97,1337%)

O método analítico ANA2PDF, por não possuir a SMC, produziu resultados bem mais expressivos. Na média, o ANA2PDF foi cerca de 30 (trinta) vezes mais rápido do que o método de referência SPV, com um pouco mais de 3% do tempo computacional deste método no processo de alocação de medidores. No pior cenário, o Caso #2-D, os métodos SMCLIN e ANA2PDF produziram um desempenho bem mais satisfatório do que o SPV. Todos os métodos alocaram a mesma quantidade de medidores. Neste cenário, o método ANA2PDF foi cerca de 35 (trinta e cinco) vezes mais rápido do que o SPV, com uma economia de tempo da ordem de 97% do tempo que o SPV precisaria para alocar um medidor no STD_UKGDS95 (Tabela 6.8).

A Figura 6.29 fornece uma análise qualitativa do custo computacional dos métodos de alocação de medidores. Como já demonstrado na Tabela 6.9, as barras correspondendo ao método ANA2PDF, em verde, permanecem praticamente constante mesmo com o incremento dos erros máximos de medição real e de pseudo-medição. Diferentemente do ANA2PDF, o SPV mostrou-se mais sensível ao incremento dos erros máximos de pseudo-medição, mas manteve um padrão constante.

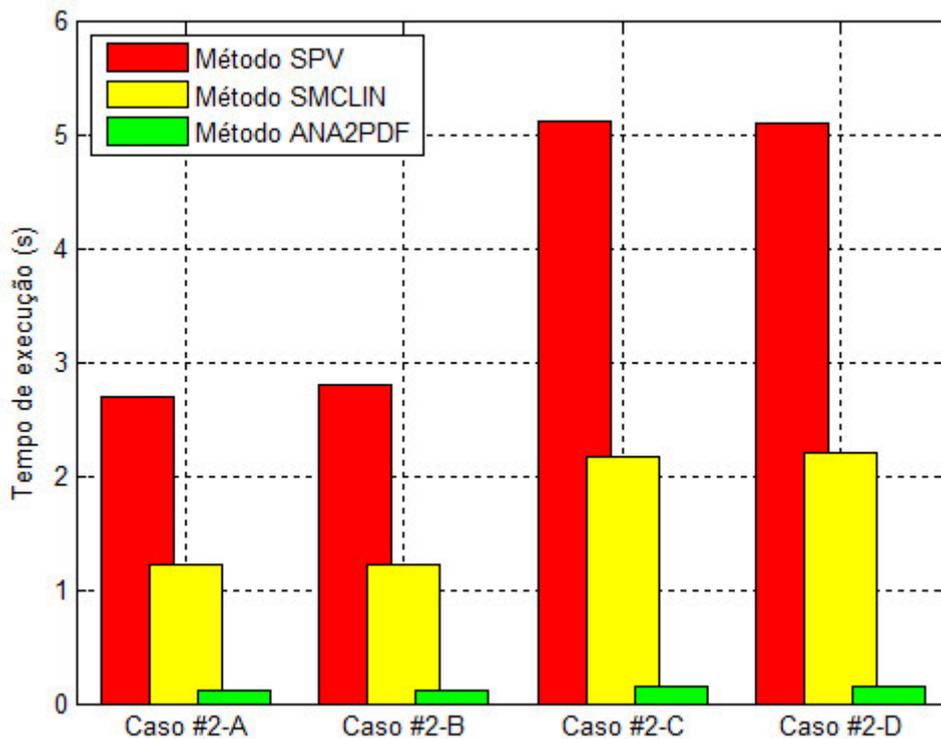


Figura 6.29: Comparação entre o tempo computacional dos métodos de alocação para o Caso #2.

6.5.3 Resultados do Caso #3

O desempenho dos métodos em relação ao índice P_i para um coeficiente de correlação entre medições de injeção/fluxo de potência igual a 0,95 é demonstrado na Tabela 6.10.

Tabela 6.10: Valores mínimo e máximo dos índices P_i e R_i para o Caso #3.

	Erros de medição		Índices P_i^{min} e R_i^{max} (%)					
	Medição Real (%)	Pseudo – Medição (%)	SPV		SMCLIN		ANA2PDF	
			P_i^{min}	R_i^{max}	P_i^{min}	R_i^{max}	P_i^{min}	R_i^{max}
A	1	20	100,0	0,0	100,0	0,0	99,9999	0,0001
B	3	20	100,0	0,0	100,0	0,0	99,9575	0,0425
C	1	50	100,0	0,0	98,0	2,0	95,6607	4,3393
D	3	50	98,0	2,0	99,0	1,0	99,5995	0,4005

Pode-se perceber que tanto o SMCLIN quanto o ANA2PDF fornecem quantidades bem próximas para o índice de probabilidade P_i quando comparados ao método SPV nos Casos #3-A, #3-B e #3D. O Caso #3-C apresenta certa discrepância do P_i^{min} obtido através do método SPV e do obtido pelo método ANA2PDF. Como apresentado na Tabela 6.11, o método ANA2PDF garante que sem medidor alocado no STD_UKGDS95 o mínimo P_i calculado satisfaz o critério de convergência. O mesmo resultado é obtido através do método SMCLIN, garantindo a probabilidade de no máximo 2% dos erros relativos de magnitude e fase da tensão violarem os limiares pré-estabelecidos. A Tabela 6.11 mostra o número de medidores alocados no STD_UKGDS95 segundo os métodos SPV, SMCLIN e ANA2PDF.

Tabela 6.11: Comparação entre o número de medidores alocados para o Caso #3.

	Erros de medição		Medidores alocados								
	Medição Real (%)	Pseudo – Medição (%)	SPV			SMCLIN			ANA2PDF		
			MT	MF	TT	MT	MF	TT	MT	MF	TT
A	1	20	0	0	0	0	0	0	0	0	0
B	3	20	0	0	0	0	0	0	0	0	0
C	1	50	0	1	1	0	0	0	0	0	0
D	3	50	0	1	1	0	1	1	0	1	1

Como mostrado na Tabela 6.11, tanto o método de referência, SPV, quanto os propostos, SMCLIN e ANA2PDF, alocaram o mesmo número de medidores para o Caso #3-D. Entretanto, para o Caso #3-C, o método SPV foi o único a alocar medidor no sistema, alocando 1 medidor de fluxo de potência no ramo 9/29, como pode ser visto na Figura 6.30.

