

# Aplicação de Métodos Ortogonais no Processamento de Erros Grosseiros em Estimadores de Estado para Sistemas de Distribuição

Julio A. D. Massignan\*, Renato de Oliveira\*\*, Gustavo M. Hebling\*, João Bosco A. London, Jr.\*

\*Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP  
Brasil (Tel.: 55 (16) 3373-8736; e-mail: julio.massignan@usp.br, gustavo.hebling@usp.br, jbalj@sc.usp.br).

\*\*Furnas Centrais Elétricas S.A., Rio de Janeiro, RJ, Brasil (Tel: 55 (34) 3428-5231; e-mail: renoliv@furnas.com.br)

---

**Abstract:** Real-Time operation of Distribution Systems demands the processing of substantial amount of data and information to support decision making at Operation Centers. State estimation is an essential part of this process and may require high computational effort due to numerical factorization of ill-conditioned matrices. Orthogonal methods have been widely applied to deal with this issue in Transmission Systems and recent proposals show its application on Distribution Systems. This paper presents the application of orthogonal methods for Gross Errors processing in three-phase IEEE test feeders, demonstrating that these methods are numerically robust and able to deal with ill conditioned systems with computational efficiency.

**Resumo:** A operação em tempo real de Sistemas de Distribuição exige o processamento de um número considerável de dados e informações para o apoio nas tomadas de decisões nos Centros de Operação. A estimação de estado é ponto chave neste processo e pode demandar alto esforço computacional devido à necessidade de fatoração numérica de matrizes mal condicionadas. Métodos ortogonais são amplamente aplicados para contornar este problema em Sistemas de Transmissão e propostas recentes os aplicam em Sistemas de Distribuição. Este artigo apresenta a aplicação de métodos ortogonais para processamento de erros grosseiros em alimentadores de teste trifásicos desbalanceados do IEEE, demonstrando que esses métodos são capazes de lidar com sistemas mal condicionados de forma eficiente computacionalmente e robusta numericamente.

**Keywords:** state estimation; state variables; orthogonal methods; gross errors; distribution systems;

**Palavras-chaves:** estimação de estado; variáveis de estado; métodos ortogonais; erros grosseiros; sistemas de distribuição.

---

## 1. INTRODUÇÃO

Dentro do contexto atual dos Sistemas de Distribuição (SDs), com a inserção cada vez maior de diferentes fontes de geração distribuída e a introdução de sistemas de medição inteligentes, o processo de Estimação de Estado (EE) apresenta-se como ferramenta essencial na operação em tempo real por parte das concessionárias e na direção das chamadas *Smart Grids*. A EE possibilita a avaliação da condição operacional por meio do processamento de dados estáticos (parâmetros da rede, topologia no modelo barra/ramo e localização de medidores) e de informações medidas provenientes do sistema SCADA (do inglês *Supervisory Control and Data Acquisition*), permitindo a tomada de decisão pelos centros de operação em situações de transição entre estados operativos (Abur et al 2004). Através de um processamento estatístico destas informações medidas, é possível reduzir sensivelmente o efeito de ruídos inerentes ao processo de medição, garantindo uma alta acurácia e maior confiabilidade no monitoramento das redes elétricas.

O estimador de estado mais utilizado na indústria é o baseado no método dos mínimos quadrados ponderados, ou WLS (do

inglês, *Weighted Least Squares*), e foi originalmente desenvolvido e largamente utilizado na estimação das tensões nodais de sistemas de transmissão (Abur et al. 2004). Um aspecto importante da EE, além da filtragem dos ruídos inerentes ao processo de medição, refere-se à possibilidade de detectar e identificar inconsistências nas medições, denominados Erros Grosseiros (EGs), e que podem surgir devido a medidores mal calibradas, saturação de TCs, erros de comunicação ou até mesmo ataques cibernéticos. Os métodos mais utilizados são o Teste do Maior Resíduo Normalizado (TMRN) e o Teste *b-chapéu* ( $\hat{b}$ ) (Monticelli et al. 1983).

Para os SDs, devido às características particulares de suas rede elétricas, como sua topologia radial de operação, a escassez de medidas SCADA ao longo dos alimentadores e a necessidade de uma análise que leve em consideração o modelo trifásico e desequilibrado, o estimador WLS, tal como foi concebido, apresenta limitações e requer adaptações através de algoritmos específicos (Primadianto et al. 2017).

Neste contexto, foram desenvolvidas metodologias alternativas ao uso do estimador tradicional WLS e especializadas em SDs, como a proposta baseada em correntes

nos ramos como variáveis de estado descrita em Baran (1994), assim como a baseada na formulação do problema a partir da matriz admitância do sistema, proposta em Lu (1995). A aderência destas formulações às características particulares dos SDs fomentou o avanço destas abordagens no quesito de aplicações em SDs, (Pau et al. 2013), uma vez que contornam os problemas associados ao mal condicionamento da matriz Ganho, que resulta em esforço computacional e instabilidade numérica do estimador WLS (Atanackovic et al. 2013).

Entretanto, estas abordagens se baseiam em aproximações do modelo de medição, através da transformação das grandezas elétricas mensuradas em medidas equivalentes de corrente. Como destacado por Feng (2012), a utilização da formulação baseada em injeção de corrente possui desvantagens teóricas e práticas, pois, além de envolver aproximações no processo de solução, envolve também aproximações do problema original. Dessa forma, o problema resolvido é como se fosse uma "réplica" do problema original, mas não seu equivalente (Feng, 2012). Apesar de obterem soluções pragmáticas ao problema de estimação, estas transformações modificam sensivelmente hipóteses relacionadas ao ruído das medidas, dificultando, por exemplo, o processamento adequado de EGs.

