

Foi exemplar correspõe  
redação final da tese de doutoramento  
por Hélio Reimi Tanaka e aprovada  
pela comissão julgadora em  
21/11/85

PROCESSAMENTO DE ERROS GROSSEIROS  
NA ESTIMAÇÃO ESTÁTICA DE ESTADO  
EM SISTEMAS DE ENERGIA ELÉTRICA

115/85

UNIVERSIDADE ESTADUAL DE CAMPINAS  
FACULDADE DE ENGENHARIA DE CAMPINAS  
DEPARTAMENTO DE ENGENHARIA ELETRICA

PROCESSAMENTO DE ERROS GROSSEIROS  
NA ESTIMAÇÃO ESTÁTICA DE ESTADO  
EM SISTEMAS DE ENERGIA ELÉTRICA

MÁRCIA REIMI TANAKA

Orientador:

ARIOMALDO V. GARCIA

Tese apresentada à Faculdade de  
Engenharia/FEC/UNICAMP, como parte  
dos requisitos exigidos para  
obtenção do título de MESTRE EM  
ENGENHARIA ELÉTRICA.

Novembro/1985  
**UNICAMP**  
BIBLIOTECA CENTRAL

DEDICATÓRIA

A

MEUS PAIS  
RICARDO

## AGRADECIMENTOS

A Ariovaldo V. Garcia pela orientação,  
estímulo e paciência,

a Alcir J. Monticelli pelas sugestões e  
discussões,

aos colegas do Setor de Eletrotécnica pelo apoio e  
incentivo,

a Edna Pfeifer pela organização das referências  
bibliográficas,

desejo expressar meus agradecimentos.

## RESUMO

Neste trabalho é feita uma avaliação do desempenho de alguns métodos para processamento de erros grosseiros, quando aplicados juntamente com o Estimador de Estado Clássico (WLS) ou com o Estimador Desacoplado Rápido. Propõe -se uma nova maneira de se obter o limiar de decisão no teste da hipótese realizado no processamento de erros grosseiros pelos resíduos normalizados.

## ÍNDICE

página

### **Capítulo 1 - Introdução**

### **Capítulo 2 - Estimação Estática do Estado**

2.1 Introdução .....	2.1
2.2 Método dos Mínimos Quadrados Ponderados .....	2.3
2.2.1 Método Clássico .....	2.5
2.2.2 Estimador Desacoplado Rápido .....	2.8

### **Capítulo 3 - Processamento de Erros Grossos**

3.1 Introdução .....	3.1
3.2 Detecção e Identificação de Medidas com Erros Grossos	3.2
3.2.1 Análise linearizada .....	3.2
3.2.2 Método 1: Teste - $J(\underline{x})/\Gamma^N$ .....	3.7
3.2.3 Método 2: Teste - $\Gamma^N$ .....	3.11
3.2.4 Método 3: Teste - $\hat{b}$ .....	3.13

## **Capítulo 4 - Testes e Resultados**

4.1 Redes Utilizadas para os Testes .....	4.1
4.2 Definição dos Limiares .....	4.4
4.3 Testes Efetuados .....	4.5
4.3.1 Alarmes Falsos .....	4.5
4.3.2 Falhas de Detecção e Falhas de Identificação .....	4.8
4.4 Influência da Relação X/R .....	4.13
4.5 Conclusões .....	4.14

## **Capítulo 5 - Dedução dos Novos Valores de $\lambda$ para o Teste-**

5.1 Introdução .....	5.1
5.2 Revisão Estatística .....	5.1
5.2.1 Aplicação ao Teste - $\tau^N$ .....	5.4
5.3 Testes e Resultados .....	5.5
5.3.1 Validação do Método .....	5.5
5.3.2 Alarmes Falsos com o Novo $\lambda$ .....	5.7
5.3.3 Falhas de Detecção e Identificação com Novo $\lambda$ ..	5.8
5.4 Conclusões .....	5.8

## **Capítulo 6 - Conclusões**

## **Referências Bibliográficas**

## Capítulo 1 - Introdução

O objetivo de um estimador de estado é, partindo das medidas disponíveis, obter o estado mais provável do sistema, correspondente ao instante no qual foram realizadas as medidas. Geralmente o número de medidas é bem maior que o número mínimo necessário para a obtenção do estado, permitindo que o estado obtido via um processo de filtragem seja tal que os valores calculados para as grandezas medidas são mais confiáveis, inclusive, que os próprios valores medidos. Deste modo, o estimador fornece ao operador valores confiáveis para as variáveis necessárias ao controle e supervisão do sistema.

Durante o processo de aquisição de dados, as medidas podem ser afetadas por erros além dos considerados normais, chamados erros grosseiros. Esses erros afetarão os resultados do estimador, principalmente na região vizinha à medida perturbada, podendo invalidar o resultado da estimação.

É, portanto, importante detectar a presença desses erros. Além disso, as medidas afetadas devem ser identificadas e eliminadas (ou corrigidas).

Neste trabalho é feita uma avaliação do desempenho de alguns métodos para processamento de erros grosseiros, quando aplicados juntamente com o Estimador de Estado Clássico (WLS) ou com o Estimador Desacoplado Rápido (os métodos testados foram: Teste -  $J(\hat{x})/r^N$ , Teste -  $r^N$  e Teste -  $\hat{b}$ ). Propõem-se uma nova maneira de se obter o limiar para o teste -  $r^N$ .

No capítulo 2 é apresentado um resumo do problema de estimação estática de estado pelo Método dos Mínimos Quadrados

Ponderados, que é o mais utilizado em sistemas de energia elétrica. São apresentadas duas abordagens, bem conhecidas, o estimador clássico (ou completo) e o desacoplado rápido.

No capítulo 3 são apresentados os três métodos para detecção e identificação de erros grosseiros comparados neste trabalho.

No capítulo 4 são descritos os testes efetuados e os resultados obtidos são apresentados.

Com base nos resultados do capítulo 4 propõe-se no capítulo 5 uma nova maneira de se calcular o limiar para o teste -  $r^N$ .

No capítulo 6 estão as conclusões deste trabalho.

## Capítulo 2 - Estimação Estática de Estado

### 2.1 Introdução

O problema de estimação estática de estado em sistemas de energia elétrica pode ser resumido da maneira que segue:

- São realizadas medidas na rede elétrica, geralmente em número elevado. Estas medidas são: fluxos de potência ativa e reativa nas linhas de transmissão, magnitude de tensão nas barras e, ainda, fluxo de corrente nas linhas. Este último tipo de medida, na maioria dos casos, não é utilizado para a estimação do estado.
- Estas medidas efetuadas são enviadas a um centro de controle, via um complexo sistema que envolve a conversão analógica digital destas medidas no local onde ela é efetuada, sua transmissão, etc...
- Numa fase denominada pré-processamento, que tanto pode ser realizada no local de medição quanto no centro de controle, são inutilizadas medidas absurdas, se houverem. As medidas restantes são utilizadas pelo estimador de estado. Deve-se ressaltar que mesmo nas medidas restantes existe a possibilidade de que hajam erros grosseiros.
- O objetivo de um estimador de estado é, partindo das medidas disponíveis, obter o estado mais provável do sistema, correspondente ao instante no qual foram realizadas as medidas. Como geralmente o número de medidas é elevado (mesmo porque isto é um requisito necessário a um

centro de controle), tem-se bem mais medidas que o número mínimo necessário para a obtenção do estado. Isto permite que o estado obtido via um processo de filtragem seja tal que os valores calculados para as grandezas medidas são mais confiáveis, inclusive, que os próprios valores medidos.

- . A afirmação acima só vale quando tanto o modelo da rede elétrica quanto as medidas são "corretos". Quer dizer, se as medidas estiverem dentro de valores esperados, de acordo com a precisão dos aparelhos de medição, e se não existirem erros no modelo da rede (topologia, parâmetros).
- . Se, por outro lado, existirem erros "fora dos aceitáveis", ou seja, erros grosseiros, há a necessidade de serem identificados e as medidas correspondentes eliminadas para posterior obtenção do estado. Neste trabalho, por hipótese, o modelo da rede é determinístico, sem erros, grosseiros ou não.

\* Neste capítulo é apresentado, de maneira resumida, o estimador baseado no Método dos Mínimos Quadrados Ponderados, que é o mais utilizado em sistemas de energia elétrica para tal fim. São apresentadas duas abordagens, bem conhecidas, o estimador clássico (ou completo) e o desacoplado rápido.

## 2.2 Método dos Mínimos Quadrados Ponderados

Um algoritmo de estimação de estado fornece, a partir de um conjunto de medidas, o estado de um sistema de acordo com um critério pré-estabelecido.

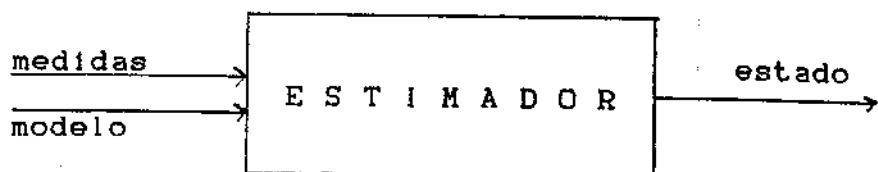


figura 2.1

O modelo escolhido para representar o sistema, neste trabalho, é determinístico, ou seja, por hipótese os parâmetros dos circuitos equivalentes das linhas e transformadores são supostos exatos; considera-se ainda que não há erros de topologia.

As medidas, o estado verdadeiro e os erros aleatórios estão relacionados através de equações não lineares que podem ser representadas por:

$$\underline{x}^m = \underline{h}(\underline{x}^v) + \underline{\omega} \quad (2.1)$$

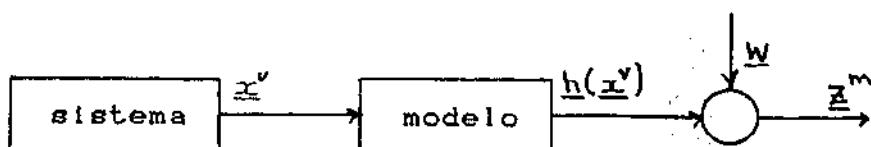


figura 2.2

onde:  $\underline{z}^m$  - vetor de medidas ( $m \times 1$ )  
 $\underline{h}(\cdot)$  - vetor de funções não lineares ( $m \times 1$ )  
 $\underline{x}^v$  - vetor de estado verdadeiro ( $n \times 1$ )  
 $\underline{w}$  - vetor de erros aleatórios nas medidas ( $m \times 1$ )  
 $m$  - número de medidas  
 $n$  - número de variáveis de estado

O vetor de erros aleatórios ( $\underline{w}$ ) é, por hipótese, composto de variáveis aleatórias independentes de média zero e variâncias conhecidas. Ou seja, a matriz covariância de  $\underline{w}$  que é conhecida, é suposta diagonal.

O vetor de estado  $\underline{x}$  é definido como:

$$\underline{x} \triangleq \begin{bmatrix} \underline{\theta} \\ \underline{V} \end{bmatrix} \quad (2.2)$$

onde:  $\underline{\theta}$  - ângulo das tensões das barras  
 (com exceção da referência angular)  
 $\underline{V}$  - magnitude das tensões das barras

O vetor de medidas pode ser colocado na forma:

$$\underline{z} = [F^T \mid P^T \mid S^T \mid Q^T \mid V^T] \quad (2.3)$$

onde:  $F_{kj}$  - fluxos de potência ativa da barra  $k$  para a barra  $j$   
 $P_k$  - injeção de potência ativa na barra  $k$   
 $S_{kj}$  - fluxos de potência reativa da barra  $k$  para a barra  $j$   
 $Q_k$  - injeção de potência reativa na barra  $k$   
 $V_k$  - magnitude de tensão na barra  $k$

### 2.2.1 Método Clássico

Pelo Método dos Mínimos Quadrados Ponderados [2] obtém-se uma estimativa do estado verdadeiro, denominada  $\hat{x}$ , que minimize uma função  $J(\underline{x})$  dada por:

$$J(\underline{x}) = \underline{w}^T W \underline{w} \quad (2.4)$$

onde  $W$  é uma matriz de ponderação. Para sistemas de energia elétrica a matriz  $W$ , na maioria dos casos, é igual à inversa da matriz covariância dos erros de medida:

$$W = [\text{cov}(\underline{w})]^{-1} \quad (2.5)$$

Sendo  $\underline{z}^m = \underline{h}(\underline{x}) + \underline{w}$ , pode-se escrever  $J(\underline{x})$  como função de  $\underline{x}$ :

$$J(\underline{x}) = [\underline{z}^m - \underline{h}(\underline{x})]^T W [\underline{z}^m - \underline{h}(\underline{x})] \quad (2.6)$$

A minimização de  $J(\underline{x})$  é obtida fazendo-se o gradiente de  $J(\underline{x})$  em relação a  $\underline{x}$  igual a zero. A solução  $\underline{x}$  é denominada  $\hat{x}$ .

$$\frac{\partial J(\underline{x})}{\partial \underline{x}} = 0$$

$$\frac{\partial J(\underline{x})}{\partial \underline{x}} = -2 H^T(\underline{x}) W [\underline{z}^m - \underline{h}(\underline{x})] = 0 \quad (2.7)$$

$$H^T(\underline{x}) W [\underline{z}^m - \underline{h}(\underline{x})] = 0 \quad (2.8)$$

onde:

$$H(\hat{x}) = \left. \frac{\partial h(x)}{\partial(x)} \right|_{x=\hat{x}} \quad (2.9)$$

e,  $\hat{x}$  é o estado estimado.

Minimizar  $J(x)$  passa a ser um problema de solução de um sistema de equações não lineares (2.8). Sendo  $H(x)$  e  $h(x)$  não lineares, utiliza-se um método iterativo para se obter  $\hat{x}$ .

Linearizando-se  $h(x)$  em torno de um ponto  $x^k$ , tem-se:

$$h(x) \approx h(x^k) + H(x^k) \cdot \Delta x^k$$

$$\hat{x}^m = h(x^k) + H(x^k) \cdot \Delta x^k + w$$

$$\text{Definindo } \Delta \hat{x}(x^k) = \hat{x}^m - h(x^k) \quad (2.10)$$

pode-se reescrever  $J(x)$  como:

$$J(x) = [\Delta \hat{x}(x^k) - H(x^k) \cdot \Delta x^k] W [\Delta \hat{x}(x^k) - H(x^k) \cdot \Delta x^k]$$

Minimizando-se  $J(x)$ , ou seja,  $\nabla_x J(x) = 0$ , chega-se a:

$$H^T(x^k) W \Delta \hat{x}(x^k) - H(x^k) \cdot \Delta x^k = 0 \quad (2.11)$$

$$\therefore \Delta x^k = [H^T(x^k) W H(x^k)]^{-1} H^T(x^k) W \Delta \hat{x}(x^k) \quad (2.12)$$

Definindo a matriz ganho como:

$$G(x^k) = H^T(x^k) W H(x^k) \quad (2.13)$$

tem-se:  $\Delta \underline{x}^k = G^{-1}(\underline{x}^k) H^T(\underline{x}^k) W \Delta \underline{z}(\underline{x}^k)$  (2.14)

e  $\underline{x}^{k+1} = \underline{x}^k + \Delta \underline{x}^k$  (2.15)

Esse processo é repetido, recalculando-se  $H(\underline{x}^k)$  a cada iteração ( $k$ ) até que o módulo da maior correção seja menor que uma tolerância pré-estabelecida, ou seja

$$|\Delta \underline{x}_{\max}^k| \leq \text{tolerância.}$$
 (2.16)

### Algoritmo para o Estimador de Estado Clássico

i) inicializar  $\underline{x}$ :  $\underline{x} = \underline{x}^0$  e  $k = 1$

ii) calcular  $h(\underline{x}^k)$ ,  $H(\underline{x}^k)$ ,  $\Delta \underline{x}^k$

iii) calcular  $G(\underline{x}^k)$  e inverter

iv) obter  $\Delta \underline{x}^k$  e atualizar o estado

v) teste de convergência:

- se  $|\Delta \underline{x}_{\max}| > \text{toler}$  não convergiu,  
 $k = k + 1$  e voltar ao passo ii

- se  $|\Delta \underline{x}_{\max}| \leq \text{toler}$  convergiu,  
fim do processo iterativo.