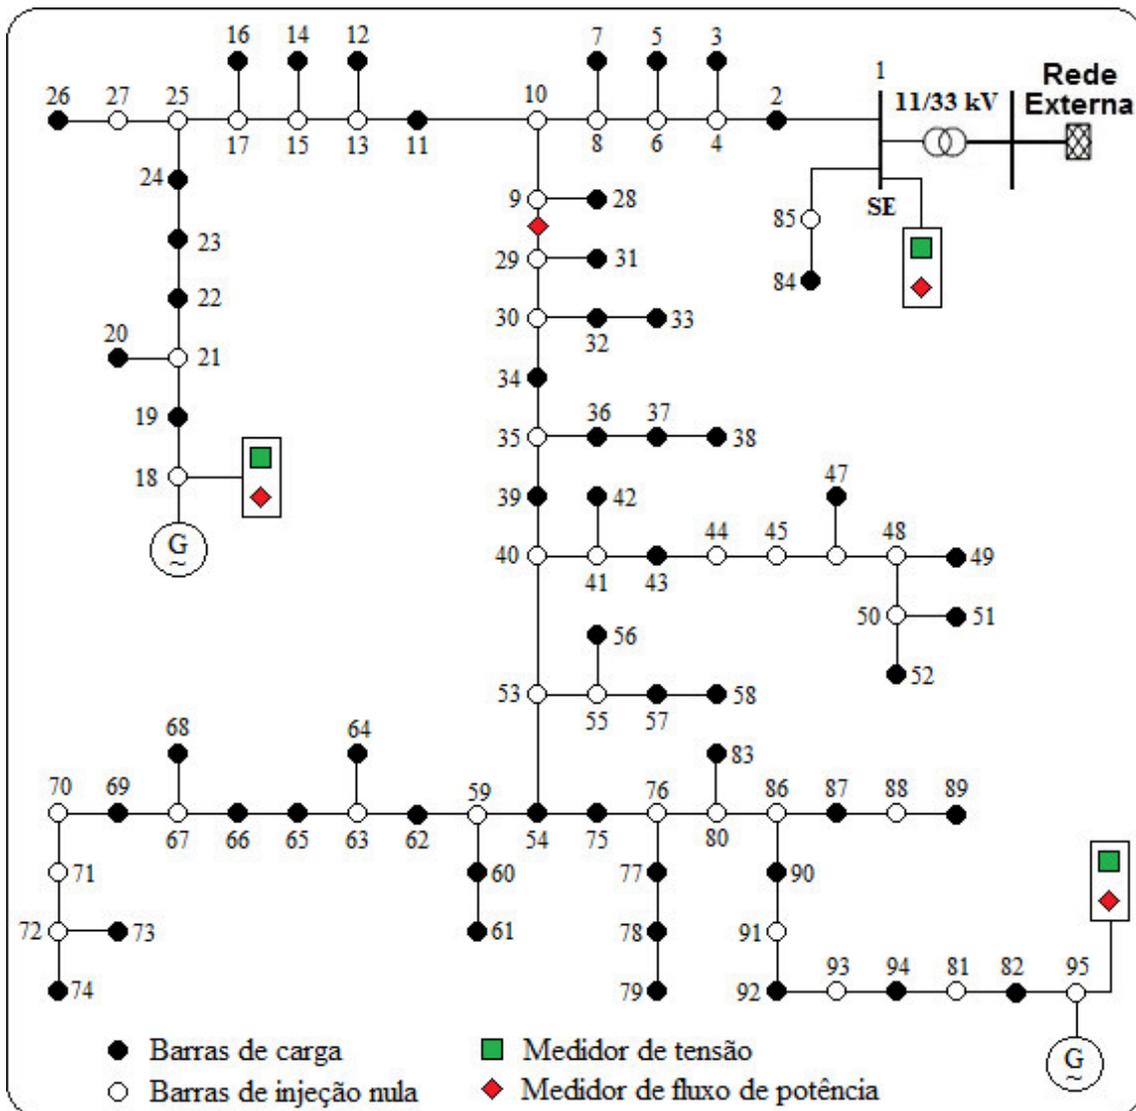


Figura 6.30: Alocação de medidor segundo o método SPV para o Caso #3-C.

Como visto na Tabela 6.11, o método SPV alocou um medidor no STD_UKGDS95 para o Caso #3-C, enquanto que os demais não alocaram medidores. Este cenário foi um de alguns cenários vistos em que o método SPV aloca mais ou menos medidores do que os métodos SMCLIN e ANA2PDF. Isto indica que amostras de 100 elementos podem não ser suficientes para estimar os índices P_i e R_i com precisão aceitável. Este fato pode ser inicialmente verificando, usando-se a SMC para estimar os índices P_i e R_i para o plano de medição do caso base (somente os medidores da GD e da subestação) com duas amostras distintas de 100 elementos. O resultado da primeira amostra indica que para o Caso #3-C, não se faz necessário alocar medidor no STD_UKGDS95. A Figura 6.31 demonstra o comportamento dos erros relativos na

magnitude e na fase da tensão estimada segundo o método SPV para esta primeira análise. A partir desta simulação, o mínimo índice P_i obtido foi de **96%** e, por conseguinte, o máximo risco R_i obtido foi de 4%. Este cenário atende a especificação de termos um P_i mínimo de 95% para convergência do método.

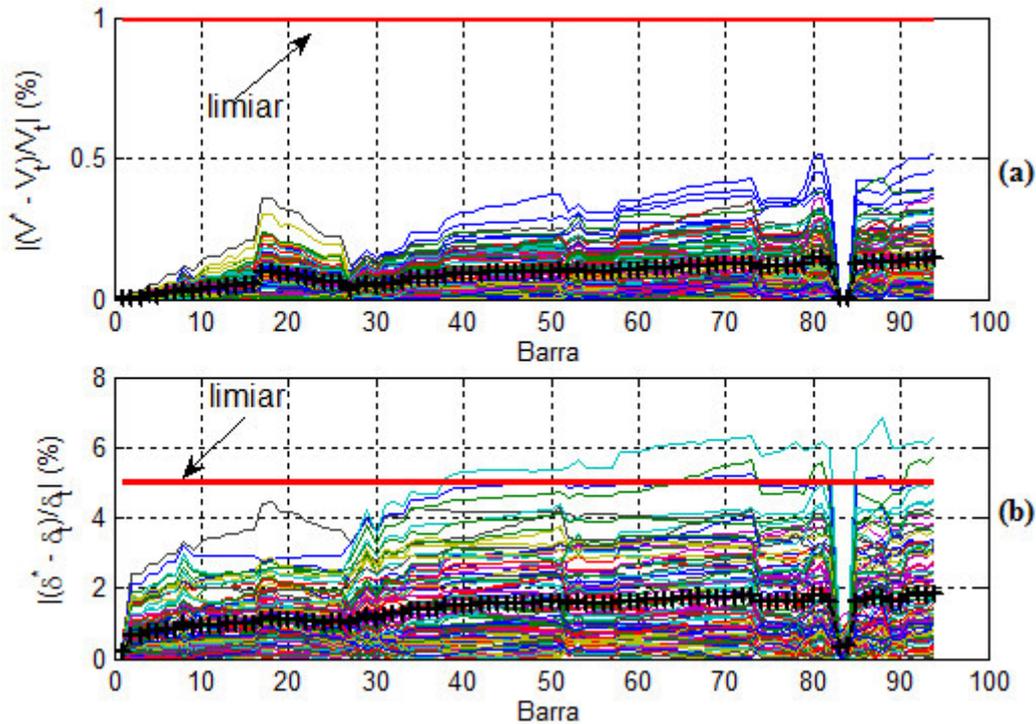


Figura 6.31: Erros relativos (a) na magnitude estimada da tensão e (b) na fase estimada da tensão para a primeira amostra de 100 elementos da SMC.

A segunda amostra de 100 elementos para o Caso #3-C indica que é necessário alocar no mínimo um medidor no STD_UKGDS95. A Figura 6.32 demonstra o comportamento dos erros relativos na magnitude e na fase da tensão estimada segundo o método SPV para esta segunda análise. A partir desta simulação, o mínimo índice P_i obtido foi de **93%** e, por conseguinte, o máximo risco R_i obtido foi de 7%. Este cenário não atende a especificação de termos um P_i mínimo de 95% para convergência do método. Portanto, faz-se necessário aumentar o tamanho da amostra usada na SMC do SPV para descobrir se realmente é necessário alocar ou não medidor no STD_UKGDS95 para o Caso #3-C. Os índices P_i e R_i estimados com amostras suficientemente grandes serão apresentados na seção 6.6.