Para enfrentar os problemas de mal condicionamento da matriz Ganho na formulação tradicional do estimador WLS, foi proposta na literatura a aplicação de métodos ortogonais para manipulação numérica em processos de EE de modo a obter uma maior robustez numérica sem perda de acurácia na modelagem do problema (Monticelli et al. 1985) (Simoès-Costa et al. 1981). Porém, estes métodos focavam em aplicações em sistemas de transmissão, onde a redundância de medidas é maior e representa-se a rede elétrica pelo circuito de sequência positiva e balanceado. Somente em pesquisas recentes que vem sendo abordado o uso de métodos ortogonais no problema de estimação para SDs. É demonstrado por Hebling et al. (2020) que a fatoração QR de *Householder* pode contribuir neste sentido, explorando um método especial para matrizes esparsas baseado em fatoração Multifrontal, melhorando a eficiência computacional e aumentando a robustez numérica. Cabe ressaltar que estes métodos ortogonais já demonstraram características favoráveis ao problema de estimação de estado em sistemas de transmissão, vide os trabalhos de Quintana (1982) e Simoes-Costa (1981).

Neste sentido, este trabalho visa dar continuidade a estes esforços, estendendo os conceitos dos métodos ortogonais para o processamento de EGs em SDs. Através de uma formulação ortogonal do problema de estimação, demonstra-se que não é necessário o cálculo explícito da matriz Ganho, reduzindo drasticamente o problema de mal condicionamento. Porém, até então, para realizar o processamento de EGs, se mostrava necessário a obtenção da inversa desta matriz, algo que para SDs extremamente mal condicionados acabava por inviabilizar tal aplicação. A contribuição deste trabalho consiste na extensão dos métodos ortogonais para o processamento de EGs possibilitando um aumento da robustez numérica. Além disto, apresenta um algoritmo para o cálculo direto dos elementos da diagonal da matriz de covariância dos resíduos, aprimorando ainda mais a eficiência computacional.

Simulações computacionais são apresentadas nos alimentadores de teste trifásicos e desbalanceados do IEEE, demonstrando a eficácia desses métodos e a capacidade em lidar com redes de distribuição de energia. Destacamos aplicações de interesse dos resultados de processamento de EGs em condições anormais de operação e como este processamento pode fornecer valiosas informações aos operadores. Desta forma, através destas análises, espera-se fomentar a discussão sobre as vantagens da implantação de EE em SDs, também aprimorando aspectos práticos de interesse das concessionárias de distribuição.

## 2. ESTIMAÇÃO DE ESTADO EM SISTEMAS DE DISTRIBUIÇÃO

O estimador de estado WLS Trifásico baseia-se no modelo não linear das medidas e hipóteses clássicas do problema de EE (Abur et al 2004).

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

onde  $z$  é vetor de medidas ( $m \times 1$ ) composto pelos grandezas elétricas medidas;  $x$  é o vetor de variáveis de estado ( $n \times 1$ ) do sistema elétrico;  $h(x)$  é o conjunto de equações não lineares ( $m \times 1$ ) que relacionam as variáveis de estado com o vetor de medidas; e  $e$  é o vetor de erros nas medidas ( $m \times 1$ ), geralmente assumido como independente com Distribuição Normal de média zero e matriz de covariância conhecida  $\Sigma$  ( $m \times m$ ). As tensões complexas nodais trifásicas na forma polar correspondem às variáveis de estado.

$$x = [V_a V_b V_c \theta_a \theta_b \theta_c]^T \quad (2)$$

O estimador de estado WLS consiste na minimização da seguinte função objetivo:

$$\min J(x) = \frac{1}{2} [z - h(x)]' \Sigma^{-1} [z - h(x)] \quad (3)$$

A inversa da matriz de covariância  $\Sigma^{-1}$  é também denotada por  $W$  e chamada matriz de ponderação. Basicamente, a minimização da função acima é obtida através da solução iterativa da chamada Equação Normal do estimador WLS. O critério de convergência é dado pela comparação da atualização das variáveis de estado em cada iteração  $k$  com uma tolerância pré-especificada.

$$H(x^k)' W H(x^k) \Delta x = H(x^k)' W [z - h(x^k)] \quad (4)$$

$$|\Delta x|_\infty \leq tol \quad (5)$$

A abordagem tradicional de EE se baseia na solução das equações normais apresentada em (4). A obtenção da solução do sistema linear acima, em geral, é realizada através de métodos de fatoração, isto é, sem o cálculo explícito da inversa da matriz Ganho do estimador (6). Dentre os métodos, os mais comuns são os baseados na fatoração LDU da matriz Ganho, por exemplo o método Cholesky. Também é possível utilizar métodos de fatoração QR para solução das equações normais (Golub et al. 1996) (Higham 2002).

$$G(x^k) = H(x^k)' W H(x^k) \quad (6)$$

## 2.1 Modelagem de Redes Elétricas de Distribuição

O modelo de estado estático para cada equipamento da rede consiste no seu modelo de quadripolo de dois terminais considerando as respectivas matrizes admitância trifásicas, número de fases e tipos de conexão. Esta matriz admitância é mostrada em (7).

$$\begin{bmatrix} \hat{I}^p \\ \hat{I}^s \end{bmatrix} = \begin{bmatrix} Y^{pp} & Y^{ps} \\ Y^{sp} & Y^{ss} \end{bmatrix} \cdot \begin{bmatrix} \hat{V}^p \\ \hat{V}^s \end{bmatrix} \quad (7)$$

onde  $Y^{pp}$ ,  $Y^{ps}$ ,  $Y^{sp}$  e  $Y^{ss}$  são as submatrizes admitância características para cada equipamento,  $\hat{V}^p$  e  $\hat{V}^s$ ,  $\hat{I}^p$  e  $\hat{I}^s$  são os vetores das tensões complexas trifásicas e correntes complexas trifásicas nos terminais  $p$  e  $s$ , respectivamente. A Fig. 1 e as equações (9) e (10) apresentam o modelo em quadripolos para um ramal de distribuição trifásico típico. Maiores detalhes dos modelos trifásicos e respectivas matrizes admitância para construção dos modelos de quadripolos para circuitos de distribuição, transformadores, reguladores de tensão, bancos de capacitores, entre outros, podem ser encontrados em Hebling (2020) e Massignan (2017).