Não se conhecendo um valor razoável para  $\underline{x}^0$ , inicializa-se o algoritmo com todos os ângulos iguais a zero e todas as magnitudes de tensões iguais a 1 p.u. (ou então iguais aos valores medidos).

### 2.2.2 Estimador Desacoplado Rápido

Neste tópico é descrito, resumidamente, o Estimador Desacoplado Rápido.

As duas principais características dos estimadores desacoplados são o desacoplamento ativo/reactivo e o uso de matrizes ( $G$  e  $H$ ) constantes. Na obtenção do estimador desacoplado rápido [3],[4] realizam-se as mesmas aproximações efetuadas para se obter o Fluxo de Carga Desacoplado Rápido [10]. A aplicação do desacoplamento além de não afetar a precisão e confiabilidade do estimador, apresenta algoritmos mais simples, melhorando o desempenho computacional e reduzindo a memória utilizada.

Para o estimador desacoplado rápido, as medidas de fluxo ativo e reativo e as medidas de injeção ativa e reativa sofrem uma transformação visando uma melhora na linearização.

O vetor de medidas transformadas é dado por:

$$\underline{z}^m = \begin{bmatrix} \underline{T}^T \\ \underline{I}^T \\ \underline{U}^T \\ \underline{K}^T \\ \underline{E}^T \end{bmatrix} \quad (2.17)$$

onde:  $T_i = \frac{F_{ki}}{V_k}$        $U_i = \frac{S_{ki}}{V_k}$        $E_k = V_k$

 $I_i = \frac{P_k}{V_k}$        $K_i = \frac{Q_k}{V_k}$

Considerando este vetor, a matriz Jacobiana pode ser escrita como:

$$H(\underline{\theta}, \underline{V}) = \begin{bmatrix} H_{P\theta} & -H_{Q\theta} \\ H_{PV} & H_{QV} \end{bmatrix}$$

onde  $H_{P\theta}$  e  $H_{PV}$  correspondem ao Jacobiano das medidas ativas ( $\underline{I}$  e  $\underline{I}$ ) e,  $H_{Q\theta}$  e  $H_{QV}$  correspondem ao Jacobiano das medidas reativas e tensões ( $\underline{U}$ ,  $\underline{K}$  e  $\underline{E}$ ).

Para a maioria dos sistemas de transmissão, verifica-se que os elementos de  $H_{P\theta}$  e  $H_{QV}$  são bem maiores, em magnitude, que os elementos de  $H_{PV}$  e  $H_{Q\theta}$ . Isso indica que para esses sistemas há um acoplamento mais forte entre as medidas ativas e os ângulos de tensão das barras, e entre as medidas reativas e as magnitudes de tensão das barras. Essa característica é usada na obtenção do estimador desacoplado.

A fim de se obter o estimador desacoplado rápido, são introduzidas as seguintes aproximações:

- i) calculam-se os elementos de  $H$  com todos os ângulos iguais a zero e tensões iguais a 1 p.u.
- ii) são desprezadas as submatrizes  $H_{PV}$  e  $H_{Q\theta}$
- iii) no cálculo de  $H_{P\theta}$  não são consideradas as resistências das linhas.

Implementadas estas aproximações, as matrizes  $H$  e  $G$  são representadas por:

$$H = \begin{bmatrix} H_{\text{pe}} & | & 0 \\ \hline 0 & | & H_{\text{qv}} \end{bmatrix} \quad G = \begin{bmatrix} G_{11} & | & 0 \\ \hline 0 & | & G_{22} \end{bmatrix}$$

onde:

$$G_{11} = H_{\text{pe}}^T W_1 H_{\text{pe}} \quad (2.18)$$

$$G_{22} = H_{\text{qv}}^T W_2 H_{\text{qv}} \quad (2.19)$$

$W_1$  é a matriz de ponderação para as medidas de fluxo ativo e injeção de potência ativa e  $W_2$  é a matriz de ponderação para as medidas de fluxo reativo, injeção de potência reativa e tensões.

O estado é obtido pela seguinte recorrência:

$$\begin{array}{l} \text{Iteração - } \underline{\Theta} \\ \left[ \begin{array}{l} \Delta \underline{\Theta}^k = G_{11}^{-1} \cdot \Delta A(\underline{\Theta}^k, \underline{V}^k) \\ \underline{\Theta}^{k+1} = \underline{\Theta}^k + \Delta \underline{\Theta}^k \end{array} \right] \end{array} \quad (2.20)$$

$$\begin{array}{l} \text{Iteração - } \underline{V} \\ \left[ \begin{array}{l} \Delta \underline{V}^k = G_{22}^{-1} \cdot \Delta R(\underline{\Theta}^{k+1}, \underline{V}^k) \\ \underline{V}^{k+1} = \underline{V}^k + \Delta \underline{V}^k \end{array} \right] \end{array} \quad (2.21)$$

onde:

$$\Delta A = H_{\text{pe}}^T W_1 \begin{bmatrix} \Delta I(\underline{\Theta}^k, \underline{V}^k) \\ \Delta \underline{I}(\underline{\Theta}^k, \underline{V}^k) \end{bmatrix} \quad (2.22)$$

$$\Delta R = H_{\text{qv}}^T W_2 \begin{bmatrix} \Delta \underline{U}(\underline{\Theta}^{k+1}, \underline{V}^k) \\ \Delta \underline{K}(\underline{\Theta}^{k+1}, \underline{V}^k) \\ \Delta E(\underline{\Theta}^{k+1}, \underline{V}^k) \end{bmatrix} \quad (2.23)$$

O fato de não ser necessário calcular  $H_{P\Theta}$  e  $H_{QV}$  a cada iteração representa uma grande economia de tempo de CPU, lembrando porém que o resultado obtido é aproximado, já que a condição de optimalidade foi alterada. Para as tolerâncias normalmente exigidas nos sistemas de energia elétrica, as aproximações introduzidas são aceitáveis [3], [4].

## Capítulo 3 - Processamento de Erros Grosseiros

### 3.1 Introdução

Durante o processo de aquisição de dados, as medidas podem ser afetadas por outros erros além dos considerados normais e que foram representados no capítulo anterior por w. Diversos fatores podem provocar o aparecimento desses erros: falhas nos medidores, falhas nos transdutores, falhas na transmissão dos sinais, ou ainda, as medidas podem ter sido realizadas em instantes ou locais sujeitos a distúrbios temporários. Esses erros afetarão os resultados do estimador, principalmente na região vizinha à medida perturbada, podendo invalidar o resultado da estimação.

Uma vez detectada a presença desses erros (isto já é um problema a ser resolvido), as medidas afetadas devem ser identificadas e eliminadas (ou corrigidas).

O processamento de erros grosseiros, que envolve a detecção e a identificação de medidas com erros grosseiros, pode ser feito segundo dois procedimentos distintos que diferem quanto a maneira de serem detectadas e identificadas as medidas afetadas por erros grosseiros. Um deles no qual se encaixam os métodos estudados neste trabalho, envolve três fases distintas:

- estimar o estado
- processar os erros grosseiros
- reestimar o estado

No outro procedimento, os erros grosseiros são tratados durante o processo iterativo. Estes métodos não são abordados neste trabalho. Para maiores informações sobre estes métodos ver as referências [5],[6]. Quando, neste trabalho, se fizer referência ao processamento de erros grosseiros, trata-se do primeiro tipo, envolvendo as três fases.

A maioria dos algoritmos de processamento de erros grosseiros baseiam-se na análise estatística dos resíduos de estimação; por esta razão, apresenta-se a seguir uma análise estatística (análise linearizada) dos resultados do estimador.

Em sequência são descritos os três métodos que são comparados neste trabalho.

### **3.2 Detecção e Identificação de Medidas com Erros Grosseiros**

#### **3.2.1 Análise linearizada**

##### **a) Erro de estimação: $\Delta \underline{x}^v$**

Define-se erro de estimação como sendo a diferença entre o valor verdadeiro do estado ( $\underline{x}^v$ ) e o valor estimado do estado ( $\hat{\underline{x}}$ ).

$$\Delta \underline{x}^v = \underline{x}^v - \hat{\underline{x}} \quad (3.1)$$

Terminada a estimação,  $\hat{\underline{x}} \approx \underline{x}^v$ , ou seja,  $\Delta \underline{x}^v$  será não polarizado, pequeno, isto se os únicos erros presentes nas medidas forem os erros aleatórios. Sendo  $\Delta \underline{x}^v$  pequeno, pode-se

linearizar  $\underline{h}(\underline{x}^v)$  em torno do ponto  $\hat{\underline{x}}$ .

$$\underline{h}(\underline{x}^v) \cong \underline{h}(\hat{\underline{x}}) + H(\hat{\underline{x}}) \cdot \Delta \underline{x}^v \quad (3.2)$$

Lembrando que  $\underline{z}^m = \underline{h}(\underline{x}^v) + \underline{w}$  e substituindo-se (3.2) em (2.11), tem-se:

$$H^T(\hat{\underline{x}})W [H(\hat{\underline{x}}) \cdot \Delta \underline{x}^v + \underline{w}] = \underline{0} \quad (3.3)$$

$$\text{ou seja: } \Delta \underline{x}^v = -G^{-1}(\hat{\underline{x}})H^T(\hat{\underline{x}})W \underline{w} \quad (3.4)$$

Sendo  $\Delta \underline{x}^v$  e  $\underline{w}$  variáveis aleatórias e a matriz  $G^{-1}(\hat{\underline{x}})H^T(\hat{\underline{x}})W$  determinística (por hipótese), pode-se calcular o valor médio e a covariância de  $\Delta \underline{x}^v$ :

$$\Delta \underline{x}^v = -G^{-1}H^TW\underline{w} \quad (3.5)$$

mas, sendo o valor esperado de  $\underline{w}$ ,  $\bar{\underline{w}}$ , por hipótese igual a zero,  $\Delta \underline{x}^v$  tem média igual a zero e,

$$\text{cov}(\Delta \underline{x}^v) = G^{-1}H^TW\text{cov}(\underline{w})[G^{-1}H^TW]^T$$

mas  $\text{cov}(\underline{w}) = W^{-1}$  e a matriz ganho é simétrica, assim:

$$\text{cov}(\Delta \underline{x}^v) = G^{-1} \quad (3.6)$$

que corresponde ao inverso da matriz ganho calculada no ponto  $\hat{\underline{x}}$ .

b) Resíduo de estimação:  $\underline{r}$

O vetor resíduo de estimação é definido como a diferença entre o valor medido e o calculado com o estado estimado.

$$\underline{r} \triangleq \underline{z}^m - \underline{h}(\hat{\underline{x}}) \quad (3.7)$$

Substituindo-se (2.1) na equação (3.7):

$$\underline{r} = \underline{h}(\underline{x}^v) - \underline{h}(\hat{\underline{x}}) + \underline{w} \quad (3.8)$$

Considerando-se agora (3.2) e (3.4), a equação (3.8) pode ser reescrita como:

$$\underline{r} = H(\hat{\underline{x}}) \Delta \underline{x}^v + \underline{w} = - HG^{-1} H^T W \underline{w} + \underline{w}$$

$$\therefore \underline{r} = [\mathbb{I}_m - HG^{-1} H^T W] \underline{w} \triangleq \Gamma \underline{w} \quad (3.9)$$

onde  $\mathbb{I}_m$  é a matriz identidade de ordem  $m$  e  $\Gamma$ :

$$\Gamma \triangleq \mathbb{I}_m - HG^{-1} H^T W \quad (3.10)$$

Sendo  $\underline{r}$  e  $\underline{w}$  variáveis aleatórias e  $\Gamma$  determinística, tem-se:

$$\underline{r} = \Gamma \underline{w} = \underline{o} \quad (3.11)$$

$$\text{e, } \text{cov}(\underline{\Sigma}) \stackrel{\Delta}{=} R = \Gamma W^{-1} \Gamma^T \quad (3.12)$$

Após algumas manipulações chega-se a:

$$R = \Gamma W = W^{-1} - H G^{-1} H^T \quad (3.13)$$

c) Resíduo normalizado:  $\underline{\Gamma}^N$

Os elementos da diagonal da matriz  $R$  (3.13) são as variâncias do resíduo  $\Gamma_i$  correspondente. Dividindo-se cada resíduo  $\Gamma_i$  pelo seu desvio padrão tem-se:

$$\Gamma_i^N = \frac{\Gamma_i}{\sqrt{R_{ii}}} = \frac{\Gamma_i}{\rho_{ii}} \quad (3.14)$$

onde  $\rho_{ii}$  é o desvio padrão do resíduo  $\Gamma_i$ .

Usando outra notação, pode-se reescrever (3.14) como:

$$\underline{\Gamma}^N = [\text{diag}(R)]^{-\frac{1}{2}} \underline{\Gamma} \quad (3.15)$$

Pode-se verificar que os resíduos normalizados têm médias iguais a zero e variações unitárias:

$$\underline{\Gamma}^N = [\text{diag}(R)]^{-\frac{1}{2}} \underline{\Gamma} = 0 \quad (3.16)$$

$$\text{cov}(\underline{\Gamma}^N) = [\text{diag}(R)]^{-\frac{1}{2}} R [\text{diag}(R)]^{-\frac{1}{2}} \quad (3.17)$$

A partir da equação (3.17) pode-se deduzir que a diagonal de  $\text{Cov}(\underline{\Sigma}'')$  é unitária.

d) Índice de mínimos quadrados:  $J(\underline{\hat{x}})$

O índice  $J(\underline{\hat{x}})$  calculado para o estado estimado  $\underline{\hat{x}}$  é dado por:

$$J(\underline{\hat{x}}) = [\underline{z}^m - \underline{h}(\underline{\hat{x}})] W [\underline{z}^m - \underline{h}(\underline{\hat{x}})]^T \quad (3.18)$$

ou, em função do resíduo de estimação  $\underline{\Sigma}$ :

$$J(\underline{\hat{x}}) = \underline{\Sigma}^T W \underline{\Sigma} \quad (3.19)$$

ou, ainda, em função do erro aleatório  $\underline{w}$ :

$$J(\underline{\hat{x}}) \equiv \underline{w}^T W \Gamma \underline{w} \quad (3.20)$$

Se  $\underline{W}$  tiver distribuição normal,  $J(\underline{\hat{x}})$  terá distribuição qui-quadrado ( $\chi^2$ ) com um número de graus de liberdade igual ao posto da matriz  $W\Gamma$ , ou seja, igual à diferença entre o número de medidas e o número de variáveis a serem estimadas [2], [3].

### 3.2.2 Método 1: Teste - $J(\underline{x})/r^N$

#### a) Detecção de erros grosseiros

O teste  $J(\underline{x})$  é um teste estatístico que indica a existência ou não de erros grosseiros. É um teste de hipótese baseado nas propriedades estatísticas da variável aleatória  $J(\underline{x})$ .