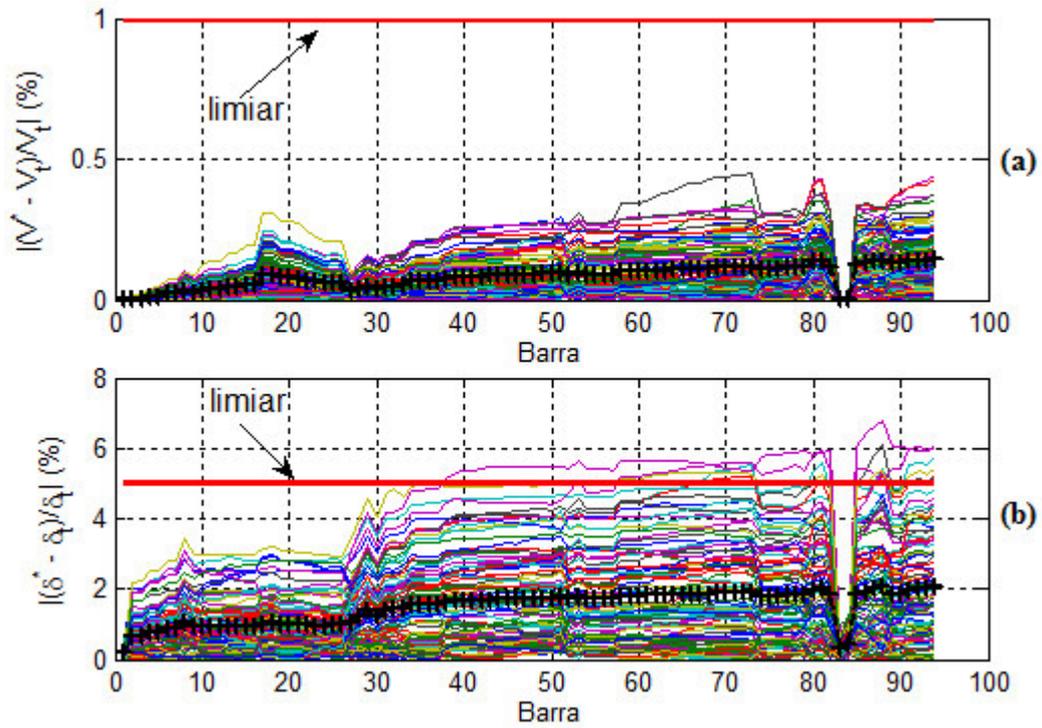


Figura 6.32: Erros relativos (a) na magnitude estimada da tensão e (b) na fase estimada da tensão para a segunda amostra de 100 elementos da SMC.

A Figura 6.33 fornece um indicativo dos índices de probabilidade bivariados P_i e R_i para os dois cenários estudados.

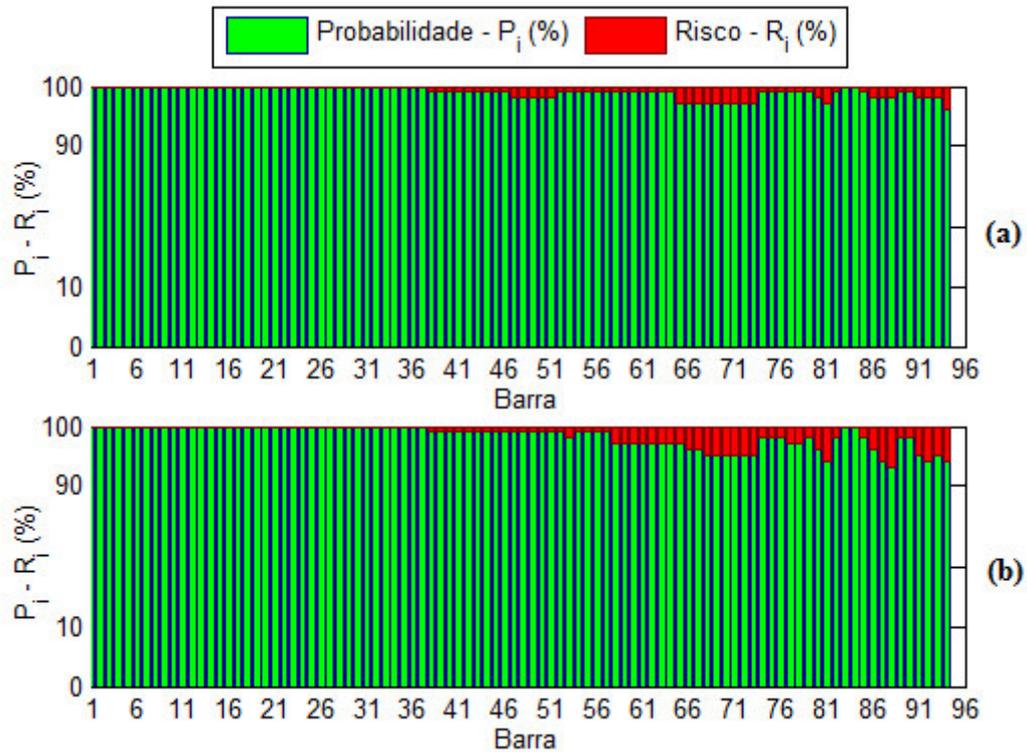


Figura 6.33: Comparação entre P_i e R_i (a) para a primeira rodada distinta da apresentada nas Tabelas 6.8 e 6.9, e (b) para a segunda rodada distinta da apresentada nas Tabelas 6.8 e 6.9.

Para o Caso #3-D, o método SPV alocou 1 medidor de fluxo de potência no ramo 10/9, como pode ser visto na Figura 6.34. Para os mesmos casos, os métodos SMCLIN e ANA2PDF alocaram 1 medidor de fluxo de potência no mesmo local do sistema, o ramo 2/4, como ilustrado na Figura 6.35.

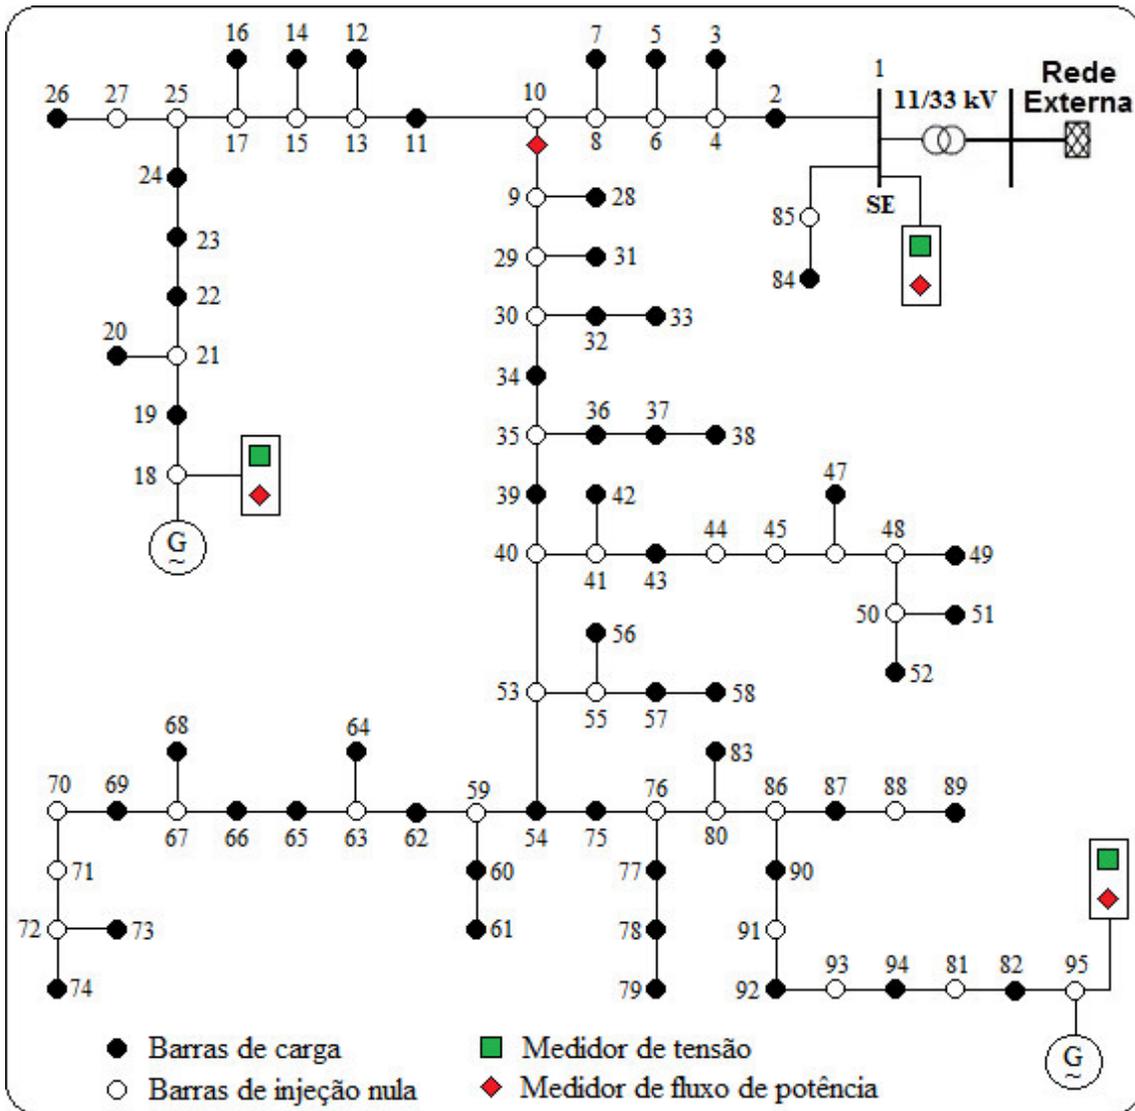


Figura 6.34: Alocação de medidor segundo o método SPV para o Caso #3-D.