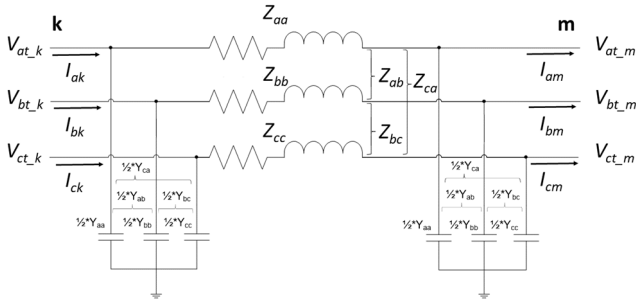


Fig. 1. Modelo trifásico utilizado para representar os ramos de distribuição.

$$Z_{\text{line}} = \begin{bmatrix} Z_{aa} & Z_{ab} & Z_{ac} \\ Z_{ba} & Z_{bb} & Z_{bc} \\ Z_{ca} & Z_{cb} & Z_{cc} \end{bmatrix} \quad Y_{\text{line}}^{sh} = \begin{bmatrix} Y_{aa}^{sh} & Y_{ab}^{sh} & Y_{ac}^{sh} \\ Y_{ba}^{sh} & Y_{bb}^{sh} & Y_{bc}^{sh} \\ Y_{ca}^{sh} & Y_{cb}^{sh} & Y_{cc}^{sh} \end{bmatrix} \quad (8)$$

$$Y^{pp} = Y^{ss} = Z_{\text{line}}^{-1} + Y_{\text{line}}^{sh} \quad (9)$$

$$Y^{ps} = Y^{sp} = -Z_{\text{line}}^{-1} \quad (10)$$

Através de (7) é possível formular os modelos de medição de acordo com as medidas disponíveis (SCADA e PMU) ou medidas provenientes das informações da rede (pseudomedidas e medidas virtuais). Em geral, representam fluxos de potência ativas e reativas em ramos da rede elétrica, injeções de potência ativa e reativa e magnitudes de tensão em barras da rede elétrica, sendo estas equações obtidas a partir das expressões de fluxo de potência nos ramos da rede (Hebling et al. 2020).

## 2.2 Aplicação de Métodos Ortogonais

A estratégia de solução das equações normais descrita por (4) pode tornar-se custosa computacionalmente e passível de deterioração numérica devido ao mal condicionamento da matriz Ganho do estimador (6). Para melhorar este aspecto, o estimador WLS trifásico implementado utiliza uma abordagem baseada na fatoração QR para obtenção iterativa do vetor de estado, mas sem a necessidade do cálculo da matriz Ganho. A seguir, é descrita a estratégia de obtenção iterativa do vetor de estado através dos métodos ortogonais.

Inicialmente é obtida a fatoração QR via o método das reflexões de Householder (Golub et al. 1996) (Higham 2002), da seguinte matriz em (11). Cabe ressaltar que outros métodos de fatoração podem ser empregados, como o método de Gram-Schmidt (Golub et al. 1996) ou mesmo o método de Rotações de Givens (Simoes-Costa 1981). Este último empregado com sucesso no contexto de estimação de estado para sistemas de transmissão devido a características favoráveis para tratamento de esparsidade. Cabe ressaltar que neste trabalho a aplicação de métodos ortogonais é genérica quanto ao algoritmo de fatoração, mas que este aspecto pode incrementar ainda mais a eficiência computacional caso métodos especiais sejam empregados, como por Simoes-Costa (1981) através das Rotações de Givens ou pela versão Multifrontal em Blocos das Reflexões de Householder por Hebling (2020).

$$W^{1/2}H(x^k) = Q'R \quad (11)$$

Com isto, podemos reescrever as equações normais como:

$$((R'Q)(Q'R))\Delta x = (R'Q)W^{1/2}[z - h(x^k)] \quad (12)$$

Simplificando, e usando a propriedade de ortogonalidade da matriz fatorada  $QQ'=I$ :

$$(R'R)\Delta x = (R'Q)W^{1/2}[z - h(x^k)] \quad (13)$$

Multiplicando-se ambos os lados da equação por  $R^{-1}$ :

$$R\Delta x = QW^{1/2}[z - h(x^k)] \quad (14)$$

Uma vez que a matriz  $R$  é triangular superior, a solução do sistema (14) é obtida diretamente pela multiplicação matriz-vetor da parcela da direita da equação e aplicando o método de substituição *Backward*. Outra vantagem importante da aplicação do método de fatoração QR diz respeito à robustez numérica, em termos do condicionamento numérico para obtenção do vetor de estado. Utilizando a abordagem de solução direta das equações normais (através de (4)), pode-se obter a seguinte expressão para análise do número de condicionamento numérico (aqui expresso como a razão entre o maior e menor valor singular de uma matriz):

$$k(H'WH) \cong k(W^{1/2}H)^2 \quad (15)$$

Desta forma, é possível esperar que o número de condicionamento das equações normais seja da ordem de grandeza do quadrado do número de condicionamento da matriz  $W^{1/2}H$  (Higham 2002). Utilizando a fatoração QR, entretanto, exige-se a solução de um sistema com condicionamento numérico muito menor,  $k(W^{1/2}H)$ :

$$\begin{aligned} k(R) &= \|R\| \|R\|^{-1} \\ &= \|(Q^{-1}W^{1/2}H)\| \|(W^{1/2}H)^{-1}Q'\| \\ &\sim \|Q^{-1}\| \|W^{1/2}H\| \|(W^{1/2}H)^{-1}\| \|Q'\| \end{aligned} \quad (16)$$

com  $QQ'=I$ ,  $Q'=Q^{-1}$ ,  $\|Q\| = \|Q^{-1}\| = 1$ , assim:

$$\begin{aligned} &\sim \|(W^{1/2}H)\| \|(W^{1/2}H)^{-1}\| \\ &= k(W^{1/2}H) \end{aligned}$$