No item anterior (3.2.1) foi visto que se só existirem medidas com erros aleatórios, o índice  $J(\underline{x})$  é uma variável aleatória com distribuição  $\chi^2$  com número de graus de liberdade igual à diferença entre o número de medidas e o número de variáveis a estimar ( $m-n$ ). Fixando-se a probabilidade de alarme falso, ou seja, a probabilidade de o teste indicar a existência de erros grosseiros quando na realidade eles não existem, obtém-se um parâmetro  $\lambda$  a partir da função de distribuição qui-quadrado. Quando  $m-n > 30$ , a distribuição aproxima-se de uma normal  $N(m-n, \sqrt{2(m-n)})$ . Nesse caso, o valor de  $\lambda$  para  $\alpha = 5\%$  pode ser calculado por:

$$\lambda = (m-n) + 1,65\sqrt{2(m-n)} \quad (3.21)$$

Assim, a detecção de medidas com erros grosseiros é feita calculando-se o índice  $J(\underline{x})$  após o fim do processo iterativo e testando-se a hipótese de não existirem erros grosseiros comparando o índice  $J(\underline{x})$  com o valor previamente calculado de  $\lambda$ :

- se  $J(\underline{x}) > \lambda$ , considera-se a hipótese falsa
- se  $J(\underline{x}) \leq \lambda$ , considera-se a hipótese verdadeira.

Caso não seja detectada a presença de erros grosseiros, considera-se que o processo de estimação terminou.

Se a hipótese de não existência de erros grosseiros é considerada falsa, é necessário identificar qual ou quais medidas estão afetadas por erros grosseiros, eliminá-las (ou seus efeitos) e reestimar o estado.

#### b) Identificação de medidas com erros grosseiros

A identificação de medidas com erros grosseiros, realizada após a detecção indicar a existência desses erros, pode ser feita de duas maneiras distintas: pelos resíduos ponderados (que são calculados dividindo-se cada resíduo  $r_i$  pelo desvio padrão da medida ( $s_i$ ) correspondente) ou pelos resíduos normalizados. Neste trabalho só foram considerados os resíduos normalizados, pois já foi mostrado em diversos trabalhos [1], [2] que estes apresentam um desempenho melhor.

O resíduo normalizado já foi definido e é calculado pela equação (3.15):

$$\underline{r}^N = \left[ \text{diag}(R)^{-\frac{1}{2}} \right] \underline{r}$$

Pode-se mostrar que se uma medida está perturbada por erros grosseiros, ela apresenta o maior resíduo normalizado. Esta demonstração encontra-se na referência [8] e é repetida a seguir.

Quando existirem erros grosseiros, pode-se escrever a equação (2.1) como:

$$\underline{z}^m = \underline{h}(\underline{x}^v) + \underline{w} + b_i \tilde{\gamma}_i \underline{e}_i \quad (3.22)$$

onde  $\underline{e}_i$  é um vetor nulo, exceto para a  $i$ -ésima componente, que é igual a unidade, e  $i$  é o índice da medida perturbada por erro grossoiro ( $b_i \tilde{\gamma}_i$ ) (nesta análise considera-se que apenas uma medida tem erros grosseiros).

A partir da equação (3.9), tem-se o resíduo  $\underline{r}$ :

$$\underline{r} = \Gamma (\underline{w} + b_i \tilde{\gamma}_i \underline{e}_i) \quad (3.23)$$

sendo  $\bar{w}=0$  e  $R=\Gamma W$ , calcula-se  $\bar{\underline{r}}$ , valor esperado de  $\underline{r}$ :

$$\underline{r} = \Gamma b_i \tilde{\gamma}_i \underline{e}_i = b_i \tilde{\gamma}_i^{-1} \underline{e}_i \quad (3.24)$$

logo, o valor esperado de  $\underline{r}^N$  é:

$$\underline{r}^N = [\text{diag}(R)]^{-\frac{1}{2}} \bar{\underline{r}} = b_i \tilde{\gamma}_i^{-1} \begin{bmatrix} \rho_{ii}^2 & \rho_{ii}^{-1} \\ \vdots & \vdots \\ \rho_{ii} & \rho_{ii} \\ \vdots & \vdots \\ \rho_{mi}^2 & \rho_{mm}^{-1} \end{bmatrix} \quad (3.25)$$

A relação entre o resíduo normalizado de uma medida qualquer e o resíduo normalizado de uma medida com erro grossoiro é:

$$\frac{|\underline{r}_i^N|}{|\underline{r}^N|} = \frac{|\rho_{ii}^2|}{|\rho_{ii}| |\rho_{ii}^{-1}|} = |\gamma_{di}| \quad (3.26)$$

onde  $\gamma_{ji}$  é a covariância (correlação) entre os resíduos das medidas  $j$  e  $i$ , e corresponde ao elemento  $_{ji} \gamma$  da matriz covariância dos resíduos normalizados dada pela equação (3.17). Pode-se mostrar [4] que  $|\gamma_{ji}| \leq 1$ .

Como a esperança de qualquer variável aleatória ao quadrado é sempre positiva, pode-se escrever que:

$$E\{[a(r_i - \bar{r}_i) - (r_j - \bar{r}_j)]^2\} \geq 0 \quad (3.27)$$

Considerando-se  $E\{(r_i - \bar{r}_i)^2\} = \rho_{ii}^2$ ,  $E\{(r_j - \bar{r}_j)^2\} = \rho_{jj}^2$

e  $E\{(r_i - \bar{r}_i)(r_j - \bar{r}_j)\} = \rho_{ij}^2$ , tem-se:

$$\alpha^2 \rho_{ii}^2 - 2\alpha \rho_{ij}^2 + \rho_{jj}^2 \geq 0 \quad (3.28)$$

esta equação do segundo grau na variável genérica  $\alpha$  é válida se e somente se o discriminante for menor ou igual a zero.

$$(2\rho_{ij}^2)^2 - 4\rho_{ii}^2 \rho_{jj}^2 \leq 0$$

$$\therefore \frac{\rho_{ij}^2}{\rho_{ii}^2 \rho_{jj}^2} \leq 1 \quad (3.29)$$

Das equações (3.29) e (3.26) chega-se a:

$$|r_j^N| \leq |r_i^N| \quad \text{para } j=1, \dots, m \quad (3.30)$$

Ou seja, o resíduo normalizado da medida com erros grosseiros é o maior (em valor absoluto).

Assim, o processo de identificação da medida afetada por erros grosseiros consiste em se determinar o maior resíduo normalizado em valor absoluto. Esse processo identifica uma medida de cada vez, isto porque erros grosseiros numa medida podem afetar outras medidas de modo a parecer que também estão perturbadas por erros grosseiros.

O procedimento consiste em identificar e eliminar uma medida e reestimar o estado. Se ainda houver medidas com erros grosseiros a detecção e identificação serão novamente realizadas, continuando desta forma até que todas as medidas com erros grosseiros sejam eliminadas.

Na figura 3.1 tem-se um diagrama de blocos resumido deste método.

### 3.2.3 Método 2: Teste - $\Gamma^N$

O teste do resíduo normalizado é um teste de hipótese baseado nas propriedades estatísticas da variável aleatória  $\Gamma^N$ .

Fixado o índice de alarme falso, ou seja, a probabilidade do teste indicar a existência de erros grosseiros quando na realidade eles não existem, calcula-se o valor de  $\lambda$  a partir da função de distribuição da variável aleatória.

No item 3.2.c foi definido o resíduo normalizado :  
 $\Gamma_i^N = \gamma_i / \rho_{ii}$ , verificou-se ainda que os resíduos normalizados tem média zero e variância unitária. Ou seja, a variável aleatória  $\Gamma^N$  tem distribuição normal unitária  $N(0,1)$ , que pode servir de base para a escolha do parâmetro  $\lambda$ .

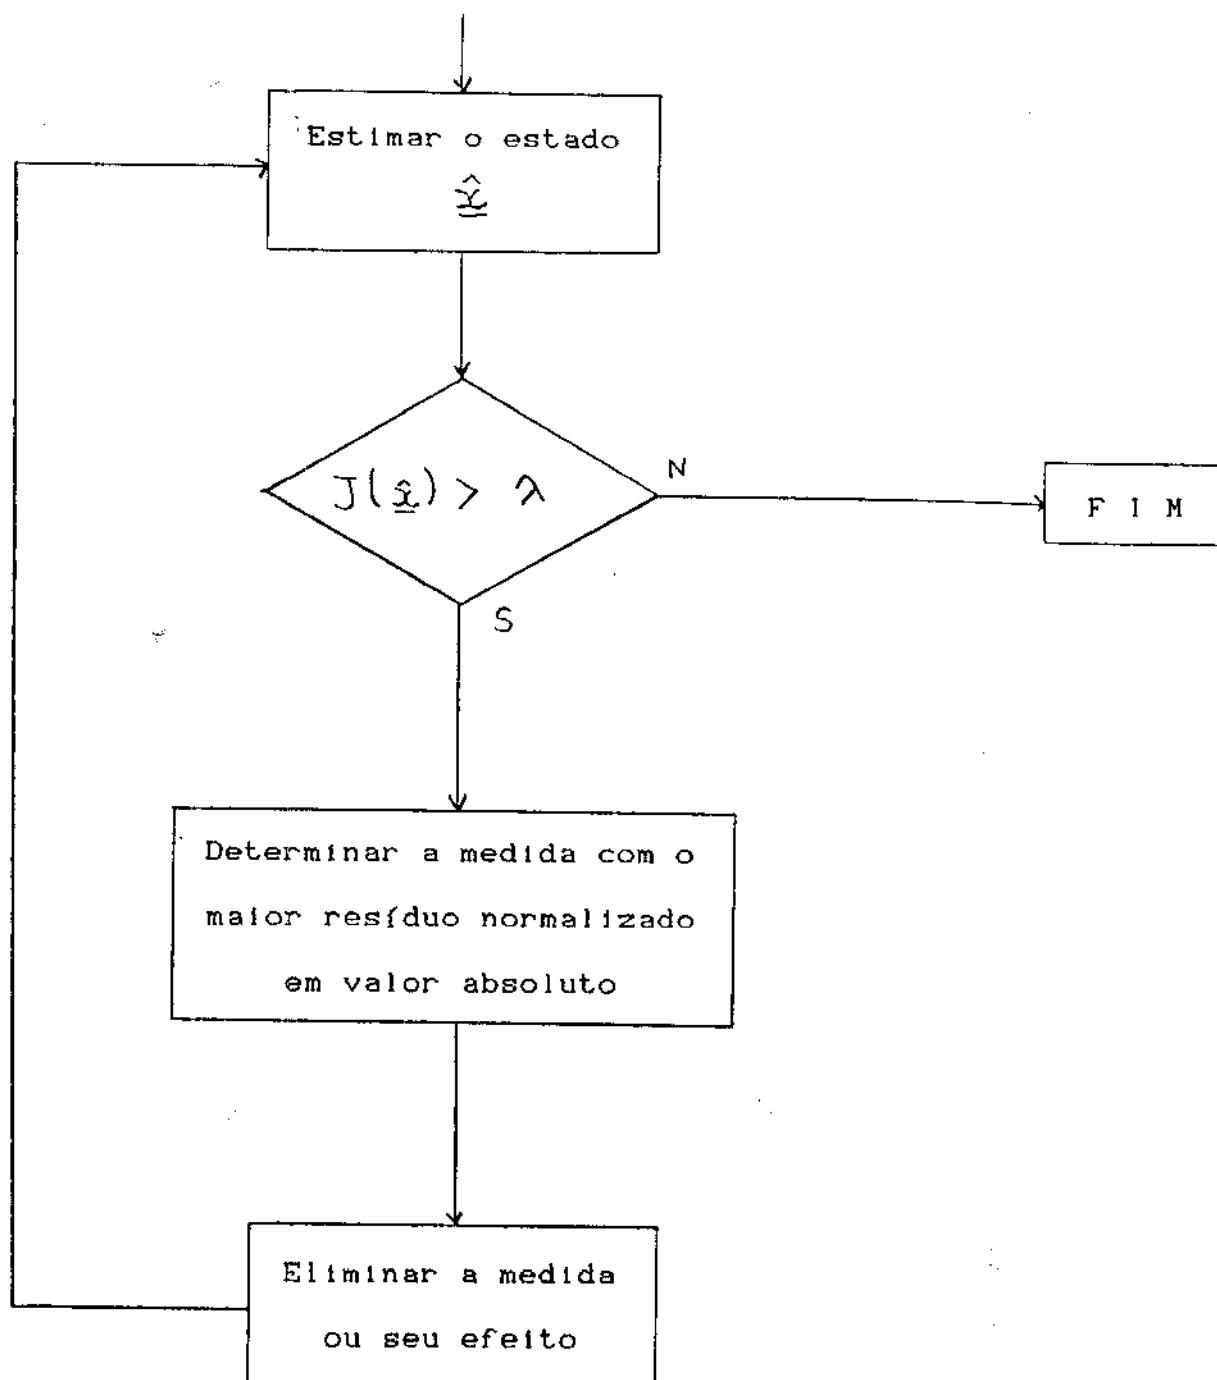


Figura 3.1 - Diagrama de blocos simplificado do algoritmo para o método 1: Teste -  $J(\hat{x})/r^N$

A detecção e identificação são feitas determinando-se a medida que possui o maior resíduo normalizado e testando se o resíduo pode ou não ser considerado uma variável com distribuição normal unitária comparando-o com o parâmetro pré-calculado.

- se  $|\Gamma_{\text{máx}}^N| > \lambda$  a hipótese de não existência de erros grosseiros é considerada falsa
- se  $|\Gamma_{\text{máx}}^N| \leq \lambda$  a hipótese é considerada verdadeira.

O diagrama de blocos resumido deste teste está na figura 3.2.

#### 3.2.4 Método 3: Teste - $\hat{b}$

A idéia básica desse método [7],[8] é comparar o valor medido  $\underline{z}^m$ , da variável que se suspeita estar afetada por erros grosseiros, com seu valor estimado, obtido usando-se um novo conjunto de medidas, no qual a medida  $\underline{z}_i$  é ignorada. A avaliação do valor estimado é feita através da Análise de Sensibilidade [3],[8].

##### a) Análise de Sensibilidade

Analisa-se a seguir como os vetores  $\hat{\underline{x}}$  e  $\underline{\Sigma}$  são sensíveis a perturbações no vetor de medidas  $\Delta \underline{z}$ .