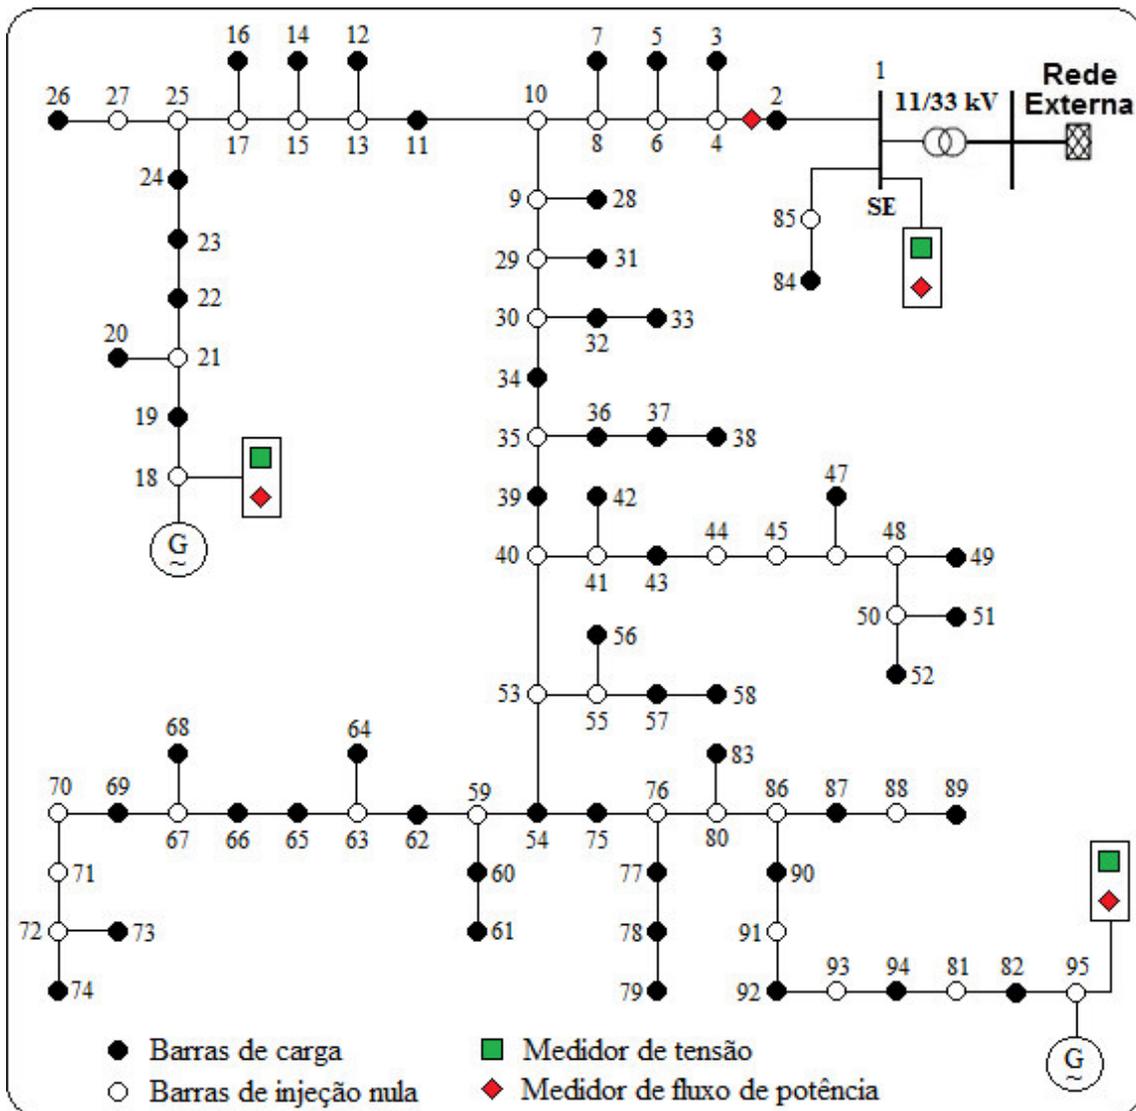


Figura 6.35: Alocação de medidor segundo os métodos SMCLIN e ANA2PDF para o Caso #3-D.

Assim como nos Casos #1 e #2, os resultados das Tabelas 6.8 e 6.9 demonstram que desconsiderar os termos de alta ordem na expansão de Taylor de $h(\hat{x})$ (equação (5.2)) não prejudicou o desempenho dos métodos, em relação ao método de referência SPV.

A Tabela 6.12 apresenta o tempo computacional dos três métodos de alocação de medidores para o Caso #3. Esta tabela também mostra os ganhos absolutos e as variações percentuais dos tempos de execução dos métodos propostos em relação ao método SPV (valores a esquerda e a direita da barra, respectivamente). Pode-se perceber que ambos os métodos propostos são mais eficientes, computacionalmente, do que o método SPV. Como o método SMCLIN tem embarcado a SMC, os ganhos foram da

ordem de duas vezes, economizando, na média, um pouco mais do que 54% do tempo de execução em relação ao método SPV, excluindo-se o Caso #3-C, devido as análises feitas anteriormente.

Tabela 6.12: Comparação entre o tempo computacional dos métodos de alocação para o Caso #3.

	Erros de medição		Tempo computacional (s)		
	Medição Real (%)	Pseudo – Medição (%)	SPV	SMCLIN	ANA2PDF
A	1	20	2,652979	1,209427 (0,4559/54,4125%)	0,109930 (0,0414/95,8564%)
B	3	20	2,633608	1,220969 (0,4636/53,6389%)	0,109883 (0,0417/95,8277%)
C	1	50	5,007665	1,225318 (0,2447/75,5312%)	0,109531 (0,0219/97,8127%)
D	3	50	4,943450	2,149824 (0,4349/56,5117%)	0,144434 (0,0292/97,0783%)

O método analítico ANA2PDF, como não possui a SMC, foi cerca de 27 (vinte e sete) vezes mais rápido do que o método de referência SPV, com um pouco mais de 4% do tempo computacional deste método no processo de alocação de medidor, excluindo-se o Caso #3-C. No pior cenário, o Caso #3-D, os métodos SMCLIN e ANA2PDF produziram um desempenho bem mais satisfatório do que o SPV. Todos os métodos alocaram a mesma quantidade de medidores. Neste cenário, o método ANA2PDF foi cerca de 34 (trinta e quatro) vezes mais rápido do que o SPV, com uma economia de tempo da ordem de 97% do tempo que o SPV precisaria para alocar um medidor no STD_UKGDS95, conforme a Tabela 6.11.

A Figura 6.36 fornece uma representação gráfica do comportamento temporal dos métodos de alocação de medidores. Como demonstrado na Tabela 6.12, as barras correspondendo ao método ANA2PDF, em verde, permanecem praticamente constante mesmo com o incremento dos máximos erros de medição real e de pseudo-medição. Os métodos SMCLIN e SPV mostraram-se mais sensíveis ao incremento dos máximos erros de pseudo-medição no Caso #3-D.