### 2.3 Análise de Resíduos Normalizados via métodos Ortogonais

O processamento de EGs é realizado após a convergência do estimador de estado, através do cálculo do resíduo normalizado e do erro estimado pelo método  $\hat{b}$ . O cálculo dos resíduos normalizados se dá inicialmente pela matriz de covariância dos resíduos, com o valor do estado estimado  $\hat{x}$ :

$$\Omega = W^{-1} - H(\hat{x})(H(\hat{x})'WH(\hat{x}))^{-1}H'(\hat{x}) \quad (17)$$

Assim como no processo iterativo de estimação do estado, a obtenção desta matriz de covariância dos resíduos pode sofrer com o mal condicionamento numérico (Quintana 1982). Novamente, neste trabalho é utilizado a fatoração ortogonal da matriz  $W^{1/2}H$  de forma a possibilitar o cálculo da matriz de covariância dos resíduos de forma numericamente estável.

$$\Omega = W^{-1} - H(\hat{x})((R'Q)(Q'R))^{-1}H'(\hat{x}) \quad (18)$$

$$\Omega = W^{-1} - H(\hat{x})(R'R)^{-1}H'(\hat{x}) \quad (19)$$

Desta forma a obtenção da matriz pode ser feita através de uma sequência de substituições *Forward* e *Backward* nas matrizes  $R'$  e  $R$ , respectivamente, obtidas de forma estável pela fatoração QR. Apesar disto, o cálculo da matriz de covariância dos resíduos ainda exige a multiplicação pelas matrizes Jacobiana e sua transposta, novamente ameaçando o condicionamento numérico do problema.

Neste sentido, a metodologia apresentada propõe uma abordagem para contornar este efeito indesejado e mantendo acurácia. A equação (17), pode ser rearranjada como:

$$\Omega = W^{-1} - H(\hat{x})R^{-1}R^{-1}H'(\hat{x}) \quad (20)$$

Fazendo uso de uma matriz auxiliar  $Y$  ( $m \times n$ ), podemos encontrar os elementos da diagonal com apenas uma sucessão de  $m$  execuções da substituição *Forward* e do cálculo de produtos escalares de cada resultado, de acordo:

$$R'Y = H'(\hat{x}) \quad (21)$$

$$\Omega_{ii} = W_{ii}^{-1} - \langle Y_{:,i}', Y_{:,i} \rangle = W_{ii}^{-1} - \|Y_{:,i}\|_2^2 \quad (22)$$

Isto se traduz num incremento de robustez numérica no cálculo da matriz de covariância dos resíduos, uma vez que não mais requer o cálculo explícito da matriz Ganho nem da multiplicação pela Jacobiana e sua transposta, com um aumento significativo de performance computacional. De posse dos elementos da diagonal da matriz de covariância dos resíduos, obtém-se então o resíduo normalizado para cada uma das medidas através de:

$$r_i^N = \frac{\sigma_{ii}}{\sqrt{\Omega_{ii}}}(z - h(\hat{x})) \quad (23)$$

Na qual,  $\sigma_{ii}$  é o desvio padrão da  $i$ -ésima medida, dado pelos elementos da diagonal da matriz de covariância  $\Sigma$  assumida para os erros no modelo de medição. Além dos resíduos normalizados, também é calculado para cada medida o valor de erro estimado pelo método  $\hat{b}$  (Monticelli et al. 1983):

$$\hat{b}_i = \frac{\sigma_{ii}}{\sqrt{\Omega_{ii}}}r_i^N \quad (24)$$

Com estes dois indicadores, é possível realizar o processamento de EGs através dos métodos clássicos da

literatura pela comparação dos valores dos indicadores acima com níveis de detecção específicos. O primeiro detecta e indica qual medida apresenta EG e se esta é considerada crítica, ou seja, se a sua remoção impede a observabilidade do sistema ao qual pertence. O segundo é utilizado em conjunto com o primeiro, estimando o valor do EG através de uma projeção dos resíduos suspeitos e possibilitando a recuperação de uma medida portadora de EG ao invés de eliminá-la.

Tais técnicas, no entanto, apresentam limitações e vulnerabilidades, como apontado por Massignan et al. (2020), que propõe também a análise complementar de correlação entre os resíduos com base no chamado índice *UI* (*Undetectability Index*). Este índice, proposto por Benedito et al. (2013), baseia-se em elementos da matriz de sensibilidade do resíduo, conforme (25), e é utilizado de modo a auxiliar na interpretação dos resultados. Isto em razão de o processamento de EGs em medidas com alto índice *UI* ser mais difícil. Aqui cabe ressaltar que a obtenção deste índice é também resultado direto da aplicação dos métodos ortogonais.

$$UI_i = \frac{\sqrt{1 - \Omega_{ii}W}}{\sqrt{\Omega_{ii}W}} = \frac{\sqrt{1 - S_{ii}}}{\sqrt{S_{ii}}} \quad (25)$$

### 3. SISTEMÁTICA DE AVALIAÇÃO DE DESEMPENHO

A metodologia de testes de desempenho consiste basicamente em emular o ambiente de operação do SD, simulando, a partir de um caso de referência, as entradas do estimador de estado (Dados da Rede Elétrica, Topologia da Rede e Medidas de Grandezas Elétricas). Este caso de referência é caracterizado pela solução do cálculo de fluxo de potência a partir de um cenário de carregamento.