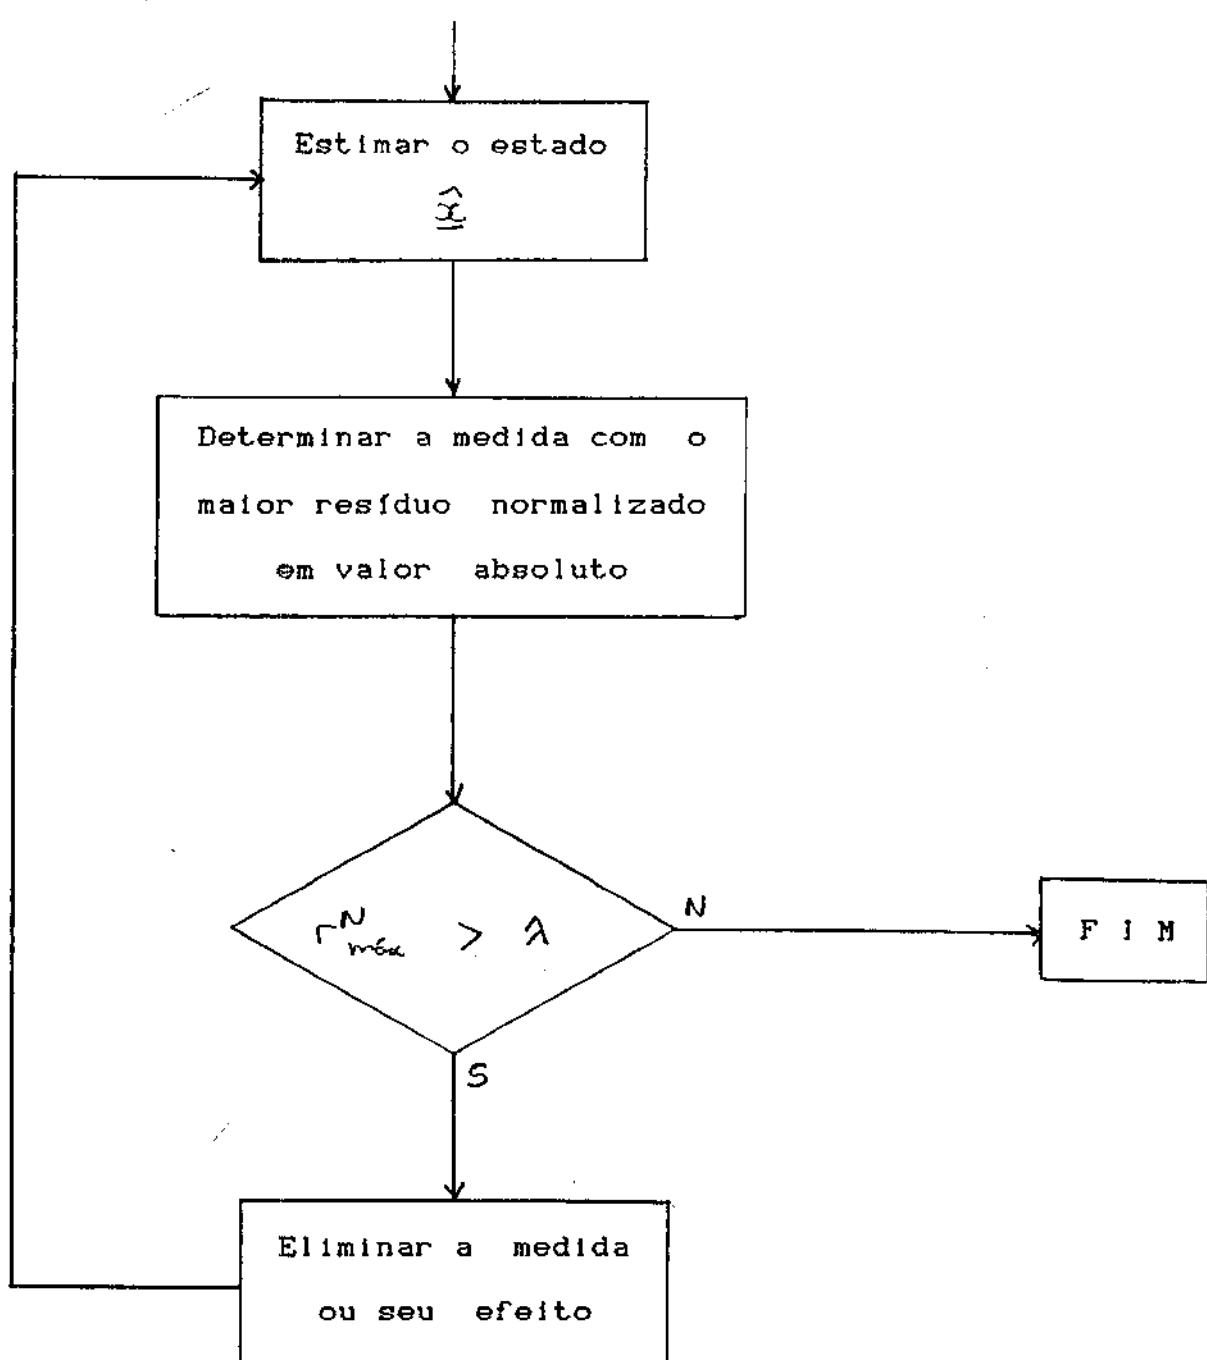


Figura 3.2 - Diagrama de blocos simplificado do algoritmo para o método 2: Teste -  $r^N$

- matriz de sensibilidade:  $\frac{\partial \hat{x}}{\partial z}$

Deseja-se calcular o efeito ( $\Delta \hat{x}$ ) no vetor de estado estimado  $\hat{x}$  resultante de uma perturbação  $\Delta z$  introduzida no vetor de medidas.

Para  $\underline{x} = \hat{x}$ , tem-se:

$$H^T(\hat{x}) = W [z^m - h(\hat{x})] = 0 \quad (3.31)$$

e, após uma perturbação  $\Delta z$  nas medidas:

$$H^T(\hat{x} + \Delta \hat{x}) W [z^m + \Delta z - h(\hat{x} + \Delta \hat{x})] = 0 \quad (3.32)$$

Supondo que a perturbação  $\Delta z$  seja pequena, pode-se introduzir as mesmas aproximações feitas na Análise Linearizada (item 3.1).

$$h(\hat{x} + \Delta \hat{x}) \approx h(\hat{x}) + H(\hat{x}) \cdot \Delta \hat{x}$$

$$H(\hat{x} + \Delta \hat{x}) \approx H(\hat{x})$$

A equação (3.32) pode então ser reescrita como:

$$H^T(\hat{x}) W [A z - H(\hat{x}) \cdot \Delta \hat{x}] = 0 \quad (3.33)$$

ou:  $\Delta \hat{x} = G^{-1}(\hat{x}) H^T(\hat{x}) W \Delta z \quad (3.34)$

e, portanto:  $\frac{\partial \hat{x}}{\partial z} = G^{-1}(\hat{x}) H^T(\hat{x}) W \quad (3.35)$

- matriz de sensibilidade:  $\frac{\partial \underline{\Sigma}}{\partial \underline{Z}}$

No ponto perturbado o vetor de resíduos passará a ser igual a:

$$\underline{\Sigma}^{\text{novo}} = \underline{\Sigma} + \Delta \underline{\Sigma} = \underline{z}^m + \Delta \underline{z} - h(\hat{\underline{z}} + \Delta \hat{\underline{z}}) \quad (3.36)$$

onde:  $\Delta \underline{\Sigma} = \Delta \underline{z} - H(\hat{\underline{z}}) \cdot \Delta \hat{\underline{z}}$  (3.37)

Substituindo-se a equação (3.34) em (3.37), chega-se a:

$$\Delta \underline{\Sigma} = [\mathbb{I}_m - H G^{-1} H^T W] \Delta \underline{z} = R W^T \Delta \underline{z} \quad (3.38)$$

portanto:  $\frac{\partial \underline{\Sigma}}{\partial \underline{z}} = R W$  (3.39)

### b) Avaliação do erro numa medida

Sejam as seguintes variáveis:

$\underline{z}_\lambda^m$  - valor medido da variável  $\lambda$

$\hat{\underline{z}}_\lambda$  - valor estimado da variável  $\lambda$ ,  
considerando-se todas as medidas

$\tilde{\underline{z}}_\lambda$  - valor estimado da variável  $\lambda$ ,  
considerando-se todas as medidas  
exceto  $\underline{z}_\lambda$

$\lambda$  - variável que apresenta o maior resíduo  
normalizado

Calcula-se  $\hat{z}_i$  a partir do estado estimado  $\hat{x}$ :

$$\hat{z}_i = h(\hat{x}) \quad (3.40)$$

e  $\tilde{z}_i$  pode ser calculado a partir da análise do efeito de perturbações no vetor de medidas no resíduo de estimação.

Seja  $\Delta z_i$  uma perturbação na medida tal que:

$$\tilde{z}_i^{\text{novo}} = z_i^m + \Delta z_i \quad (3.41)$$

O novo resíduo da medida  $i$  será:

$$r_i^{\text{novo}} = r_i + \Delta r_i \quad (3.42)$$

Sendo  $\Delta z_j = 0$  para  $j \neq i$ , obtém-se a partir da equação (3.38) a relação entre  $\Delta r_i$  e  $\Delta z_i$ :

$$\Delta r_i = \frac{\rho_{ii}^2}{\sigma_i^2} \cdot \Delta z_i \quad (3.43)$$

Deseja-se que a alteração  $\Delta z_i$  seja tal que o novo resíduo seja igual a zero ( $r_i^{\text{novo}} = 0$ ), ou seja:

$$z_i^{\text{novo}} = \tilde{z}_i \quad \text{e} \quad \Delta r_i = -r_i$$

portanto, a partir de (3.43), tem-se:

$$\Delta z_i = -\frac{\sigma_i^2}{\rho_{ii}^2} \cdot r_i \quad (3.44)$$

$\tilde{z}_i$  será então dado por:

$$\tilde{z}_i = z_i^m - \frac{\sigma_i^2}{\rho_{ii}^2} \cdot r_i \quad (3.45)$$

Se todas as medidas são exatas, a menos de  $z_i^m$ , afetada por um erro grosso (b<sub>i</sub> r<sub>i</sub>), a estimativa  $\tilde{z}_i$  corresponderá ao valor verdadeiro da medida i.

$$b_i r_i = z_i^m - \tilde{z}_i = z_i^m - z_i^v = \frac{\sigma_i^2}{\rho_{ii}^2} \cdot r_i \quad (3.46)$$

A magnitude do erro grosso, em número de desvios padrões, será:

$$b_i = \frac{r_i}{\rho_{ii}} \tau_i^N \quad (3.47)$$

Se além do erro grosso forem considerados erros aleatórios de média zero (w), a expressão 3.47 corresponderá ao valor esperado de b<sub>i</sub>.

O processamento de erros grosseiros, por este método, consiste em avaliar os resíduos normalizados de todas as medidas, determinar a medida correspondente ao maior resíduo normalizado (em valor absoluto), estimar o erro grosso da medida e, em seguida testar a hipótese de existência de erros grosseiros:

\* - se  $|\hat{b}_i| > \lambda$  a hipótese de não existência de erros grosseiros é falsa

- se  $|\hat{b}_i| \leq \lambda$  a hipótese é verdadeira.

UNICAMP

BIBLIOTECA CENTRAL

O diagrama de blocos simplificado deste método está na figura 3.3.

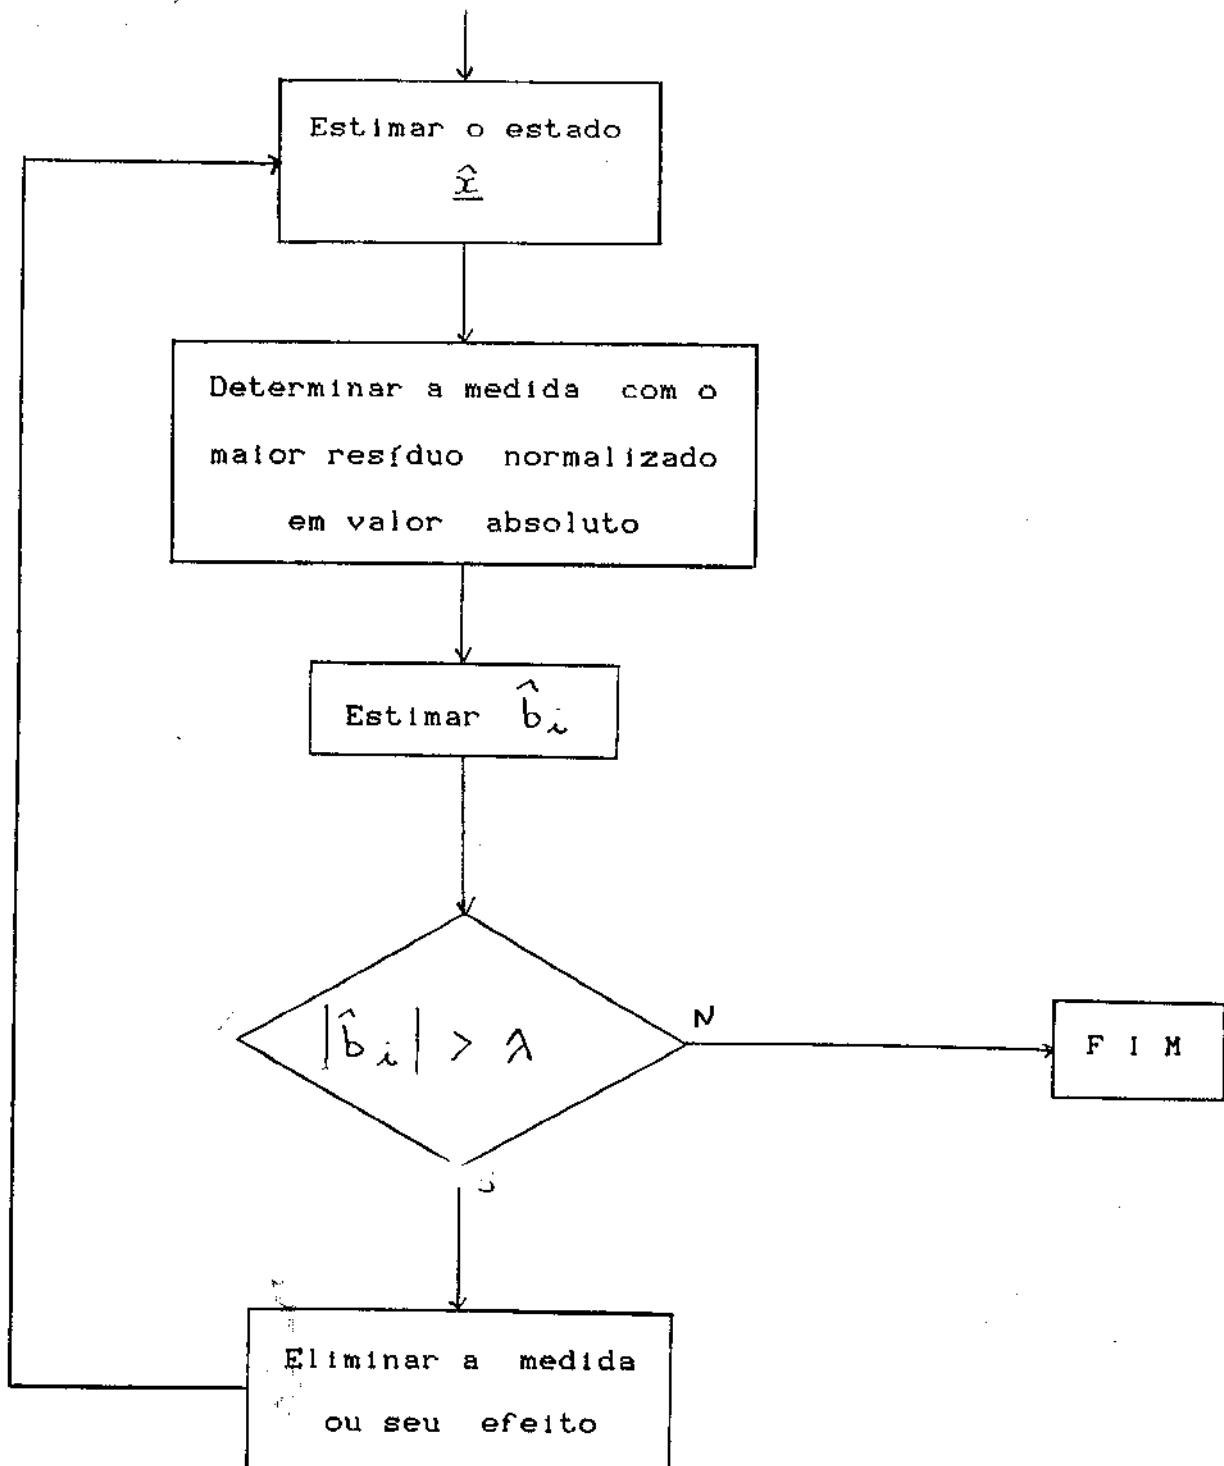


Figura 3.3 - Diagrama de blocos simplificado do algoritmo para o método 3: Teste -  $\hat{b}$

A seguir, no capítulo 4, são apresentados testes com os tres métods descritos aplicados com o estimador desacoplado e com o estimador clássico.