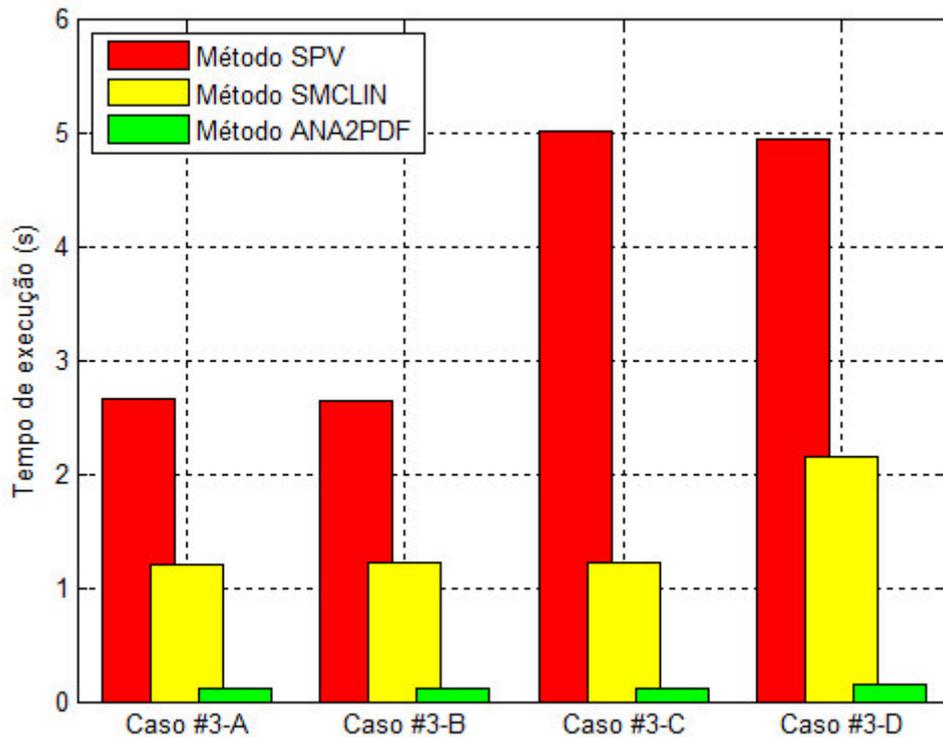


Figura 6.36: Comparação entre o tempo computacional dos métodos de alocação para o Caso #3.

6.6 Impacto do Tamanho da Amostra da SMC no Desempenho do Método SPV

Na subsecção 6.5.3, vimos um indicativo de que o método SPV é sensível ao comportamento estocástico das medições e, portanto, o número de simulações Monte Carlo sugerido por Singh, Pal e Vinter (2009) não é suficiente para estimar com maior precisão o índice de probabilidade bivariado P_i . Desta forma, faz-se necessário obter o número mínimo de simulações necessárias para estimar com certo grau de precisão a incerteza associada ao índice P_i . Na seção 4.2 do capítulo 4, foi visto que o nível de precisão da SMC pode ser expresso através de um coeficiente de variação β definido a partir de (4.9). Para simulações em que se deseja obter um evento raro, o número de simulações N costuma ser bastante grande. Assim, o coeficiente de variação β pode ser utilizado para estimar o número mínimo de simulações necessárias para que todos os resultados converjam para valores estáveis. Reescrevendo (4.10) em função de R_i ($R_i = 1 - P_i$), tem-se:

$$N = \frac{1 - R_i}{\beta^2 R_i} \quad (6.4)$$

Aplicando-se (6.4) para uma incerteza relativa β associada ao máximo erro relativo da fase estimada da tensão, $\epsilon_\theta = 5\%$, tem-se que o número mínimo de simulações necessárias é $N_\theta = 7600$ e para uma incerteza relativa β associada ao máximo erro relativo da magnitude estimada da tensão, $\epsilon_V = 1\%$, tem-se que o número mínimo de simulações necessárias é $N_V = 190000$. Nesta dissertação extrapolou-se os valores de N_θ e N_V para $N_\theta = 10000$ e $N_V = 200000$.

A primeira análise de caso é referente ao Caso #3-C. Segundo as Tabelas 6.10 e 6.11, enquanto os métodos SMCLIN e ANA2PDF não alocaram medidor, o método SPV alocou um medidor no STD_UKGDS95 garantindo que todos os 100 elementos da amostra não violam os limites pré-estabelecidos dos erros relativos da tensão estimada. Entretanto, como demonstrado na subseção 6.5.3, os índices P_i e R_i se mostraram sensíveis à variabilidade amostral. Para a primeira amostra obteve-se um P_i^{min} de 96%, atendendo o limite para este índice. Para a segunda amostra, foi obtido um P_i^{min} de 93%, não atendendo o limite para este índice. Desta forma, deve-se analisar a possibilidade das estimativas de P_i e R_i se tornarem imprecisas quando o tamanho da amostra é pequeno. Esta validação é realizada usando-se a SMC para estimar as probabilidades P_i e R_i para o plano de medição do caso base com uma amostra dimensionada para estimar estes índices com precisão aceitável, ou seja, para $N_\theta = 10000$ ou $N_V = 200000$. Utilizando-se, arbitrariamente, N_θ com o tamanho da amostra da SMC, obteve-se $P_i^{min} = 95,75\%$ e, portanto, $R_i^{max} = 4,25\%$. Estes valores atendem aos limites para as probabilidades e estão bem próximos do índice P_i gerado pelo método ANA2PDF, que é de 95,6607%, conforme Tabela 6.10. Este resultado demonstra que amostras de 100 elementos podem não ser suficientes para estimar com precisão o índice de probabilidade bivariado P_i . Além disso, este resultado mostra que o método SPV está vulnerável a problemas de mascaramento devido ao uso de pequenas amostras na SMC. O método ANA2PDF proposto nesta dissertação é imune a este tipo de problema, pois ele estima os índices P_i usando fórmulas analíticas sem usar a SMC. A Tabela 6.13 resume os resultados obtidos referentes à primeira análise.

Tabela 6.13: Resultados referentes à primeira análise sobre o impacto do tamanho da amostra no método SPV.

Tamanho da amostra	P_i^{min} (%)
Amostra 1: N = 100	96,0000
Amostra 2: N = 100	93,0000
SMC de evento raro: N = 10000	95,7500
ANA2PDF	96,6607

A Figura 6.37 fornece um indicativo dos índices de probabilidade bivariados P_i e R_i para a SMC com amostra aumentada aplicada ao Caso #3-C.

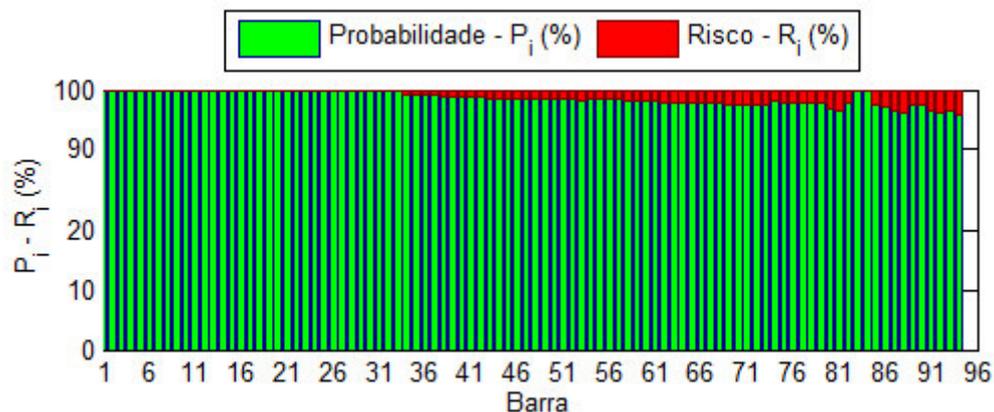


Figura 6.37: Comparação entre P_i e R_i - Caso #3-C com uma amostra de 10000 para a SMC.

A segunda análise de caso é referente ao Caso #1-D. Segundo as Tabelas 6.4 e 6.5, todos os métodos alocaram dois medidores. Entretanto, desconsiderando-se o resultado apresentado nestas tabelas, uma rodada distinta do método SPV (o algoritmo de alocação foi executado com sementes distintas para os geradores de números aleatórios) forneceu resultados diferentes considerando que o método SPV alocou apenas um medidor de fluxo de potência no sistema STD_UKGDS95, no ramo 2/4. O resultado indica que para o Caso #1-D, com apenas um medidor instalado no ramo 2/4, o mínimo índice P_i obtido foi de **96%** e, por conseguinte, o máximo risco R_i obtido foi de 4%. Este cenário atende a especificação de termos um P_i mínimo de 95% para convergência do método. A Figura 6.38 demonstra o comportamento dos erros relativos na magnitude e na fase da tensão estimada para esta rodada do método SPV. As curvas em '+' representam o erro médio.