Os valores das medidas em tempo real, que representam o sistema SCADA (ou por PMUs, medidores inteligentes ou mesmo pseudomedidas), são emulados a partir de simulações de Monte Carlo. Esta metodologia consiste basicamente na inserção de ruído nas grandezas elétricas calculadas para o caso de referência. O ruído é obtido através da amostragem aleatória em uma quantidade total de simulações de Monte Carlo (geralmente acima de 100). As amostras de ruído são geradas individualmente, para cada medida, a partir de um gerador de números aleatórios e do desvio padrão da respectiva medida (assumido como conhecido), conforme (26).

$$z_i = z_i^{ref} + u_i \cdot \frac{|z_i^{ref}| \cdot pr_i}{3} \quad (26)$$

na qual,  $z_i$  é o valor da medida  $i$  com a inserção de ruído que será utilizado como dado de entrada no estimador de estado,  $z_i^{ref}$  é o respectivo valor da grandeza elétrica obtida no caso de referência,  $pr_i$  é a respectiva precisão do medidor em percentual obtido de sua classe de precisão dos dados de placa, e  $u_i$  é uma variável aleatória com distribuição normal padronizada, de média zero e desvio unitário, ou seja,  $u_i \sim N(0,1)$ , cujo valor é obtido através de um gerador de números aleatórios. O cálculo do desvio padrão e sua interpretação é importante pois guia também a inserção de EGs. Estes são emulados como *outliers* de valor controlado em função das características de precisão individual de cada medidor (por exemplo 20x o desvio padrão da medida).

O desempenho do estimador de estado é então avaliado em termos de uma análise dos erros de estimação considerando os resultados obtidos no caso referência. Neste trabalho, foi utilizado o indicador de erro MAE (*Mean Absolute Error*) como métrica de desempenho, dado por:

$$MAE_i = \frac{1}{n_{trials}} \sum_{K=1}^{n_{trials}} |\hat{x}_i^K - x_i^{ref}| \quad (27)$$

onde,  $K$  denota cada repetição da simulação de Monte Carlo com  $n_{trials}$  repetições. A Fig. 2 ilustra esta sistemática de avaliação de desempenho. Este tipo de metodologia já é consolidado na área de EE e busca representar, em um ambiente controlado de simulação, as condições encontradas nos centros de operação (Singh et al. 2009) (da Silva et al. 2018) (Castillo et al. 2011).




Fig. 2. Sistemática de teste de validação do estimador de estado baseado em simulação de Monte Carlo com referência gerada pelo cálculo de fluxo de potência.

#### 4. RESULTADOS DE SIMULAÇÃO

Os alimentadores de teste trifásicos e desbalanceados do IEEE (IEEE, 2020) foram utilizados para a realização das simulações. Em todos os testes foi considerada a condição nominal dos respectivos sistemas para compor os cenários de referência (cálculo de fluxo de potência), alterando somente o tipo de cargas para PQ em estrela aterrado, isto é, sem modelos de carga dependentes de tensão. Os testes realizados se dividiram em três tipos: o primeiro consistindo em simulações de Monte Carlo para averiguar o comportamento estatístico e precisão do estimador; o segundo para averiguar o processamento de EGs através dos métodos ortogonais; e o terceiro para explorar desempenho computacional e numérico.

O plano de medição base para o sistema IEEE123 utilizado na simulação de Monte Carlo e para as simulações de EGs é ilustrado na Fig. 3. É considerado um cenário com a subestação e equipamentos especiais (reguladores, transformadores, chaves e capacitores) dispendo de medidas SCADA (precisão de 2%) e pseudomedidas de potência ativa e reativa nos transformadores de distribuição (precisão de 30%). Vale ressaltar que este cenário busca representar uma condição realística dos SDs, onde a maioria das informações é composta de pseudomedidas de carga e poucas informações do SCADA em tempo real ao longo do alimentador.

##### 4.1 Análise de Desempenho e Precisão do Estimador

Inicialmente foi realizada uma análise de desempenho e precisão do estimador em um cenário somente com ruídos de medição, isto é, dentro da faixa de precisão adotada. Esta avaliação considerou diferentes níveis de redundância, configurados em três cenários de planos de medição distintos,

que buscam capturar condições extremas de redundância e uma condição realística de informações do SCADA:

1. Cenário de redundância mínima: pseudomedidas em todos os transformadores de distribuição + Medida SCADA de tensão na subestação;
2. Cenário subestação e equipamentos especiais (reguladores, transformadores, chaves e capacitores) monitorados: pseudomedidas em todos os transformadores de distribuição e medidas SCADA de tensão e potências ativa e reativa na subestação e reguladores e potências ativa e reativa nos transformadores, chaves e capacitores (Fig. 3);
3. Cenário de redundância máxima: todas as medidas SCADA possíveis.

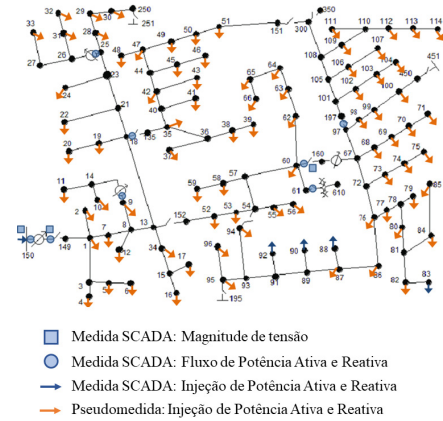


Fig. 3. Sistema teste IEEE123 e respectivo plano de medição.

A Fig. 4 apresenta a métrica de desempenho MAE de cada uma das variáveis de estado (magnitudes de tensão em todas as fases de todas as barras e seus respectivos ângulos) dentre todas as repetições da simulação de Monte Carlo. Este resultado busca ilustrar o nível de precisão que pode ser obtido pelo estimador somente na presença de ruído de medição, isto é, sem a influência de EGs, além de demonstrar uma validação das implementações. Nota-se, como esperado, o aumento da acurácia do estimador conforme medidas são adicionadas no SD. Vale ressaltar que, com poucas medidas do sistema SCADA, se obtém uma melhora expressiva, mas ainda assim um baixo nível de redundância global, relação entre quantidade de medidas e variáveis de estado, de 1.12.




Fig. 4. Métrica de desempenho MAE das variáveis de estado em diferentes cenários de redundância.