## Capítulo 4 - Testes e Resultados

### 4.1 Redes Utilizadas para os Testes

Para comparar os desempenhos dos métodos apresentados anteriormente, foram utilizadas as redes: IEEE30 e Furnas66.

IEEE30 - rede com 30 barras e 42 linhas (figura 4.1)

Furnas66 - rede com 66 barras e 94 linhas (figura 4.2)

O conjunto de medidas é formado por medidas de fluxo de potência ativa e reativa em todas as linhas, em ambos os extremos da linha (2 medidas de fluxo ativo e duas de fluxo reativo), injeção de potência ativa e reativa em barras de injeção nula e tensões em todas as barras.

IEEE30 - total de 210 medidas, com medidas de injeção nas barras 6,9,22,25,27,28

Furnas66 - total de 460 medidas, com medidas de injeção nas barras 113,117,118,119,120,122,131,140,142

Nas simulações as medidas são geradas a partir dos resultados do fluxo de carga (fluxo de potência). Estes resultados são supostos exatos (valores verdadeiros) e, para a geração do conjunto de medidas, somam-se aos valores verdadeiros erros aleatórios de distribuição normal, com médias iguais a zero e variações conhecidas ( $\sigma^2$ ). Neste trabalho foram utilizados os

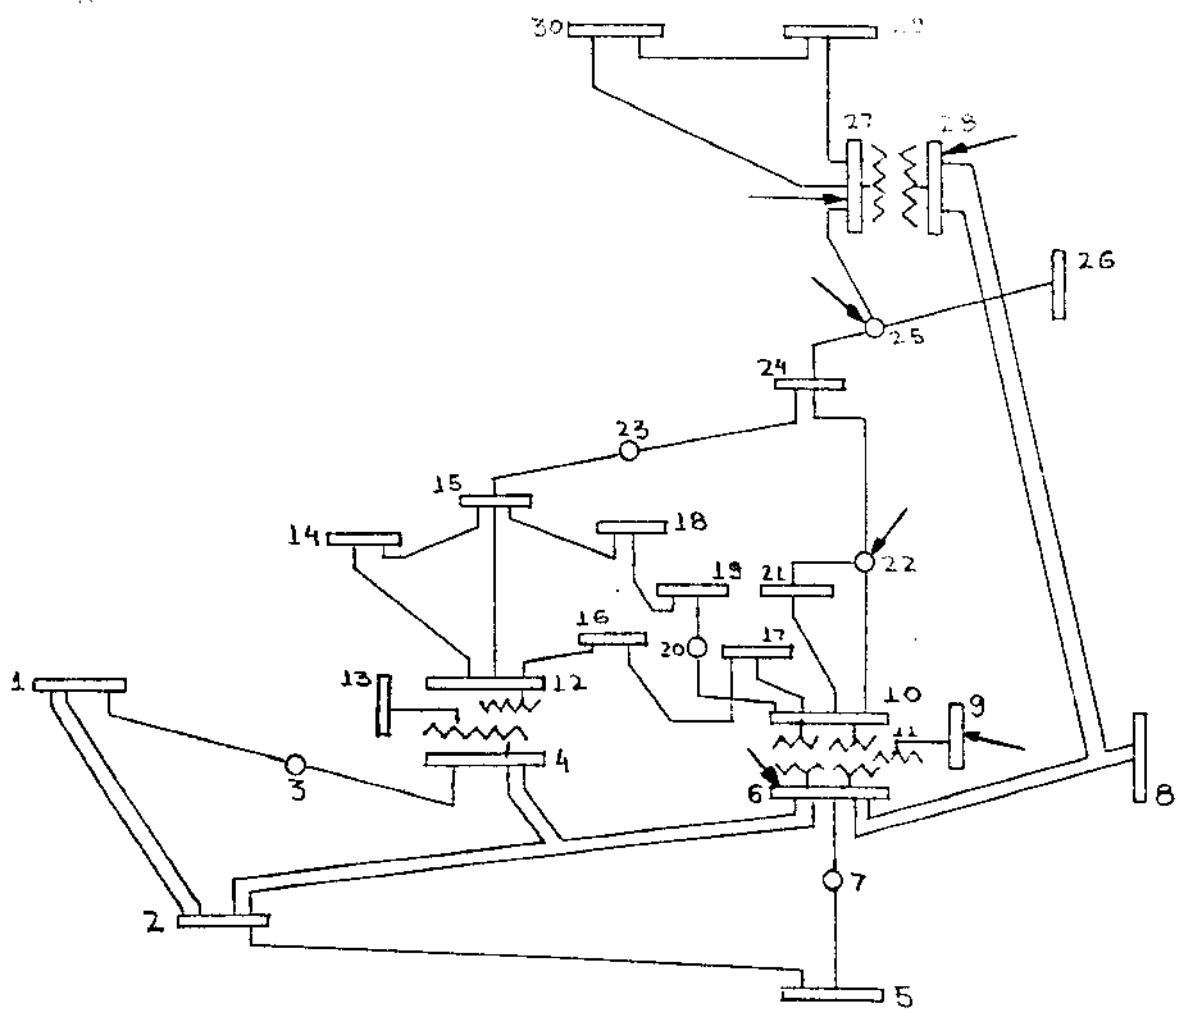


Figura 4.1 - Rede IEEE30

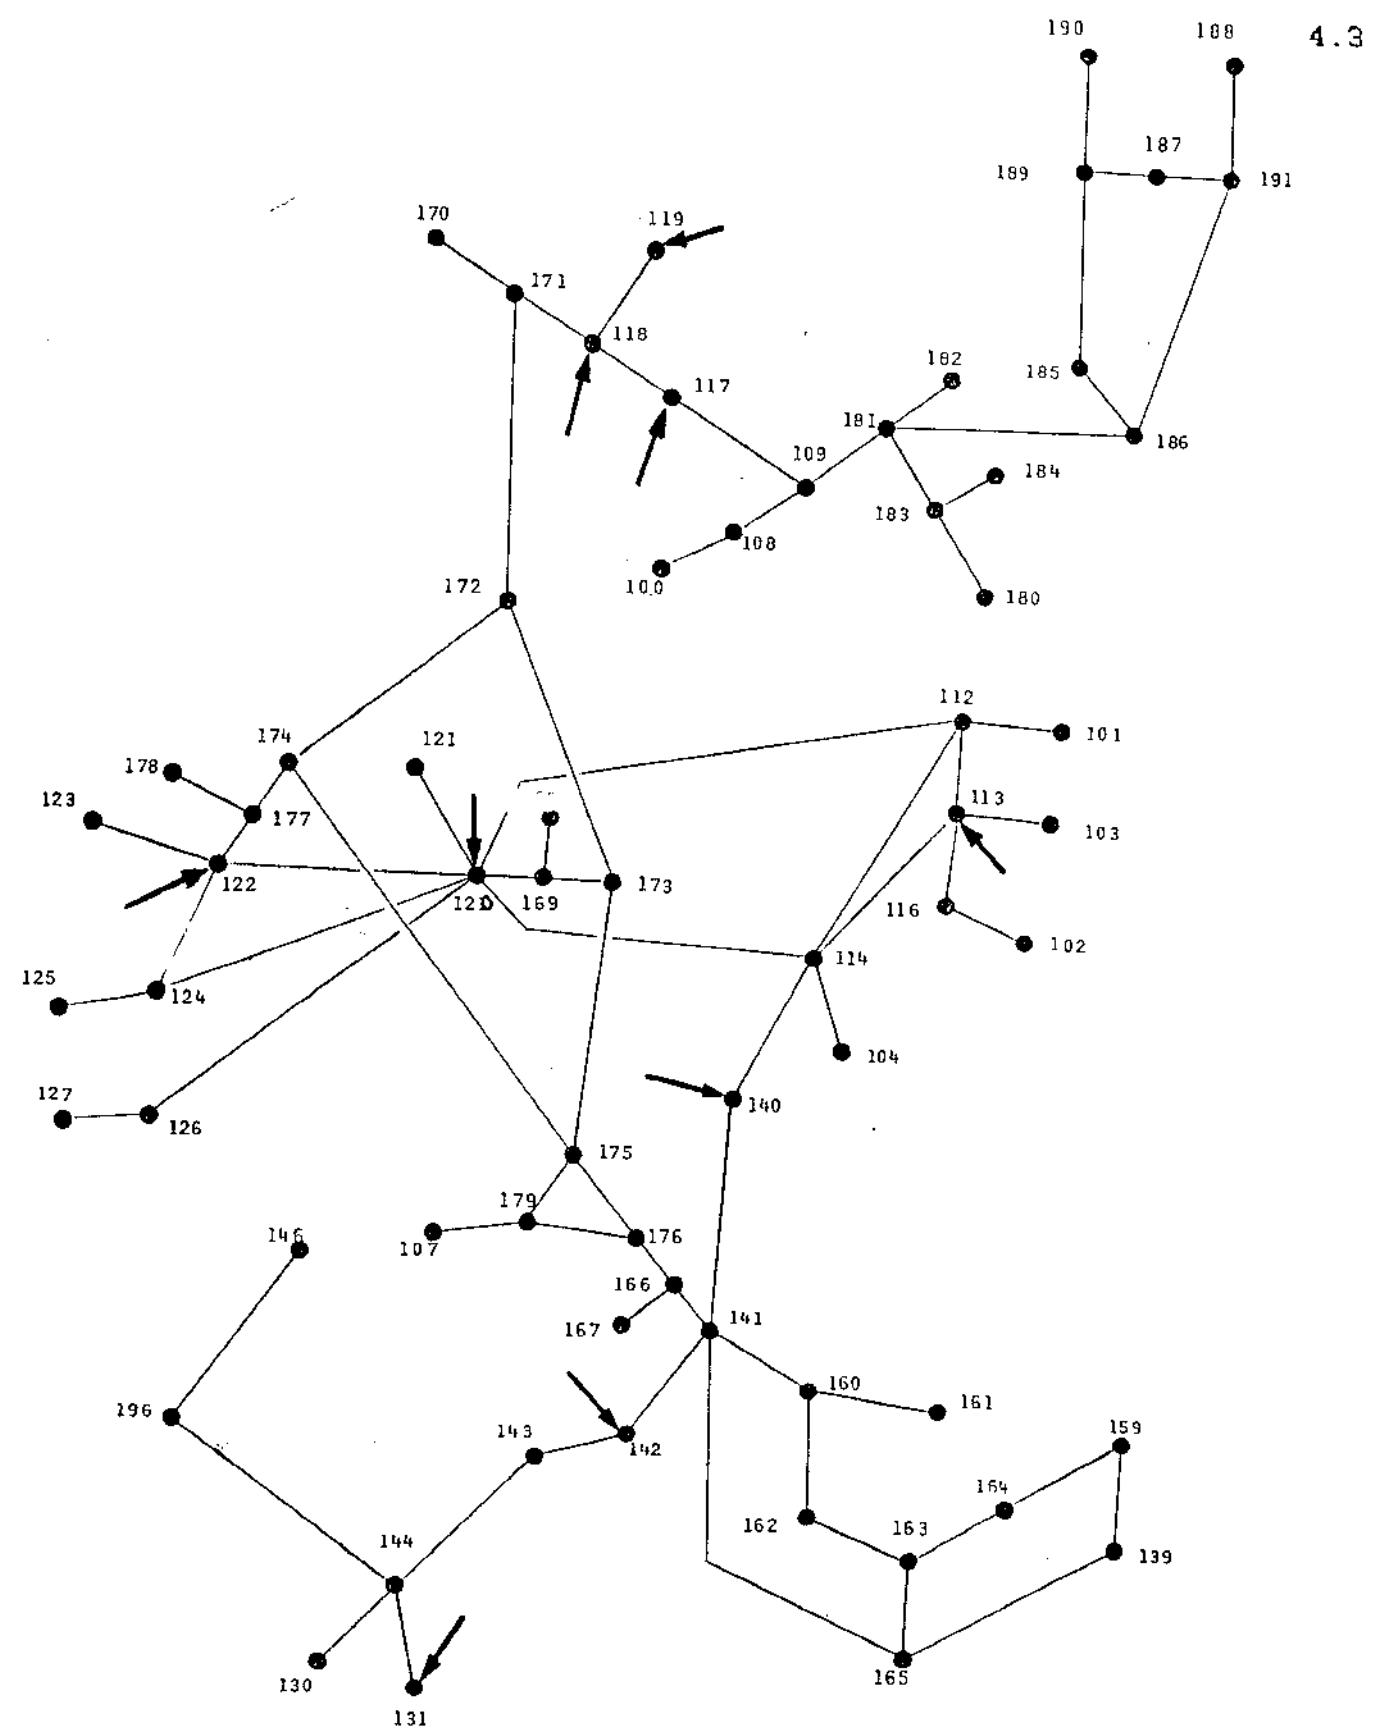


Figura 4.2 - Rede Furnas66

valores  $\bar{V} = \frac{1}{3}0$  p.u. para as medidas de potência ativa e reativa e, ainda,  $\bar{V} = \frac{1}{3}00$  p.u. para as medidas de magnitude de tensão.

#### 4.2 Definição dos Límites

O limiar para a variável aleatória  $J(\hat{x})$  é definido a partir da sua curva de distribuição. Na maioria das vezes, tem-se sistemas com mais de 30 graus de liberdade. Nestes casos, a distribuição da variável  $J(\hat{x})$  é aproximadamente a normal de mesma média e variância. O limiar para o teste  $-J(\hat{x})$  é calculado pela expressão:

$$\lambda = (m-n) + k \sqrt{\chi^2_{\alpha}(m-n)} \quad (4.1)$$

onde os valores  $k$  são obtidos da tabela  $N(0,1)$  para valores de probabilidade de alarmes falsos definidos.

Para o teste  $-r^N$  foram utilizados dois limiares: um a partir da curva de distribuição  $N(0,1)$  (diversos autores propõe o teste  $-r^N$  desta maneira [1],[2],[3]) para uma probabilidade de 5% de que o resíduo da medida seja maior que o limiar ( $\lambda=1,96$ ) e o outro obtido como sugerido na referência [8] (Na realidade, a definição do limiar resulta num método distinto). Para obter este último limiar, simularam-se 500 casos somente com erros aleatórios, sendo que para cada caso foi utilizado um conjunto de erros aleatórios diferente na geração do conjunto de medidas. Em cada caso foi determinada a medida com o maior resíduo normalizado e, a partir destes resultados foi traçada a curva de distribuição para o módulo do maior resíduo

(figura 4.3). Na curva de distribuição foi obtido o valor de  $\lambda$  para  $r^N$ ,  $\lambda = 3,55$ .