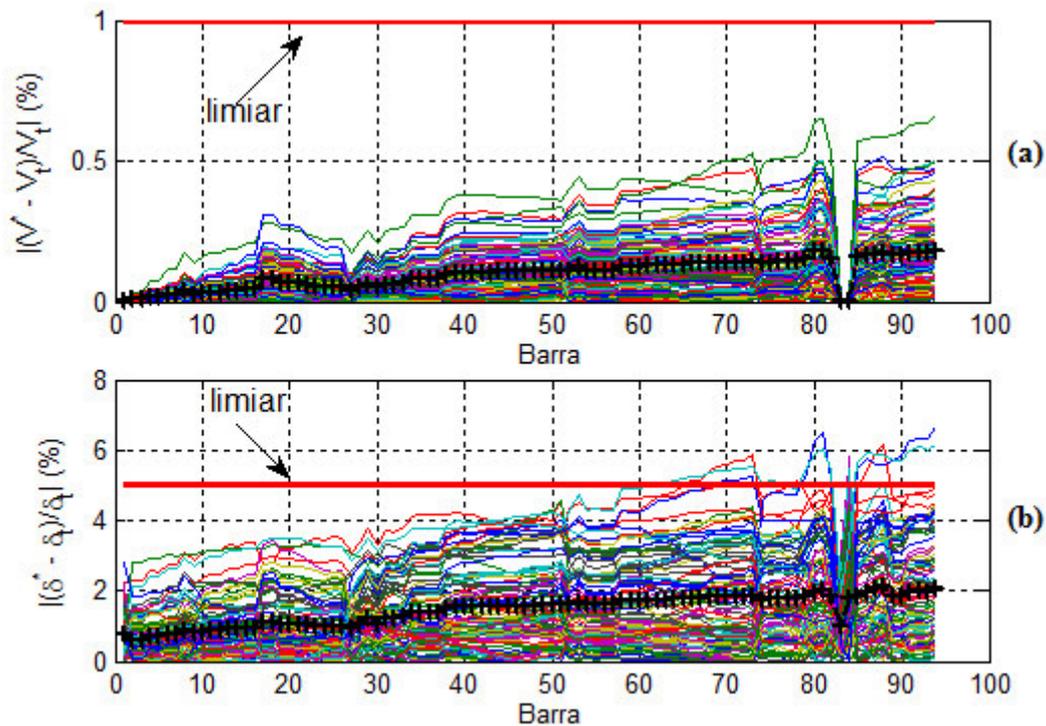


Figura 6.38: Erros relativos na magnitude estimada da tensão (a) e na fase estimada da tensão (b) para o caso Caso #1-D do método SPV com apenas um medidor de fluxo de potência instalado no ramo 2/4.

Com o método SPV foi alocado um número menor de medidores (apenas um medidor no ramo 2/4) se comparado com os métodos SMCLIN e ANA2PDF (Tabela 6.5). Portanto, deve-se analisar a possibilidade do método SPV atender ou não os limites para as probabilidades com amostras pequenas de 100 elementos. Esta análise foi realizada aplicando-se a SMC para estimar os índices P_i e R_i para o plano de medição gerado pelo SPV (apenas um medidor de fluxo de potência no ramo 2/4). Utilizando, arbitrariamente, N_θ como tamanho da amostra para a SMC, obteve-se $P_i^{min} = 91,64\%$ e $R_i^{max} = 8,36\%$. Estes valores não satisfazem os limites para as probabilidades. Este resultado demonstra que amostras de 100 elementos não foram suficientes para estimar com precisão o índice de probabilidade bivariado P_i . Portanto, pode-se concluir que amostras de 100 elementos não são suficientes para estimar os índices P_i e R_i com precisão aceitável.

Adicionalmente, utilizando N_V como tamanho da amostra para a SMC, obteve-se $P_i^{min} = 91,834\%$ e, portanto, $R_i^{max} = 8,166\%$. Estes valores também não atendem o

critério de convergência do método SPV, demonstrando novamente que amostras de 100 elementos não foram suficientes para estimar com precisão o índice de probabilidade bivariado P_i .

Se fosse aplicado o método ANA2PDF para o Caso #1-D, com apenas um medidor de fluxo de potência instalado no ramo 2/4, seriam obtidos os valores de $P_i^{min} = 91,6907\%$ e $R_i^{max} = 8,3093\%$. Estes valores estão bem próximos daqueles obtidos com 10000 e 200000 com a SMC, confirmando a precisão do método analítico proposto. A Tabela 6.14 resume os resultados obtidos referentes à segunda análise.

Tabela 6.14: Resultados referentes à segunda análise sobre o impacto do tamanho da amostra no método SPV.

Tamanho da amostra	P_i^{min} (%)
Amostra 1: N = 100	96,0000
SMC de evento raro: N = 10000	91,6400
SMC de evento raro: N = 200000	91,8340
ANA2PDF	91,6907

Os resultados obtidos nos Casos #1-D e #3-C confirmam que amostras com 100 elementos, utilizadas pelo SPV, não são suficientes para estimar com maior precisão o índice de probabilidade bivariado P_i . Esta consideração pode fazer com que o SPV aloque erroneamente mais ou menos medidor dependendo do plano de medições existente.

CONCLUSÕES

7.1 Introdução

Nesta dissertação foram desenvolvidos técnicas e algoritmos para alocar medidores de tensão e/ou fluxo de potência visando a estimação de estado em redes de distribuição radiais. As metodologias propostas para alocar medidores baseiam-se na combinação de três técnicas: linearização das funções associadas às medições via expansão de Taylor; simulação Monte Carlo não-sequencial para modelar o comportamento estocástico das medições, e; métodos para descorrelacionar variáveis aleatórias gaussianas. A aplicação destas técnicas possibilitou a estimação dos riscos dos erros relativos da magnitude e fase das tensões, com relação aos seus respectivos valores verdadeiros, violarem limites especificados. A minimização destes riscos foi utilizada como função objetivo do problema de alocação de medidores.

7.2 Principais Contribuições

As principais contribuições deste trabalho para alocação de medidores em redes de distribuição são:

I) Alocação de medidores com medições correlacionadas via SMC linear:

Como foi visto, o custo computacional do algoritmo proposto por Singh, Pal e Vinter (2009) é elevado devido a natureza não-linear, combinatorial e estocástica do problema. A partir da literatura técnica, também constatou-se que as metodologias de alocação de medidor, tanto em redes de distribuição quanto em sistemas de transmissão, fazem uso do método de Gauss-Newton para estimar o estado do sistema. Visando minimizar o custo computacional do algoritmo de alocação, o estado do sistema é estimado usando uma linearização das funções associadas às medições através da expansão de Taylor. Desta forma, quando há um novo vetor de medições, o estado do

sistema é obtido usando apenas uma transformação linear cujo dado de entrada é o vetor de medições. Visto que a matriz de sensibilidade da transformação é constante para um plano de medição específico, pode-se estimar o estado para vários conjuntos de medições sem a necessidade de atualizar a matriz de sensibilidade.

II) Alocação de medidores com medições correlacionadas via método analítico:

A partir da revisão bibliográfica sobre alocação de medidores em redes de distribuição, além das metodologias utilizarem o MGN na estimação do estado, elas fazem uso da técnica de simulação Monte Carlo para modelar o comportamento estocástico das medições. A segunda contribuição se baseia na linearização das funções não-lineares associadas às medições em torno do valor verdadeiro do vetor de estado da rede. Todavia, o método proposto dispensa a técnica de SMC para estimar a incerteza relativa do estado estimado. Em vez de se utilizar a SMC para calcular os riscos associados com os erros relativos, calcula-se esta probabilidade de forma direta usando as PDFs da magnitude e da fase para cada barra i do vetor de variáveis de estado. O método ANA2PDF, diferentemente dos métodos SPV e SMCLIN, não precisa estimar o estado do sistema a fim de calcular a função objetivo do problema de alocação. A grande vantagem do ANA2PDF é calcular esta função de forma direta (sem o uso da SMC) a partir das distribuições de probabilidade do estado estimado.