##### 4.2 Erros Grosseiros em medidas SCADA

Para cada caso de EG é apresentada uma tabela com o tipo de medida, sua localização, o valor de referência para a medida contaminada com EG  $z_{ref}$  (proveniente do cálculo de fluxo de potência), a precisão adotada  $Pr$ , o respectivo valor de desvio-padrão  $\sigma$  e o EG inserido. Em seguida, é apresentada uma

figura que sintetiza a análise dos índices de detecção de EGs: o resíduo normalizado e o erro estimado pelo método  $\hat{b}$  para cada medida. Para guiar a análise qualitativa do processamento de EGs, são destacados nas figuras os índices das medidas contaminadas com EG ( $x$  e  $y$ ) e duas retas vermelhas que indicam os limiares para comparação dos resíduos normalizados ( $\beta = 3$ ) e do valor de  $\hat{b}$  ( $c = 4$ ). Além disto, são destacadas duas retas verdes que representam o índice denominado  $UI$  para qualificação de medidas que apresentam vulnerabilidade no processamento de EGs.

Inicialmente foi adicionado um EG em uma medida na subestação, em uma das fases do fluxo de potência ativa. A medida destacada na Fig. 5 apresentou resíduo normalizado e erro estimado superiores aos limiares considerados, apresentando baixo índice  $UI$ , sendo de fácil detecção.

**Tabela 1. EG de  $20\sigma$  no fluxo de potência ativa na fase C da saída da subestação (regulador 150-149)**

Tipo	Localiz.	$Z_{ref}$ (kW)	$\sigma$ (kW)	EG (kW)
SCADA	P <sub>150-149</sub> <sup>C</sup>	1193,0181	7,953	$20\sigma = 159,069$




Fig. 5. Análise dos índices de detecção de EG. Os pontos em azul representam os valores de resíduo normalizado e erro estimado pelo método b-chapéu para cada respectiva medida do plano de medição. Em destaque, em preto, os valores da medida contaminada com erro grosseiro, sendo as demais consideradas somente com ruído branco. As retas em vermelho representam os limiares de detecção e as retas em verde as retas que delimitam o valor do índice  $UI$  das medidas.

No intuito de explorar mais efeitos de EGs, foi adicionado um EG em uma medida ao longo do alimentador. Mesmo em uma região que possui menor nível de redundância, quando comparado com a subestação, ainda é possível obter bons resultados de detecção. Note que, neste caso, a medida se apresenta com um índice  $UI$  médio entre  $UI = 2$  e  $UI = 5$ .

**Tabela 2. EG fase trocada A e C no fluxo de potência ativa de chave no alimentador (chave 18-35)**

Tipo	Localiz.	$Z_{ref}$ (kW)	$\sigma$ (kW)	EG (kW)
SCADA	P <sub>18-35</sub> <sup>A</sup>	301,5528	2,010	$-50,9\sigma = -101,127$
SCADA	P <sub>18-35</sub> <sup>C</sup>	200,5489	1,337	$75,7\sigma = 102,632$




Fig. 6. Análise dos índices de detecção de EG.

Em seguida, para demonstrar situações de difícil identificação, foram acrescentados dois EGs no par de medidas SCADA de injeção de potência em um dos bancos de capacitor. Nota-se que essas medidas com  $UI$  altos dificultam o processamento,

não sendo detectado nem identificado corretamente. Neste sentido, vale destacar um aspecto demonstrado em (Benedito, 2013) sobre o índice  $UI$ , que apesar desta medida apresentar um valor medido relativamente pequeno, este índice está mais relacionado com características intrínsecas ao modelo de medição e não com o valor medido ou mesmo com a magnitude do EG inserido. Ou seja, mesmo se o valor fosse mais expressivo ainda seria uma região de difícil detecção.

**Tabela 3. EG de  $20\sigma$  na fase B do fluxo de potência ativa e reativa do banco de capacitor na barra 90**

Tipo	Localiz.	$Z_{ref}$ (kW)	$\sigma$ (kW)	EG (kW)
SCADA	P <sub>90</sub> <sup>B</sup>	40,0000	0,267	$20\sigma = 5,333$
SCADA	Q <sub>90</sub> <sup>B</sup>	20,0000	0,133	$20\sigma = 2,667$




Fig. 7. Análise dos índices de detecção de EG.

### 4.3 Erros Grosseiros em Pseudomedidas

Nesta segunda seção de teste, foram avaliados os efeitos de EGs em pseudomedidas. Inicialmente foi adicionado um EG em uma das fases de uma pseudomedida. Apesar de um baixo índice  $UI$ , o processamento de EG apresentou dificuldades quanto à identificação visto que outras medidas também apresentaram resíduo normalizado similar ao da medida com EG. Isto ocorre devido ao fato de que geralmente as pseudomedidas formam conjuntos críticos de medidas, apresentando, assim, valores de resíduo normalizado muito próximos. Desta forma dificultando a correta identificação de um erro grosseiro dentre as medidas do conjunto crítico, um desafio adicional ao processamento de EGs em SDs.

**Tabela 4. EG de  $20\sigma$  na fase A da pseudomedida de injeção de potência ativa de carga na barra 76**

Tipo	Localiz.	$Z_{ref}$ (kW)	$\sigma$ (kW)	EG (kW)
PSEUDO	P <sub>48</sub> <sup>A</sup>	70,0000	7,000	$20\sigma = 140,000$




Fig. 8. Análise dos índices de detecção de EG.

Uma vez que as pseudomedidas de carga em SDs são geralmente obtidas através de curvas típicas, é esperado que EGs nessas curvas (por exemplo, devido à má classificação dos consumidores ou curvas não atualizadas) se propaguem por um número relativamente alto de pseudomedidas nos SDs, criando situações de EGs múltiplos. No intuito de avaliar este efeito, foram inseridos EGs em 10% do conjunto de pseudomedidas, conforme apresentado a seguir.