Para a definição do limiar para o teste -  $\hat{b}$ , foram utilizados os dados obtidos para o teste -  $r^N$ . Para cada resíduo normalizado, foi calculado seu  $\hat{b}_i$  correspondente. Com estes valores foi traçada a curva de distribuição para a variável  $\hat{b}$  (figura 4.4). A partir desta curva obteve-se o valor de  $\lambda$  para  $\hat{b}$ ,  $\lambda = 4,6$ .

#### 4.3 Testes Efetuados

##### 4.3.1 Alarmes Falsos

O teste de alarmes falsos pode ser interpretado de duas maneiras diferentes. Numa, analisa-se cada medida individualmente; neste caso, o número de alarmes falsos será igual ao número de medidas cujos  $r_i^N$  são maiores que  $\lambda$ , em cada simulação. Ou então, pode-se analisar as medidas em conjunto, neste caso o número de alarmes falsos será igual ao número de vezes que o teste indica a presença de erros grosseiros em pelo menos uma medida, quando na realidade eles não existem. Esta é uma linha semelhante à do teste  $J(\hat{x})$ . Neste trabalho, é adotada esta segunda maneira de interpretar o teste de alarmes falsos.

Para este teste foram simulados 500 casos com diferentes conjuntos de medidas. Estas medidas estavam perturbadas apenas por erros aleatórios. Estas simulações foram rodadas com o estimador desacoplado rápido, que foi utilizado na

referência [3,5] e com o estimador clássico, desenvolvido especialmente para este trabalho.

Na tabela 4.1 estão os resultados deste teste. O teste de alarmes falsos não precisa ser realizado para os testes e , quando os limiares são obtidos conforme a referência [8], pois estes devem apresentar aproximadamente 5% de alarmes falsos, uma vez que estes limiares foram obtidos a partir dos resultados sem erros grosseiros.

-----  alarmes falsos  -----				
rede	estimador	J( )	RN(*)	
AEP30	W L S	30	500	
AEP30	W L S	47	500	
FURNAS	D E S	30	500	

Tabela 4.1 - Número de alarmes falsos para 500 casos rodados.  
 (\*) - convencional ( $\lambda = 1,96$ )

O limiar  $\lambda = 1,96$  é usado se o objetivo é analisar as medidas individualmente, mesmo sabendo que em todas as simulações aproximadamente 5% das medidas terão resíduos normalizados maiores que 1,96. Na tabela 4.1, pode-se notar que para todos os casos, o teste de alarmes falsos , conforme interpretado neste trabalho, com  $\lambda = 1,96$  indicou a presença de erros grosseiros quando só existiam erros aleatórios, o que é um resultado previsto.

Se o objetivo é analisar as medidas em conjunto, deve-se usar um outro limiar, proposto na referência [8]. Neste trabalho, no Capítulo 5, é apresentada uma justificativa técnica para este limiar para o teste -  $\Gamma^N$ .

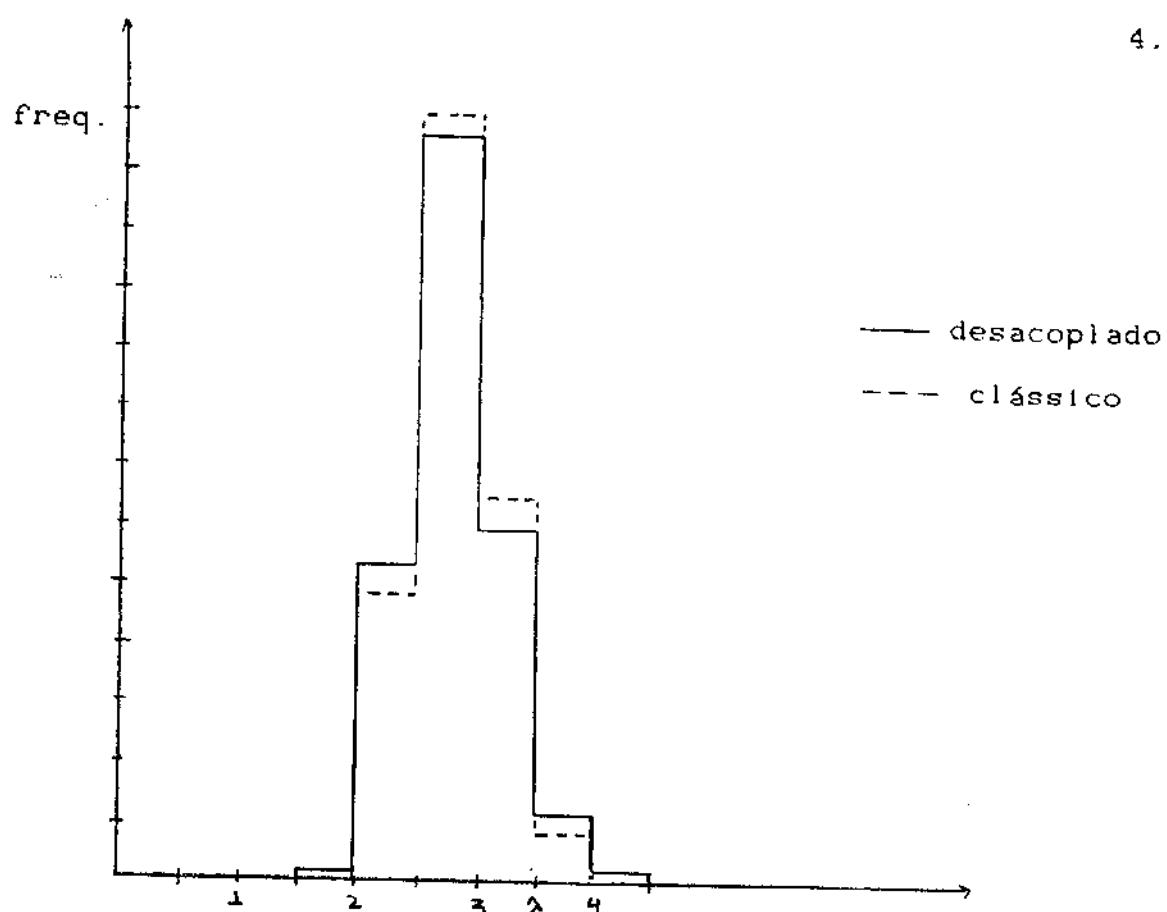


Figura 4.3 - Histograma para determinação de  $\lambda$  para a variável  $c^N$

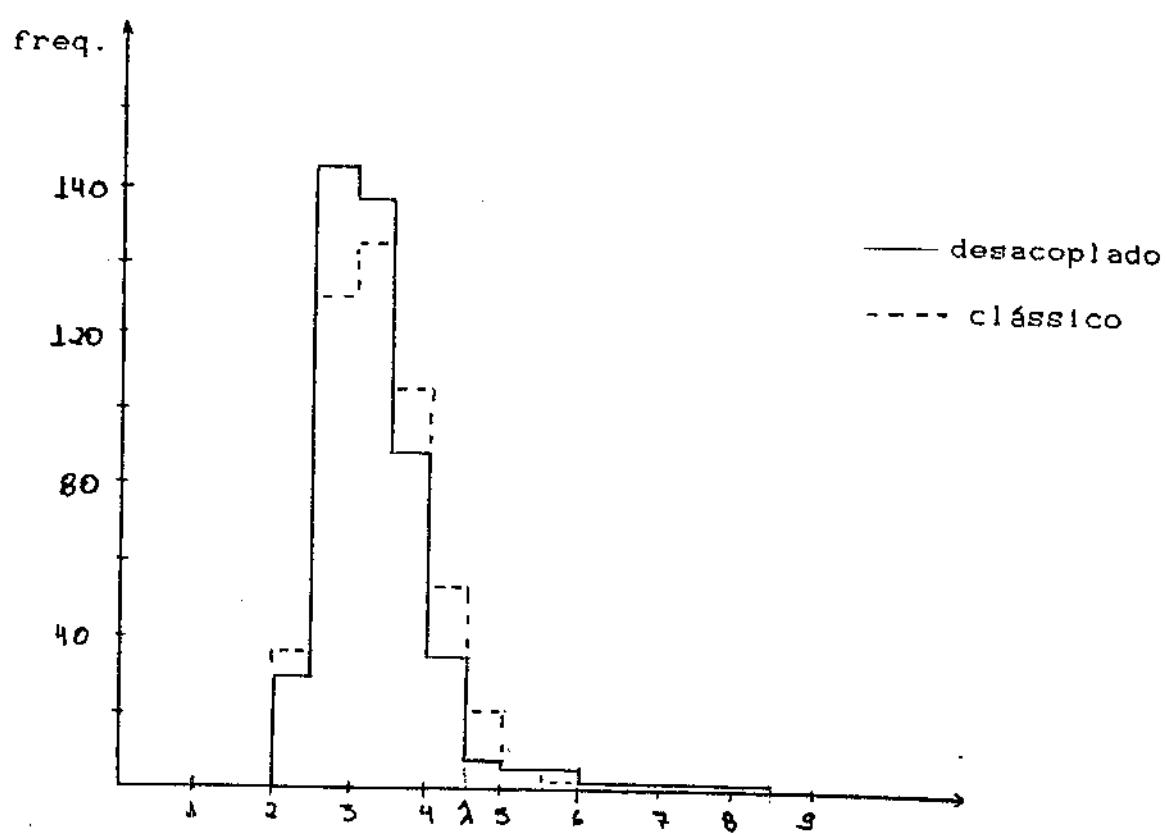


Figura 4.4 - Histograma para determinação de  $\lambda$  para a variável  $\hat{b}$

#### 4.3.2 Falhas de Detecção e Falhas de Identificação

Os métodos precisam também ser avaliados com relação a falhas de detecção e a falhas de identificação. Por falha de detecção, neste trabalho, entenda-se o caso em que existem medidas com erros grosseiros e o método não consegue detectá-las. Por falhas de identificação, entendam-se casos em que há a detecção, mas a medida indicada não é a portadora de erros grosseiros.

Para este teste, foram introduzidos erros grosseiros de magnitude variável em medidas de todos os tipos. Procurou-se, ainda, localizar os erros grosseiros tanto em locais de alta e baixa redundância como, ainda, de alta e baixa tensão.

Em cada caso, apenas uma medida era portadora de erro grosso. Cada situação foi simulada 200 vezes para diferentes conjuntos de erros aleatórios. Os diferentes casos foram simulados com o estimador desacoplado rápido e com o estimador clássico.

No diagrama da figura 4.5 mostra-se de forma simplificada o procedimento utilizado para testar os métodos para processamento de erros grosseiros. E, na tabela 4.2, estão alguns dos resultados das diversas simulações.

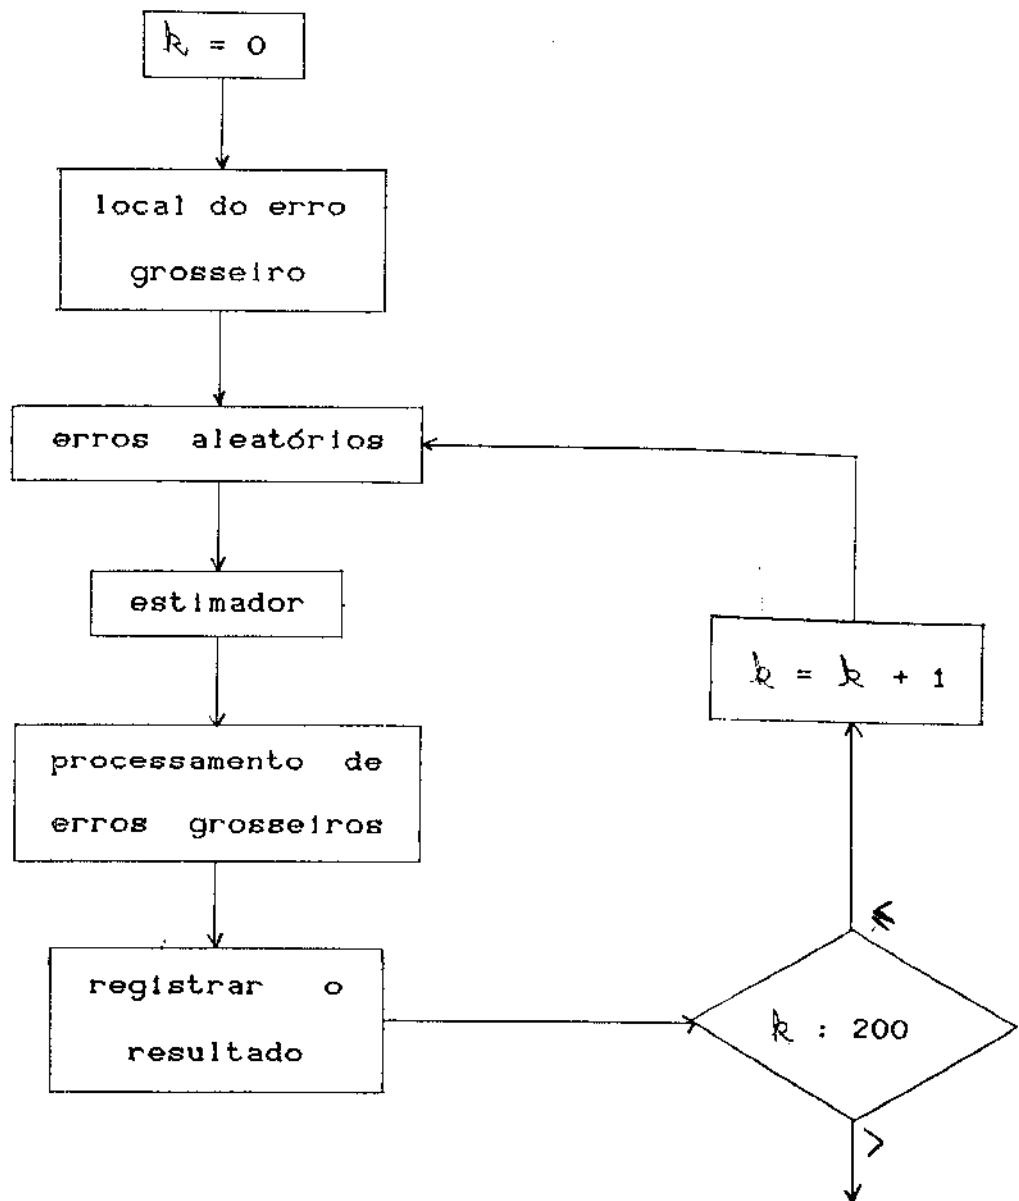


figura 4.9 - Diagrama de blocos simplificado do procedimento utilizado para testar os métodos para processamento de erros grosseiros.