III) Avaliação da precisão de métodos de alocação baseados na SMC:

Os resultados dos testes com algoritmos de alocação proposto por Singh, Pal e Vinter (2009) (método SPV) demonstrou que este método está sujeito a erros de mascaramento quando a função objetivo do problema de alocação é estimada usando a SMC com uma amostra de apenas 100 elementos. Ou seja, o método SPV pode gerar um plano de medição subdimensionado no qual seria necessário instalar mais medidores para alcançar as metas estabelecidas para os riscos dos erros relativos.

7.3 Aplicações Práticas

A aplicação das metodologias proposta para alocação de medidores em redes de distribuição foi realizada no capítulo 6. O sistema teste utilizado para a aplicação das metodologias propostas foi parte de um sistema britânico de distribuição composto por

95 barras e duas unidades de GD. Este sistema foi utilizado para avaliar o comportamento de dois métodos propostos para alocação, um baseado na SMC linear e outro analítico baseado na distribuição de probabilidade nodal da magnitude e fase da tensão estimada. A seguir, são apresentadas as principais conclusões obtidas nos testes com o sistema teste de 95 barras STD_UKGDS95:

1) Do ponto de vista econômico, os resultados demonstram que desconsiderar os termos de alta ordem na expansão de Taylor das funções não-lineares, $h(\hat{x})$, não prejudicou o desempenho dos métodos SMCLIN e ANA2PDF em relação ao método de referência SPV, pois as técnicas alocaram a mesma quantidade de medidores. Outra consideração é referente à relação coeficiente de correlação entre medições de injeção/fluxo de potência e erros máximos de medição real e de pseudo-medição. À medida que se aumenta a correlação entre medições, seja de injeção ou fluxo de potência, o número de medidores alocados tende a diminuir gradativamente, tanto no método de referência SPV quanto nos métodos propostos. Uma possível explicação para isso é a aproximação realística do modelo de medições correlacionadas. Associar, por exemplo, uma medição de fluxo de potência ativa e reativa a um único medidor tornou o modelo de estimação de estado mais autêntico e, portanto, melhorou a precisão do índice de probabilidade P_i e das matrizes de covariância envolvidas no processo.

2) Foi visto que os índices P_i^{min} e R_i^{max} obtidos são, praticamente, equivalentes para os métodos SPV e SMCLIN, e bem próximos do método ANA2PDF. Em alguns casos, os índices referentes aos métodos SPV e SMCLIN diferem devido ao comportamento estocástico da SMC. Vale ressaltar que mesmo com o modelo aproximado de primeira ordem de $h(\hat{x})$, os métodos SPV e SMCLIN tendem ao mesmo valor do índice P_i do ANA2PDF quando o número de simulações é muito grande.

3) Os ganhos dos métodos SMCLIN e ANA2PDF ficaram mais evidentes no tempo computacional dos algoritmos. Ambos os métodos mostraram-se mais vantajosos do que o método de referência SPV. O método SMCLIN, na média, foi duas vezes mais rápido do que o SPV, ou seja, executa a mesma função do SPV com a metade do tempo. Já o método ANA2PDF, na média, foi cerca de trinta vezes mais rápido do que o SPV, gastando no máximo 5% do tempo que o SPV precisaria para executar a mesma função. É importante enfatizar que esta redução no custo computacional foi obtida sem sacrificar a precisão do cálculo da função objetivo, como demonstrado nas tabelas de

índices de probabilidade bivariados, e alocando a mesma quantidade de medidores – exceto para casos onde ocorreram erros de mascaramento.

4) Alguns resultados obtidos confirmaram que o método SPV é sensível ao comportamento estocástico das medições e, portanto, o número de simulações Monte Carlo sugerido por Singh, Pal e Vinter (2009) não é suficiente para estimar com maior precisão o índice de probabilidade bivariado P_i . Neste ponto, o método SPV pode alocar, erroneamente, mais ou menos medidor dependendo do plano de medições existente. Isso pode levar a mais gastos ou a mais imprecisão resultante de planos de medição subdimensionados. Vale ressaltar que o método SMCLIN também é passível dos mesmos problemas do SPV, pois faz uso da SMC com amostras de 100 elementos. Porém, o ANA2PDF é imune a estes problemas, porque dispensa a técnica de SMC para estimar o índice P_i . Este método o calcula o índice P_i de forma direta segundo as PDFs da magnitude e da fase da tensão para cada barra i do vetor de variáveis de estado.

7.4 Sugestões para Trabalhos Futuros

O tema principal desta dissertação foi alocação ótima de medidores visando a estimação de estado em redes de distribuição de energia elétrica. Trabalhos futuros neste assunto concentram-se no desenvolvimento de modelos e técnicas para simular de forma mais precisa locais candidatos para instalação de medidores na rede de distribuição de média e baixa tensão. A seguir, algumas sugestões para trabalhos futuros são apresentadas:

1) Extensão da metodologia proposta em coordenadas de fase:

Nesta dissertação, o índice de probabilidade bivariado P_i foi estimado utilizando-se o modelo de sequência positiva da rede. A escolha deste modelo teve por objetivo comparar as metodologias propostas de alocação com o método de referência desenvolvido por Singh, Pal e Vinter (2009). Entretanto, este modelo não permite representar de forma mais adequada aspectos associados à natureza desbalanceada das redes de distribuição, como por exemplo: a existência de laterais bifásicas ou monofásicas e os desequilíbrios das cargas entre as fases. Adicionalmente, foi possível inferir sobre a correlação de medições entre fases.

2) Modelo analítico para alocação de medidores multifuncionais:

Medidores multifuncionais são equipamentos projetados para a medição de diversas grandezas elétricas (tensão, corrente, potência, fator de potência, etc.) e também para a contabilização e registro de distúrbios de qualidade de energia (distorções harmônicas, afundamentos de tensão, subtensões/sobretensões, etc.). Os medidores multifuncionais são os mais utilizados atualmente na automação de sistemas de distribuição. Entretanto, as metodologias propostas para alocação de medidor baseiam-se em medidores convencionais, que são equipamentos dedicados para medição de apenas uma grandeza elétrica: tensão, corrente ou potência (ativa e reativa). Visto que os ganhos do método ANA2PDF são bastante expressivos, seria importante analisar o comportamento de uma técnica analítica de alocação de medidores multifuncionais em redes de distribuição.

3) Modelo analítico embarcado em meta-heurísticas para alocação de medidores convencionais ou multifuncionais:

Uma das características do problema de alocação de medidores para a EERD é a sua natureza combinatorial, pois as variáveis de decisão são as barras ou os ramos candidatos a instalação de dispositivos de medição. Desta forma é interessante se investigar o desempenho de meta-heurísticas, como Algoritmo Genético ou Otimização por Enxame de Partículas (PSO – *Particle Swarm Optimization*) para avaliar a qualidade das suas soluções para o problema de alocação com relação ao custo e a precisão. Este estudo torna-se viável devido às reduções significativas no custo computacional do algoritmo de alocação SPV produzidas pelo ANA2PDF.

REFERÊNCIAS

Abur, A., and Expósito, A. G. (2004) **Power System State Estimation: Theory and Implementation**. CRC Press.

Beard, C. (2010) **Smart Grid for Dummies**. Wiley.

Billinton, R., and Allan, R. N. (1992) **Reliability Evaluation of Engineering Systems: Concepts and Techniques**. 2nd ed. New York, Plenum Press.

Billinton, R., and Li, W. (1994) **Reliability Assessment of Electric Power Systems Using Monte Carlo Methods**. New York, Springer.

Brown, R. E. (2009) **Electric Power Distribution Reliability**. 2nd ed. New York, Marcel Dekker.