**Tabela 5. Múltiplos EGs de  $20\sigma$  em 20% das pseudomedidas de potência ativa e reativa**

Tipo	Localização	EG (kW)
PSEUDO	$P_{5^C}, P_{19^A}, P_{24^C}, P_{32^C}, P_{42^A}, P_{47^A}, P_{51^A}, P_{64^B}, P_{65^C}, P_{76^C}, P_{109^A}, Q_{5^C}, Q_{19^A}, Q_{24^C}, Q_{32^C}, Q_{42^A}, Q_{47^A}, Q_{51^A}, Q_{64^B}, Q_{65^C}, Q_{76^C}, Q_{109^A}$	$20\sigma$




Fig. 9. Análise dos índices de detecção de EG.

Nota-se novamente uma situação extremamente difícil de identificação. Apesar disto, estes métodos ainda capturam os efeitos conjuntos destes EGs, motivando buscas por metodologias complementares de processamento de EGs.

## 5. ANÁLISE DOS RESULTADOS

No intuito de auxiliar a visualização de regiões vulneráveis para o processamento de EGs, a Fig. 10 apresenta o mapeamento da rede elétrica e respectivo plano de medição, considerando o índice  $UI$  para classificação das medidas quanto à dificuldade de processamento de EGs. O tamanho e coloração de cada nó são proporcionais ao índice  $UI$  da medida, seguindo a escala na figura.




Fig. 10. Mapeamento de regiões vulneráveis para o processamento de EGs de acordo com o índice  $UI$ .

Para averiguar a aderência do índice  $UI$  para mapeamento de vulnerabilidades foram realizadas 100 repetições de Monte Carlo. Cada repetição apresenta um EG adicionado em uma medida diferente, aleatoriamente escolhida dentro de cada conjunto de acordo com o respectivo índice  $UI$ .

**Tabela 6. Assertividade de identificação de EGs para diferentes níveis de magnitude de EGs e de acordo com o índice  $UI$**

Tipo	Índice $UI$	$10\sigma$	$20\sigma$	$50\sigma$
SCADA	Alto $UI > 5$	0,0 %	2,0 %	52,3 %
	Médio $2 < UI < 5$	26,3 %	89,9 %	100,0 %
	Baixo $UI < 2$	100,0%	100,0%	100,0 %
PSEUDO	Alto $UI > 5$	0,0 %	2,0 %	17,2 %
	Médio $2 < UI < 5$	0,0 %	21,2 %	27,3 %
	Baixo $UI < 2$	22,2 %	28,3 %	36,4 %

De uma forma geral, pode-se observar que a baixa redundância dos SDs dificulta o processamento de EGs pelas abordagens tradicionais. Apesar disto, nota-se que existem situações em que é possível realizar um processamento de EGs de forma precisa e com bons resultados, em especial no caso de erros

nas medidas do sistema SCADA de baixo índice  $UI$ . Quanto a pseudomedidas, estas representam dificuldades adicionais de identificação de EGs, pois apresentam baixa precisão, o que as torna menos sensíveis e por geralmente formarem conjuntos críticos de medidas. Entretanto, é possível detectar efeitos de EGs em regiões específicas ou mesmo seus efeitos conjuntos.

Quanto ao mapeamento das medidas SCADA pelo índice  $UI$ , este apresentou boa aderência frente aos cenários avaliados, como apresentado na tabela anterior e nos exemplos ilustrados anteriormente. Ou seja, regiões de alto índice  $UI$  são menos sensíveis no processamento de EGs via resíduos normalizados e erro estimado pelo método  $\hat{b}$ . Vale destacar que, mesmo em condições de índices  $UI$  menores, ainda devem ser levados em consideração aspectos de observabilidade, em especial para capturar vulnerabilidades relativas aos conjuntos críticos de medidas formados por pseudomedidas.

## 5.1 Desempenho computacional

As simulações computacionais foram realizadas com uma implementação do estimador de estado trifásico em linguagem C e os resultados obtidos em um microcomputador Core i7 2.60 GHz, 8GB RAM. Na Fig. 11 são apresentadas as características de convergência para os sistemas IEEE 4, 13, 34 e 123 barras, e os respectivos tempos de execução do estimador de estado. Em seguida, na Tabela 7 são apresentadas características específicas do processamento de EGs, em comparação com a abordagem tradicional de solução das equações normais. Notam-se as principais vantagens da implementação através do método proposto, baseado na fatoração ortogonal da matriz Jacobiana ponderada ( $W^{1/2}H$ ) ao invés de utilizar explicitamente a matriz Ganho, tanto uma redução no condicionamento numérico do problema quanto um ganho de eficiência computacional.




Fig. 11. Convergência e tempos de processamento do estimador de estado trifásico nos sistemas de teste IEEE.

**Tabela 7. Condicionamento numérico e tempo de processamento de EGs para os sistemas de teste**

Sistema de Teste	Número de Condicionamento		Tempo de Proc. de EGs (s)	
	$G(x)$	$W^{1/2}H$	Método Tradicional	Método Ortogonal
IEEE4	3,1 E+05	4,7 E+02	0,001	0,001
IEEE13	9,9 E+11	7,2 E+06	0,015	0,001
IEEE34	9,8 E+12	1,6 E+07	0,078	0,031
IEEE123	4,7 E+11	5,1 E+07	1,672	0,547

## 6. CONCLUSÕES

O mal condicionamento numérico do problema de EE em SDs limita tanto a aplicação de estimadores de estado nestas redes, como também inibem a exploração de técnicas de processamento de EGs. No intuito de aprimorar este aspecto,

este trabalho apresentou uma nova abordagem para o processamento de EGs em estimadores de estado para SDs que é baseada em métodos ortogonais incrementando sensivelmente a robustez numérica e permitindo a aplicação de técnicas de processamento de EGs em SDs mal condicionados.