## Legenda da tabela 4.2:

- Teste  $J(\hat{x})/RN$  - teste -  $J(\hat{x})/r^N$  com limiar  $\lambda = 179,164$
- Teste RN(3,55) - teste -  $r^N$  com limiar  $\lambda = 3,55$
- Teste BCH - teste -  $\hat{b}$  com limiar  $\lambda = 4,60$
- ER n - erro grosso de n desvios padrões
- V 2 - medida de tensão na barra 2
- FA 9-11 - medida de fluxo de potência ativa da barra 9 para a barra 11
- FR 9-11 - medida de fluxo de potência reativa da barra 9 para a barra 11
- IA 9 - injeção de potência ativa na barra 9
- IR 9 - injeção de potência reativa na barra 9

		Teste J(x)/RN			Teste RN 3,55			Teste BCH		
Medida	ER	*	**	***	*	**	***	*	**	***
V 2	8	40	01	40	01	01	0	01	01	0
V 11	8	136	31	139	181	51	23	61	31	9
V 13	8	99	01	99	11	01	1	11	01	1
V 25	8	97	01	97	11	21	3	01	21	2
V 26	8	172	141	186	163	91	172	126	61	132
V 26	15	138	51	143	161	61	22	81	61	14
V 30	8	179	131	192	165	121	177	132	91	141
V 30	15	121	21	123	201	11	21	81	11	9
IFA 9-11	8	69	11	70	01	01	0	01	01	0
IFA 12-14	8	31	01	31	01	01	0	01	01	0
IFA 29-30	8	41	01	41	01	01	0	01	01	0
IFA 25-26	8	42	01	42	01	01	0	01	01	0
IFR 9-11	8	16	01	16	01	01	0	01	01	0
IFR 12-14	8	9	01	9	01	01	0	01	01	0
IFR 29-30	8	14	01	14	01	01	0	01	01	0
IFR 25-26	8	20	01	20	01	01	0	01	01	0
IA 6	8	63	01	63	191	31	22	71	11	8
IA 6	15	16	01	16	01	01	0	01	01	0
IA 9	8	111	11	112	11	11	2	01	11	1
IA 9	15	0	01	0	01	01	0	01	01	0
IA 22	8	95	11	96	01	11	1	01	11	1
IA 22	15	0	01	0	01	01	0	01	01	0
IA 25	8	102	01	102	11	01	1	01	01	0
IA 25	15	0	01	0	01	01	0	01	01	0
IA 27	8	121	01	121	41	21	6	21	01	2
IA 27	15	1	01	1	01	01	0	01	01	0
IA 28	8	97	01	97	01	01	0	01	01	0
IA 28	15	0	01	0	01	01	0	01	01	0
IR 6	8	144	31	147	241	31	27	81	21	10
IR 9	8	98	01	98	01	11	1	11	01	1
IR 22	8	89	01	89	01	01	0	01	01	0
IR 25	8	65	01	65	01	01	0	01	01	0
IR 27	8	76	01	76	11	01	1	11	01	1
IR 28	8	72	01	72	01	01	0	01	01	0

Tabela 4.2.a - Insucessos na detecção/identificação num total de 200 casos com o estimador clássico.

- (\*) - falhas na detecção, ou seja, a variável testada é menor que  $\lambda$
- (\*\*) - insucessos na identificação; a medida identificada como portadora de erros grosseiros não é a medida na qual foi simulado o erro
- (\*\*\*) - total de falhas

			Teste J(x)/RN	Teste RN 3,55	Teste BCH							
	Medida	ER	*	**	***	*	**	***	*	**	***	
	V 2	8	281	01	28	01	01	01	01	01	01	0
	V 11	8	1211	61	127	261	81	34	181	31	21	
	V 13	8	891	11	90	31	11	4	01	11	1	
	V 25	8	611	01	61	01	01	0	01	01	0	
	V 26	8	1671	331	200	1691	311	200	1851	151	200	
	V 26	15	1841	161	200	1881	121	200	1891	111	200	
	V 30	8	1641	361	200	1751	251	200	1851	151	200	
	V 30	15	871	1131	200	841	1161	200	1611	391	200	
IFA	9-11	8	461	01	46	01	01	0	01	01	0	
IFA	12-14	8	01	01	0	01	01	0	01	01	0	
IFA	29-30	8	01	01	0	01	01	0	01	01	0	
IFA	25-26	8	311	21	33	01	01	0	01	01	0	
IFR	9-11	8	141	01	14	01	01	0	01	01	0	
IFR	12-14	8	111	01	11	01	01	0	01	01	0	
IFR	29-30	8	51	01	5	01	01	0	01	01	0	
IFR	25-26	8	101	01	10	01	01	0	01	01	0	
IA	6	8	1421	91	151	401	71	47	191	21	21	
IA	6	15	111	01	11	01	01	0	01	01	0	
IA	9	8	971	11	98	01	11	1	01	11	1	
IA	9	15	11	01	1	01	01	0	01	01	0	
IA	22	8	871	01	87	11	11	2	11	11	2	
IA	22	15	01	01	0	01	01	0	01	01	0	
IA	25	8	761	11	77	11	21	3	11	11	2	
IA	25	15	01	01	0	01	01	0	01	01	0	
IA	27	8	951	31	98	41	31	7	11	21	3	
IA	27	15	11	01	1	01	01	0	01	01	0	
IA	28	8	781	11	78	11	01	1	11	01	1	
IA	28	15	01	01	0	01	01	0	01	01	0	
IR	6	8	1311	41	135	291	41	33	101	31	13	
IR	9	8	881	01	88	01	11	1	11	01	1	
IR	22	8	711	01	71	01	01	0	01	01	0	
IR	25	8	531	11	54	01	01	0	01	01	0	
IR	27	8	521	01	52	01	01	0	01	01	0	
IR	28	8	581	01	58	01	01	0	01	01	0	

Tabela 4.2.b - Insucessos na detecção/identificação num total de 200 casos com o estimador desacoplado.

- (\*) - falhas na detecção, ou seja, a variável testada é menor que  $\lambda$
- (\*\*) - insucessos na identificação; a medida identificada como portadora de erros grosseiros não é a medida na qual foi simulado o erro
- (\*\*\*) - total de falhas

Com relação à detecção, observa-se na tabela 4.2, que em todos os tipos de simulações, o teste -  $J(\hat{x})$  mostrou-se o menos eficiente. Esta ineficiência agrava-se à medida que a rede aumenta de tamanho [8]. Isto porque o erro grosso numa certa medida influí pouco no valor de  $J(\hat{x})$  que é a soma dos resíduos de todas as medidas, sendo desprezível para o sistema como um todo, porém, afetando bastante o estado da região onde se localiza a medida perturbada.

No caso da identificação, nota-se que quando o erro grosso localizou-se nas barras 26 e 30, os métodos falharam muito na identificação da medida, para uma magnitude do erro de 8% . Nota-se que quando a magnitude do erro passou para 15% , o desempenho dos métodos com o estimador clássico melhorou, indicando que o problema estava no nível de redundância. Para o desacoplado o desempenho não se alterou quando a magnitude do erro grosso passou de 8% para 15% . Além disso, ambos os estimadores apresentaram alguns problemas de detecção e identificação quando o erro era numa medida de injeção.

#### 4.4 Influência da Relação X/R

O objetivo deste teste é verificar a influência das relações X/R nos problemas de identificação de erros grosseiros em medidas de tensão em barras de baixa tensão [11], quando aplicado ao estimador desacoplado. Para isto, foram alteradas (artificialmente) as relações X/R das linhas 27-29, 27-30 e 29-30 (multiplicadas por 5). Com este novo conjunto de dados repetiram-

se os casos com erro grosseiro na medida de tensão na barra 30, 200 simulações cada caso, com o estimador desacoplado.

Foi criado também outro conjunto de dados que, além das linhas já mencionadas, tem as relações das linhas 22-24, 24-25 e 25-26 também multiplicadas por 5. A partir deste último conjunto, repetiram-se os casos para erro grosseiro na medida de tensão na barra 26.

Os resultados destas simulações estão na tabela 4.3. Deste teste, conclui-se que os problemas de identificação da medida com erro grosseiro, para um erro em medida de tensão, encontrados quando aplicados com o estimador desacoplado estão relacionados com a localização na rede, sendo que erros na região de alta tensão são mais facilmente identificáveis que os localizados na região de baixa tensão.

#### 4.5 Conclusões

Com base nos resultados dos testes efetuados, pode-se afirmar que os métodos de detecção e identificação apresentam comportamento semelhante quando aplicados tanto com o estimador clássico quanto com o desacoplado rápido, ou seja, as aproximações introduzidas para a obtenção do estimador desacoplado rápido não afetam o desempenho dos métodos.

Além disto, os métodos  $r^N$  ( $\lambda = 3.55$ ) e  $\hat{b}$  apresentaram desempenho semelhante e, ambos, muito melhor, para detecção, que o  $J(\underline{x})$ .

Medida	ER	Teste J(x)/RN			Teste RN 3,55			Teste BCH		
		*	**	***	*	**	***	*	**	***
V30	8	164	36	200	175	25	200	185	15	200
V30(1)	8	169	15	184	141	13	154	99	5	104
V30	15	87	113	200	84	116	200	161	39	200
V30(1)	15	100	21	102	11	21	3	21	0	2
V26	8	167	33	200	169	31	200	185	15	200
V26(2)	8	175	10	185	107	45	152	79	39	118
V26	15	184	16	200	188	12	200	189	11	200
V26(2)	15	101	21	103	41	41	8	41	21	6

Tabela 4.3 - Insucessos na detecção/identificação com alteração da relação X/R

- (\*) - falhas na detecção, ou seja, a variável testada é menor que  $\lambda$
- (\*\*) - insucessos na identificação; a medida identificada como portadora de erros grosseiros não é a medida na qual foi simulado o erro
- (\*\*\*) - total de falhas
- (1) - conjunto de dados com as relações das linhas 27-29, 27-30 e 29-30 multiplicadas por 5
- (2) - arquivo com as relações das linhas 27-29, 27-30, 29-30, 22-24, 24-25 e 25-26 multiplicadas por 5

## Capítulo 5 - Dedução das Novas Valores de $\lambda$ para o Teste - $r^N$

### 5.1 Introdução

Neste capítulo é apresentada uma justificativa teórica para a determinação do limiar  $\lambda$  para o teste  $r^N$ , seguindo a interpretação de alarmes falsos usada neste trabalho, referida item 4.3.1. Ou seja, o número de alarmes falsos é igual ao número de vezes que o teste indica a presença de erros grosseiros em pelo menos uma medida, quando na realidade eles não existem.

### 5.2 Revisão Estatística

Sejam  $k$  variáveis aleatórias,  $x_1, x_2, \dots, x_k$ , independentes, com distribuição  $N(0,1)$ . A probabilidade de que uma variável aleatória qualquer  $x_i$ , por exemplo, assuma um valor maior ou igual a  $\lambda$  é dada por:

$$\text{prob}(x_i \geq \lambda) = \int_{\lambda}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-z^2/2} dz \triangleq 1 - p_i \quad (5.1)$$

Definindo  $\lambda$ , a probabilidade  $p_i$  pode ser facilmente encontrada em tabelas existentes em qualquer livro de estatística.

O problema que se quer resolver é um pouco diferente. Dadas as  $k$  variáveis aleatórias, quer se determinar a probabilidade de que pelo menos uma delas assuma um valor maior ou igual a  $\lambda$ . Ou seja, a probabilidade do conjunto

$$A: \{x_1 \geq \lambda \text{ ou } x_2 \geq \lambda \text{ ou } \dots \text{ ou } x_k \geq \lambda\} \quad (5.2)$$

Chamando esta probabilidade de  $p^*$  tem-se que:

$$p^* = 1 - \text{prob}(x_1 < \lambda \text{ e } x_2 < \lambda \text{ e } \dots \text{ e } x_k < \lambda) \quad (5.3)$$

ou seja, é o complemento da probabilidade de que nenhuma variável aleatória assuma um valor menor que  $\lambda$ . Lembrando que, por hipótese, as variáveis aleatórias são independentes, tem-se:

$$\begin{aligned} p^* &= 1 - \text{prob}(x_1 < \lambda) \times \text{prob}(x_2 < \lambda) \times \dots \times \text{prob}(x_k < \lambda) \\ &= 1 - (p_i)^k \end{aligned} \quad (5.4)$$

com  $p_i$  definido na equação (5.1).

Da equação (5.4) pode se obter, facilmente,  $p_i$  em função de  $p^*$ :

$$p_i = (1 - p^*)^{1/k} \quad (5.5)$$

Da equação (5.5) pode-se resolver o seguinte problema: conhecidos  $k$  (número de variáveis independentes) e  $p^*$  (probabilidade de que pelo menos uma das medidas assuma <sup>ou igual a</sup> um valor maior que  $\lambda$ ), determinar o  $\lambda$  correspondente. Para tanto, basta determinar  $\rho_i$  e recorrer a uma tabela de distribuição normal.

Para  $p^* = 0,05$  (5%), e  $k$  variando de 1 a 1000 tem-se o valor de  $\lambda$  na tabela 5.1.

	$k$		$\lambda$	
	1		1,96	
	2		2,24	
	5		2,57	
	10		2,80	
	20		3,00	
	30		3,10	
	50		3,30	
	100		3,50	
	151		3,60	
	200		3,70	
	329		3,80	
	500		3,90	
	1000		4,10	

Tabela 5.1      Valor de  $\lambda$  em função do número de variáveis aleatórias independentes

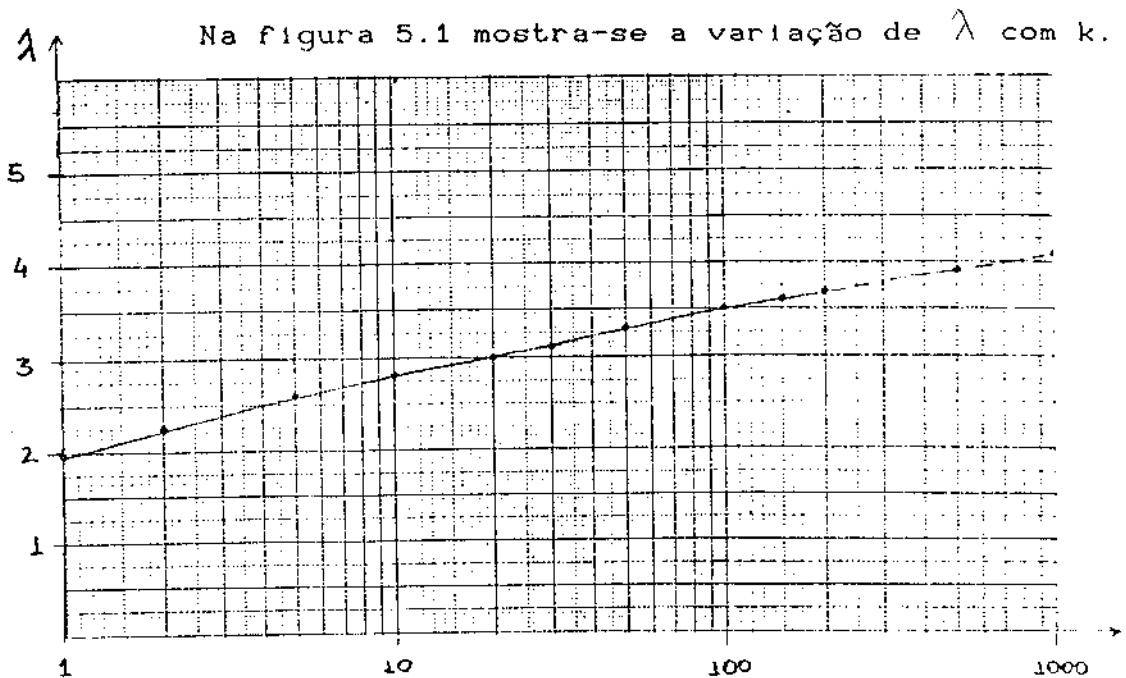


Figura 5.1 - Variação de  $\lambda$  com  $k$

### 5.2.1 Aplicação ao Teste - $\Gamma^N$

O que foi deduzido no tópico anterior pode ser aplicado diretamente ao teste -  $\Gamma^N$ , com a ressalva de que o número de resíduos normalizados independentes é igual a  $m-n$ , número de graus de liberdade. Isto pode ser verificado utilizando-se a relação entre  $\Sigma$  e  $\underline{w}$ , dada pela equação (3.9):

$$\underline{\Sigma} = \Gamma \cdot \underline{w} \quad (3.9)$$

O vetor  $w$  é composto de  $m$  variáveis independentes (por hipótese) e  $\Gamma$  tem posto igual a  $m-n$ . Assim,

$$k = m - n \quad (5.6)$$

É fácil concluir que a probabilidade  $p^*$ , definida na equação (5.3) é a probabilidade de alarme falso assumida. Desta forma, a definição do limiar  $\lambda$  para o teste  $-t^N$  segue os passos:

- i) definir  $p^*$  = probabilidade de alarme falso
- ii) conhecidos  $p^*$  e o número de graus de liberdade, determina-se  $P_c$ :

$$P_c = (1 - p^*)^{1/k}$$

(com  $k = m - n$ )

- iii) de uma tabela de distribuição  $N(0, 1)$  entra-se com  $P_c$  e obtém-se  $\lambda$ , que é o valor procurado.