D.-García, A. D., Heydt, G. T., and Suryanarayanan, S. (2011) **Implications of the Smart Grid Initiative on Distribution Engineering. Part 3 – Restoration, State Estimation and Reliability Enhancement**. Arizona State University, PSERC Publication.

Debs, A. S. (1990) **Modern Power Systems Control and Operation**. Taiwan, Kluwer Academic Publishers.

Hadjsaïd, N., and Sabonnadière, J.-C. (2012) **Smart Grid**. Wiley.

Karady, G. G., and Holbert, K. E. (2013) **Electrical Energy Conversion and Transport**. Wiley-IEEE Press.

L.-Garcia, A. (2008) **Probability, Statistics, and Random Processes for Electrical Engineering**. 3rd ed. Pearson Prentice Hall.

Lewis, F. L., Xie, L., and Popa, D. (2008) **Optimal and Robust Estimation With an Introduction to Stochastic Control Theory**. 2nd ed. CRC Press.

Li, W. (2011) **Probabilistic Transmission System Planning**. Wiley.

Miller, S., and Childers, D. (2012) **Probability and Random Processes**. 2nd ed. Elsevier.

Mingoti, S. A. (2006) **Análise de Dados através de Métodos de Estatística Multivariada: Uma Abordagem Aplicada**. UFMG.

Montgomery, D. C., and Runger, G. C. (2011) **Applied Statistics and Probability for Engineers**. 5th ed. Wiley.

Monticelli, A. (1999) **State Estimation in Electric Power Systems: A Generalized Approach**. New York, Massachusetts, Kluwer Academic Publishers.

- Ross, S. M. (2010) **Introduction Probability Models**. 10th ed. California, Elsevier.
- Short, T. A. (2014) **Electric Power Distribution Handbook**. 2nd ed. CRC Press.
- Thomas, M. S., and McDonald, J. D. (2015) **Power System SCADA and Smart Grids**. CRC Press.
- Vaahedi, E. (2014) **Practical Power System Operation**. Wiley.
- Virgilito, S. B. (2007) **Estatística Aplicada**. 3ª ed. Edicon.
- Willis, H. L., and Scott, W. G. (2002) **Distributed Power Generation Planning and Evaluation**. New York, Marcel Dekker.
- Costa, A. S., e Salgado, R. (2002) **Notas de Aula da Disciplina EEL 6301 - Análise de Segurança em Sistemas Elétricos de Potência** [Internet], DEE/UFSC. Disponível em: <<http://www.labspot.ufsc.br/~simoies/assp/assp.html>>, [Acesso em: 16 de fevereiro de 2014].
- MathworksTM. (2004) **MATLAB Statistics Toolbox User's Guide. Version 5** [Internet], MathworksTM. Disponível em: <http://cda.psych.uiuc.edu/matlab_pdf/stats.pdf>, [Acesso em: 29 de agosto de 2015].
- Pal, B. C. (2015) **State Estimations in Power Distribution (SEPD)** [Internet], Imperial College London. Disponível em: <http://www.ee.ic.ac.uk/bikash.c.pal/index_files/state_space.html>, [Acesso em: 22 de abril de 2015].
- Bracale, A., Caramia, P., Carpinelli, G., Di Fazio, A. R., and Varilone, P. (2013) A Bayesian-Based Approach for a Short-Term Steady-State Forecast of a Smart Grid, **IEEE Trans. on Smart Grid**, vol. 4 Dec., pp. 1760-1771.
- Caro, E., Conejo, A., and Mínguez, R. (2009) Power System State Estimation Considering Measurement Dependencies, **IEEE Trans. on Power Systems**, Vol. 24, No. 4, pp. 1875-1885.
- Caro, E., Conejo, A., Mínguez, R., Zima, M., and Anderson, G. (2011) Multiple Bad Data Identification Considering Measurement Dependencies, **IEEE Trans. on Power Systems**, Vol. 26, No. 4, pp. 1953-1961.
- Ghosh, A. K., Lubkeman, D. L., Downey, M. J., and Jones, R. H. (1997) Distribution Circuit State Estimation using a Probabilistic Approach, **IEEE Trans. on Power Systems**, Vol. 12, No. 1, pp. 45-51.
- Lin, W. M., and Teng, J. H. (1996) Distribution fast decoupled state estimation by measurement pairing, **IEE Proceedings-Generation, Transmission and Distribution**, 143 (1), pp. 43-48.

Lin, W. M., Teng, J. H., and Chen, S. J. (2001) A highly efficient algorithm in treating current measurements for the branch-current-based distribution state estimation, **IEEE Trans. Power Delivery**, vol. 16, pp. 433–439.

Liu, J., Ponci, F., Monti, A., Muscas, C., Pegoraro, P. A., and Sulis, S. (2014) Optimal Meter Placement for Robust Measurement Systems in Active Distribution Grids, **IEEE Transactions on Instrumentation and Measurement**, Vol. 63, No. 5, pp. 1096-1105.

Lu, C. N., Teng, J. H., and Liu, W. H. E. (1995) Distribution System State Estimation, **IEEE Trans. on Power Systems**, 10 (1), pp. 229–240.

Morales, J. M., Baringo, L., Conejo, A. J., and Mínguez, R. (2010) Probabilistic Power Flow with Correlated Wind Sources, **IET Generation, Transmission & Distribution**, Vol. 4, No. 5, pp. 641-651.

Muscas, C., Pilo, F., Pisano, G., and Sulis, S. (2009) Optimal Allocation of Multichannel Measurement Devices for Distribution State Estimation, **IEEE Transactions on Instrumentation and Measurement**, Vol. 58, No. 6, pp. 1929-1937.

Shafiu, A., Jenkins, N., and Strbac, G. (2005) Measurement Location for State Estimation, **IEE Proceedings – Generation, Transmission and Distribution**, Vol. 152, No. 2, pp. 240-246.

Singh, R., Pal, B. C., and Jabr, R. A. (2008) Choice of estimator for distribution system state estimation, **IET Generation, Transmission & Distribution**, 3 (7), pp. 666–678.

Singh, R., Pal, B. C., and Vinter, R. B. (2009) Measurement Placement in Distribution System State Estimation, **IEEE Trans. on Power Systems**, Vol. 24, No. 2, pp. 668-675.

Singh, R., Pal, B. C., and Vinter, R. B. (2011) Meter Placement for Distribution System State Estimation: An Ordinal Optimization Approach, **IEEE Trans. on Power Systems**, Vol. 26, No. 4, pp. 2328-2335.

Souza, J. C. S., Assis, T. M. L, and Pal, B. C. (2016) Data Compression in Smart Distribution Systems via Singular Value Decomposition, **IEEE Trans. on Smart Grid**, Aceito para Publicação.

Valverde, G., Saric, A. T., and Terzija, V. (2013) Stochastic Monitoring of Distribution Networks Including Correlated Input Variables, **IEEE Trans. on Power Systems**, Vol. 28, No. 1, pp. 246-255.

Wang, H., and Schulz, N. N. (2004) A Revised Branch Current-Based Distribution System State Estimation Algorithm and Meter Placement Impact, **IEEE Trans. on Power Systems**, 19 (1), pp. 207–213.

AMPS – Applied Measurements for Power Systems, 2013. Aachen, Germany, 25-27 September. (2013). **Impact of Input Data Correlation on Distribution System State Estimation**, C. Muscas, M. Pau, A. P. Pegoraro, and S. Sulis. pp. 114-119.

CIREN – 18th International Conference and Exhibition on Electricity Distribution, 2005. Turin, Italy, 6-9 June. (2005). **Control of Active Networks**, A. Shafiu, V. Thornley, N. Jenkins, and G. Strbac. Session No. 4, pp. 1-4.

IMTC – Instrumentation and Measurement Technology Conference, 2006. Sorrento, Italy, 24-27 April. (2006). **Optimal Placement of Measurement Devices in Electric Distribution Systems**, C. Muscas, F. Pilo, G. Pisano, and S. Sulis. pp. 1873-1878.

SMART GRID & SMART STORAGE. (2015) [Imagem Online]. Disponível em: <<http://www.saetpd.it/activities/energy/smart-grid-smart-storage>>, [Acesso em: 15 de dezembro de 2015].