Resultados de simulações, obtidos no sistema IEEE123, demonstram que as medidas SCADA disponíveis proporcionaram uma maior assertividade na detecção e identificação de EGs. Sendo esta detecção possível pela avaliação dos resíduos normalizados em conjunto com o método  $\hat{b}$ , e também pelo emprego da técnica de análise dos índices  $UI$ , utilizado neste trabalho como indicador da vulnerabilidade de regiões dos SDs aos efeitos dos EGs. Por outro lado, a presença de pseudomedidas também comprovou as dificuldades de detecção de EGs. Além de apresentarem valores de índice  $UI$  maiores (ou seja, mais vulneráveis), em geral estas pseudomedidas formam conjuntos críticos de medidas o que dificulta ainda mais a correta detecção e identificação de EGs. Apesar disto, nota-se que os efeitos conjuntos destes EGs ainda são possíveis de se capturar indicando a necessidade de análises complementares. Por fim, a proposta de aplicação de métodos ortogonais nas etapas envolvidas no processo de EE apresentou um ganho considerável na robustez numérica e eficiência computacional

Dentre os trabalhos futuros, destaca-se a investigação de metodologias complementares para o processamento de EGs em SDs em conjunto com análises qualitativas de observabilidade, em especial através de informações complementares para as pseudomedidas. Além disto, também é interessante a exploração de diferentes algoritmos de fatoração ortogonal para elencar vantagens específicas no tratamento de sistemas de distribuição.

#### AGRADECIMENTOS

Os autores agradecem a Universidade de São Paulo (USP) e às agências de fomento CAPES, CNPq (308297/2018-0) e FAPESP (processo nº 2016/19646-6) pelo apoio financeiro.

#### REFERÊNCIAS

- Abur, A. and Exposito, A. G. (2004). Power system state estimation: theory and implementation. CRC Press. New York.
- Almeida, M. A. and Ochoa, L. F. (2017). An improved three-phase AMB distribution system state estimator. *IEEE Trans. Power Systems*, vol. 32, no. 2.
- Atanackovic, D. and Dabic, V. (2013). Deployment of real-time state estimator and load flow in BC Hydro DMS - challenges and opportunities. *2013 IEEE PES General Meeting*, Vancouver, BC.
- Baran, M. and Kelley, A. (1994). State estimation for real-time monitoring of distribution systems. *IEEE Transactions on Power Systems*, vol. 9, no. 3, p. 1601-1609.
- Benedito, R. A. S., Alberto, L. F. C., Bretas, N. G. and London Jr., J. B. A. (2013). Power system state estimation: undetectable bad data. *Int. Trans. Electr. Energy Syst.*
- Castillo, M. R. M., et. al. (2011). Offline detection, identification, and correction of branch parameter errors based on several measurement snapshots. *IEEE Trans. Power Syst.*, vol. 26, no. 2, pp. 870-877.
- Feng, X., Yang, F., Peterson, W. (2012). A practical multi-phase distribution state estimation solution incorporating smart meter and sensor data. *IEEE Power and Energy Society General Meeting*, pp.1-6, 22-26.
- Golub, G. H. and Van Loan, C. F. (1996). Matrix computations, 3rd ed. The Johns Hopkins University Press, Maryland.
- Hebling, G.M., Massignan, J. A. D., London Jr., J. A. B. and Camillo, M. H. M. (2020). Sparse and numerically stable implementation of a distribution system state estimation based on Multifrontal QR factorization. *Electric Power System Research*, vol. 189, pp. 106734
- Higham, N. J. (2002). Accuracy and Stability of Numerical Algorithms, 2nd ed. Society for Industrial and Applied Mathematics, Philadelphia.
- IEEE (2020), "IEEE Test Feeders." [Online]. Disponível em: <http://sites.ieee.org/pes-testfeeders/>. [Acessado em 01-Maio-2020].
- KEMA (2006). Metrics for determining the impact of phasor measurements on power system state estimation, DRAFT. Eastern Interconnection Phasor Project.
- Lu, C. N., Teng, J. H., Liu, W. H. E. (1995). Distribution system state estimation. *IEEE Transactions on Power Systems*, v. 10, n. I, p. 229-240.
- Massignan, J. A. D., Pereira Jr., B. R., London Jr., J. B. A. (2017) Load Flow Calculation with Voltage Regulators Bidirectional Mode and Distributed Generation. *IEEE Trans. on Power Systems*, v. 32, n. 2, pp. 1576-1577.
- Massignan, J. A. D., London Jr., J. B. A., Miranda, V. and Vieira, C. S. (2020). Vulnerability of largest normalized residual test and  $\hat{b}$ -test to gross errors. *IEEE PES General Meeting* (para ser publicado).
- Monticelli, A and Garcia, A. (1983). Reliable bad data processing for real-time state estimation. *IEEE Trans. Pow. App. Syst.*, vol. PAS-102, no. 5, pp. 1126-1139.
- Monticelli, A., Murari, C. A. F. and Wu, F. F. (1985). A hybrid state estimator: solving normal equations by orthogonal transformations. *IEEE Trans. Power Appar. Syst.*, vol. PAS-104, no. 12, pp. 3460-3468.
- Pau, M. et. Al. (2013). Efficient branch-current-cased distribution system state. *IEEE Trans Instr. Meas.*, vol. 62, no. 9.
- Primadianto, A. and Lu, C. A. (2017). A review on distribution system state estimation. *IEEE Trans. Power Systems*, vol. 32, no. 5.
- Quintana V.H., Costa A.S., Mier M. (1982). Bad Data Detection and Identification Techniques Using Estimation Orthogonal Methods. *IEEE Transactions on Power Systems*, vol. PAS101, no.9, p. 3356-3364.
- da Silva, R. S., Fernandes, T. R. and de Almeida, M. C., (2018). Specifying angular reference for three-phase distribution system state estimators. *IET Gener. Transm. Distrib.*, vol. 12, no. 7, pp. 1655-1663.
- Simoies-Costa, A. and Quintana, V. (1981). A robust numerical technique for power system state estimation. *IEEE Trans. Power Appar. Syst.*, vol. PAS-100, no. 2, pp. 691-698.
- Singh, R., Pal, B. C. and Vinter, R. B. (2009). Measurement placement in distribution system state estimation. *IEEE Trans. Power Syst.*, vol. 24, no. 2, pp. 668-675.