Nas redes-teste utilizadas, o número de graus de liberdade são iguais a 151 para IEEE30 e 329 para FURNAS66. Na tabela 5.1 verifica-se que os  $\lambda$ 's correspondentes são 3,6 e 3,8. Note-se que na referência [8] obteve-se, simulando 500 casos, o valor 3,55 para a rede IEEE30.

### 5.3 Testes e Resultados

#### 5.3.1 Validação do Método

Em primeiro lugar foram feitos testes para se verificar como o valor de  $\lambda$  para o teste  $-t^N$  variava com o

número de graus de liberdade do sistema e, se este valor, obtido segundo a referência [8] era compatível com o calculado conforme sugerido no item 5.1, considerando que os resíduos normalizados são independentes.

A rede utilizada para este teste foi a Stagg, rede com 5 barras e 7 linhas está na figura 5.1, e foi retirada da referência [9].

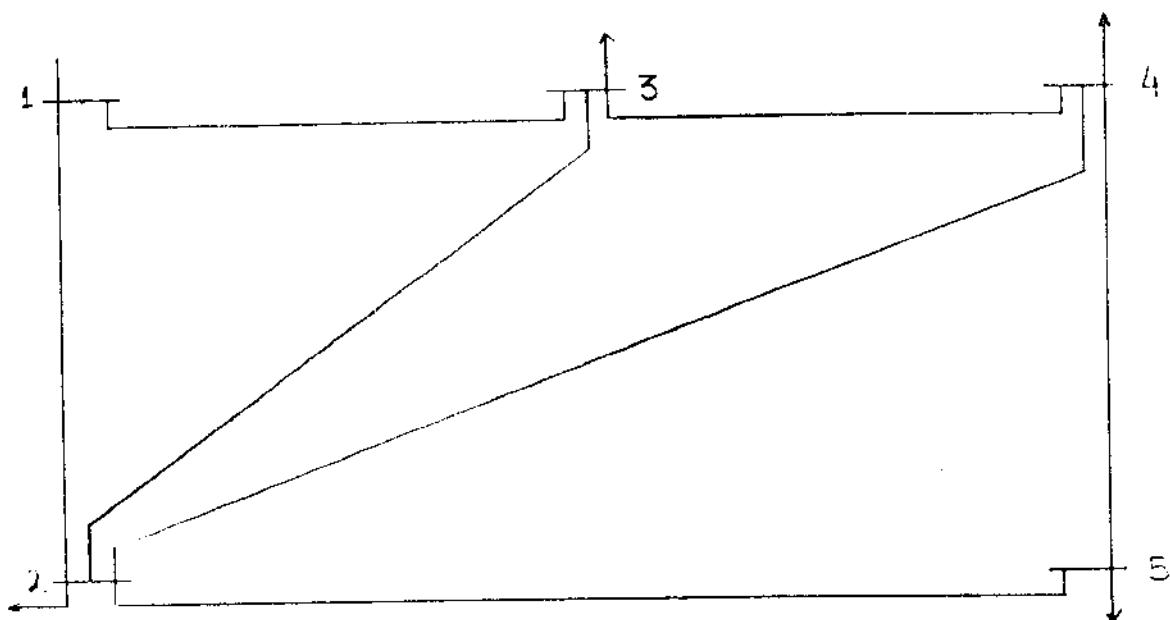


Figura 5.1 - Rede Stagg

Com o objetivo de se terem sistemas com diferentes graus de liberdade, nas simulações foram utilizados conjuntos de medidas diferentes, sendo simulados 200 casos para cada conjunto de medidas somente na presença de erros aleatórios. Os resultados destes testes estão na tabela 5.2.

	k	*	**	
	34	3,0	3,2	
	20	2,9	3,0	
	10	2,75	2,8	
	4	2,5	2,49	
	2	2,05	2,24	
	1	1,9	1,96	

Tabela 5.2 - Limiares para diferentes graus de liberdade  
 \* - referência [8]  
 \*\* - nova proposta  
 k - graus de liberdade = m-n

Como pode ser notado, os valores obtidos teoricamente estão bem próximos dos obtidos segundo a referência [8]. Ressalte-se que em todos estes testes foi utilizado o estimador desacopla o que significa que os desvios padrões dos resíduos são obtidos de maneira aproximada.

### 5.3.2 Alarmes Falsos com o Novo $\lambda$

Com o valor de  $\lambda$  para o teste -  $r^N$  calculado como sugerido no item 5.2, repetiu-se o teste de alarmes falsos. Na tabela 5.3 estão os resultados deste teste.

estimador	sistema	(*)	(**)	
W L S	AEP30	500	14	
D E S	AEP30	500	14	
D E S	FURNAS	500	35	

Tabela 5.3 - Número de alarmes falsos para 500 casos rodados.  
 (\*) - convencional ( $\lambda \approx 1,96$ )  
 (\*\*) - nova proposta ( $\lambda \approx 3,6$  AEP30)  
 ( $\lambda \approx 3,6$  Furnas)

Pela tabela 5.3, pode-se observar que o teste de alarmes falsos com o novo  $\lambda$  apresenta um resultado razoável (no caso, 5% dos casos correspondem a 25 alarmes falsos).

### 5.3.3 Falhas de Detecção e Identificação com Novo $\lambda$

Além do teste de alarmes falsos, é importante verificar se  $\lambda$ , calculado como proposto neste trabalho, aumenta muito as falhas de detecção. Com esta finalidade, repetiu-se alguns dos casos simulados para os testes de falhas de detecção e falhas de identificação citados no Capítulo 4.

Na tabela 5.4 estão alguns dos resultados. Observa-se que o  $\lambda$  calculado conforme sugerido por este trabalho não implicou numa piora significativa das falhas de detecção e identificação.

## 5.4 Conclusões

Neste capítulo apresentou-se uma justificativa teórica para a obtenção do novo valor de  $\lambda$  no teste  $\chi^2$ . Evidenciou-se que este valor é função de dois parâmetros: o número de graus de liberdade ( $m-n$ ) e a probabilidade de alarme falso assumida.

## Legenda da tabela 5.4:

Teste RN(3,55)	- teste - " com limiar $\lambda = 3,55$
Teste RN(3,60)	- teste - " com limiar $\lambda = 3,60$
ER n	- erro grosso de n desvios padrões
V 2	- medida de tensão na barra 2
FA 9-11	- medida de fluxo de potência ativa da barra 9 para a barra 11
FR 9-11	- medida de fluxo de potência reativa da barra 9 para a barra 11
IA 9	- injeção de potência ativa na barra 9
IR 9	- injeção de potência reativa na barra 9

		Teste RN 3.55   Teste RN 3.60	
Medida   ER		*	**   ***
V 11   8   18   5   23   1   21   4   25			
V 13   8   11   0   1   1   4   0   4			
V 25   8   11   2   3   1   1   2   3			
V 26   8   163   9   172   1   172   8   180			
V 26   15   16   6   22   20   5   25			
V 30   8   165   12   177   167   7   174			
V 30   15   20   11   21   14   7   21			
FA 9-11   8   0   0   0   0   0   2   2			
FA 25-26   8   0   0   0   0   0   0   0			
FR 9-11   8   0   0   0   0   0   0   0			
FR 25-26   8   0   0   0   0   0   0   0			
IA 6   8   19   3   22   63   3   66			
IA 9   8   11   1   2   0   6   6			
IA 22   8   0   1   1   1   0   0   1			
IA 25   8   11   0   1   1   1   0   1			
IA 27   8   4   2   6   6   11   7			
IA 28   8   0   0   0   1   1   0   1			
IR 9   8   0   1   1   1   0   0   0			
IR 22   8   0   0   0   0   0   0   0			
IR 25   8   0   0   0   0   0   1   1			
IR 27   8   11   0   1   1   1   0   1			
IR 28   8   0   0   0   0   0   0   0			

Tabela 5.4.a - Insucessos na detecção/identificação num total de 200 casos com o estimador clássico

- (\*) - falhas na detecção, ou seja, a variável testada é menor que  $\lambda$ .
- (\*\*) - insucessos na identificação; a medida identificada como portadora de erros grosseiros não é a medida na qual foi simulado o erro
- (\*\*\*) - total de falhas

		Teste RN 3.55	Teste RN 3.60					
Medida	ER	*	**	***	*	**	***	
V 11	8	26	8	34	31	8	39	
V 13	8	31	11	4	41	11	5	
V 25	8	01	01	0	01	01	0	
V 26	8	169	31	200	177	231	200	
V 26	15	188	121	200	194	61	200	
V 30	8	175	25	200	183	17	200	
V 30	15	84	116	200	100	100	200	
I FA 9-11	8	01	01	0	01	01	0	
I FA 25-26	8	01	01	0	01	01	0	
I FR 9-11	8	01	01	0	01	01	0	
I FR 25-26	8	01	01	0	01	01	0	
I IA 6	8	40	7	47	41	7	48	
I IA 9	8	01	11	1	01	11	1	
I IA 22	8	11	11	2	11	11	2	
I IA 25	8	01	21	2	11	21	3	
I IA 27	8	41	31	7	51	31	8	
I IA 28	8	11	01	1	11	01	1	
I IR 9	8	01	11	1	11	01	1	
I IR 22	8	01	01	0	01	01	0	
I IR 25	8	01	01	0	01	01	0	
I IR 27	8	01	01	0	01	01	0	
I IR 28	8	01	01	0	01	01	0	

Tabela 5.4.b - Insucessos na detecção/identificação num total de 200 casos com o estimador desacoplado

- (\*) - falhas na detecção, ou seja, a variável testada é menor que 9.
- (\*\*) - insucessos na identificação; a medida identificada como portadora de erros grosseiros não é a medida na qual foi simulado o erro
- (\*\*\*) - total de falhas

## Capítulo 6 - Conclusões e Comentários Finais

O objetivo inicial deste trabalho era a avaliação de alguns métodos propostos na literatura para o processamento de erros grosseiros. Para tanto foram utilizados dois estimadores de estado. Um, empregando o método desacoplado rápido [3][4], e outro, empregando o método clássico, que foi desenvolvido especialmente para este trabalho. No desenvolver do trabalho foi possível, além de uma avaliação de alguns métodos para processamento de erros grosseiros, propor uma nova maneira de calcular os limitares de detecção para o teste  $\Gamma^N$ .

Embora em cada capítulo precedente já se tenha comentado e concluído acerca do tópico abordado, abaixo estão alguns pontos que devem ser ressaltados.

- a) Dos testes efetuados e apresentados no capítulo 4, pode-se afirmar, de uma maneira geral, que os métodos de detecção e identificação apresentaram desempenho semelhante quando aplicados com os dois estimadores. Ressalte-se que esta conclusão já foi obtida em [1].
- b) Os problemas de identificação (e detecção), aconteceram quase sempre em virtude do baixo nível de redundância. Ressalte-se que, para o estimador desacoplado, quando além do baixo nível de redundância a medida afetada por erros grosseiros era uma medida de tensão numa barra localizada numa

região de baixa tensão, foram encontrados problemas de detecção e identificação.

- c) As medidas de injeção, quando perturbadas por erros grosseiros, causaram alguns problemas a todos os métodos de processamento de erros grosseiros e com ambos estimadores.
- d) Dos métodos testados, como já havia sido concluído em [8], o teste  $-J(\hat{x})/\tau^N$  se mostrou o menos eficiente. O teste  $-\tau^N$  e o teste  $-\hat{b}$  têm desempenho semelhante. Saliente-se que o teste  $-\tau^N$  aqui referido é o que aparece nos testes apresentados na referência [8] ou então, o proposto no capítulo 5 deste trabalho. Dada a facilidade com que se definem os limites de detecção para o teste  $-\tau^N$ , é de se supor que a maneira aqui proposta de obtenção deste limite seja a preferida.

Dese ser ressaltado que todos os resultados foram obtidos para a presença de apenas um erro grosso. Na presença de múltiplos erros grosseiros, sem interação entre eles, é de se esperar que as conclusões acima listadas sejam praticamente as mesmas. Contudo, se houver interação entre os erros grosseiros, estas conclusões podem ser alteradas.

## REFERENCIAS BIBLIOGRAFICAS

- [1] - ALLEMONG, J. J.; RADU, L.; SASSON, A. M. A fast and reliable state estimation algorithm for AEP's new control center. *IEEE Transactions on Power Apparatus and Systems*, PAS 101(4):933-44, April, 1982.
- [2] - DOPAZO, J. F.; KLITIN, D. A.; SASSON, A. M. State estimation for power systems: detection and identification of gross measurement errors. In: Conference on Power Industry Computer Application, B-PICA/73, Minneapolis, 1973.
- [3] - GARCIA, A. V. Estimação estática de estado em sistemas de potência utilizando método desacoplado. Campinas (SP), Faculdade de Engenharia de Campinas, 1977. 118p. Tese (mestrado) - Faculdade de Engenharia de Campinas, UNICAMP.
- [4] - GARCIA, A. V.; MONTICELLI, A.; ABREU, P. Fast decoupled state estimation and bad data processing. *IEEE Transactions on Power Apparatus and Systems*, PAS 98(5):1645-652, September/October, 1979.
- [5] - HANDSCHIN, E. et al. Bad data analysis for power system state estimation. *IEEE Transactions on Power Apparatus and Systems*, PAS 94(2):329-37, March/April, 1975.
- [6] - MERRIL, H. M. & SCHWEPPPE, F. C. Bad data suppression in power systems static state estimation. *IEEE Transactions on Power Apparatus and Systems*, PAS 90(6):2718-25, November/December, 1971.
- [7] - MONTICELLI, A. & GARCIA, A. V. Análise de sensibilidade aplicada ao processamento de erros grosseiros na estimação de estado em sistemas de energia elétrica. In: Congresso Brasileiro de Automática, 4. Campinas (SP), UNICAMP, 1982. p.462-66.
- [8] - MONTICELLI, A. & GARCIA, A. V. Reliable bad data processing for real-time state estimation. *IEEE Transactions on Power Apparatus and Systems*, PAS 102(5):1126-139, May, 1983.

- [9] - STAGG, G. W. & EL-ABIAD, A. H. Computer methods in power system analysis. New York, McGraw-Hill, 1968. (McGraw-Hill series in electronic systems) 427p.
- [10] - STOTT, B. & ALSAÇ, O. Fast decoupled load flow. IEEE Transactions on Power Apparatus and Systems, PAS 93(3):859-69, May/June, 1974.
- [11] - TANAKA, M. R. & GARCIA, A. V. Avaliação de métodos para processamento de erros grosseiros na estimação de estado em sistemas de energia elétrica. In: Congresso Brasileiro de Automática, 5. Campina Grande (PB), 1984. p.256-262.