

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO

**A ESTIMAÇÃO DE ESTADO EM REDES DE TRANSPORTE DE ENERGIA
COM DETECÇÃO E IDENTIFICAÇÃO DE ANOMALIAS**

Roque Filipe Mesquita Brandão

Licenciado em Engenharia de Automação e Controlo
pela Universidade Moderna do Porto

Dissertação submetida para satisfação parcial dos
requisitos do grau de mestre
em
Engenharia Electrotécnica e de Computadores
(Área de especialização de Sistemas de Energia)

Dissertação realizada sob a orientação da
Professora Doutora Isabel Maria Marques Alves Ferreira,
do Departamento de Engenharia Electrotécnica e de Computadores
da Faculdade de Engenharia do Porto
e co-orientação do
Professor Doutor José António Beleza Carvalho,
do Departamento de Engenharia Electrotécnica
do Instituto Superior de Engenharia do Porto

Porto, Janeiro de 2005

Labor omnia vincit improbus
(“O trabalho persistente tudo vence”, Virgílio)

À minha esposa Zita.
Ao Gonçalo ou à Francisca que
em breve fará parte da família.

Agradecimentos

Desejo expressar o meu profundo agradecimento à minha orientadora científica, Prof^a Doutora Isabel Maria Marques Alves Ferreira, pela disponibilidade demonstrada ao longo do tempo, pelos incentivos, orientações e sugestões essenciais à elaboração desta dissertação.

Ao Prof. Doutor José António Beleza Carvalho, orientador do grupo de disciplinas de sistemas de energia do ISEP, a amizade, a lealdade, a disponibilidade e o apoio constante, as sugestões e os incentivos fulcrais para a passagem das dificuldades. Sem ele nada disto teria sido possível.

À minha família que apesar das dificuldades, tudo fizeram para que eu nunca desistisse.

Resumo

Este trabalho de investigação analisa o problema da Estimação de Estado de Sistemas Eléctricos de Energia. O estimador de estado processa um conjunto redundante de medidas com o objectivo de estimar o estado de uma rede eléctrica de energia. Medidas lógicas e analógicas são teletransmitidas para os centros de controlo. As medidas lógicas são utilizadas pelo processador de topologia para determinar a configuração do sistema. As medidas analógicas são usadas juntamente com a informação proveniente do processador de topologia, com os parâmetros da rede e por vezes com algumas pseudomedidas como dados iniciais do processo de estimação de estado. Se o conjunto de medidas for suficiente para tornar a estimação de estado possível, então a rede diz-se observável. Perdas temporárias da observabilidade da rede podem acontecer devido a mudanças repentinas da topologia da rede ou a falhas do sistema de telecomunicações. Para garantir precisão na estimativa de estado obtida, é fundamental dotar o estimador de estado de uma rotina de detecção e identificação de erros grosseiros, que eventualmente poderão afectar as medidas a serem processadas.

Genericamente pode afirmar-se que as técnicas de estimação de estado se dividem em dois grandes grupos: estimação estática e estimação dinâmica. A estimação estática baseia-se no pressuposto de que o ponto de funcionamento do sistema se pode considerar aproximadamente constante para pequenos intervalos de tempo. Estes métodos não consideram portanto a evolução temporal do vector de estado do sistema. A estimação dinâmica está normalmente associada a estudos em tempo real da segurança dinâmica das redes eléctricas de energia. Estes métodos recorrem habitualmente a algoritmos baseados no filtro de Kalman, no entanto, a utilização destes algoritmos apresenta dois tipos de

dificuldades: a elevada dimensão dos problemas a analisar e a exigência de um reduzido tempo de execução.

O presente trabalho pode considerar-se dividido em três partes fundamentais. Na primeira parte é feita uma abordagem à formulação matemática do problema e faz-se referência aos algoritmos mais utilizados. Na segunda parte apresentam-se e discutem-se algumas das metodologias mais utilizadas para a detecção e identificação de erros grosseiros. Na terceira parte, descreve-se o algoritmo implementado para análise de estimação de estado de um SEE com detecção e identificação de erros grosseiros e discutem-se os resultados obtidos.

Abstract

This research work studies the problem of State Estimation in Electric Power Systems. State estimation processes a set of redundant measurements to estimate the state of the power system. Logic and analogic measurements are telemeters to the control centre. Logic measurements are used in topology processor to determine the system configuration. The state estimator uses a set of analog measurements along with the system configuration supplied by the topology processor, network parameters and if necessary some pseudo measurements as input of state estimation process. If the set of measurements is sufficient to make the state estimation possible, thus the network is observable. Temporary unobservability may still occur due to unanticipated network topology changes or failures in the telecommunications systems. To guarantee the accuracy of state estimation results, it's necessary to provide the state estimator with a routine of detection and identification of anomalies that may eventually affect the measures.

Generically it's possible to say that state estimation techniques are divided in two main groups: static estimation and dynamic estimation. Static estimation is based in the presupposition that system function point can be considered constant for small time periods. These methods don't take in attention the temporal evolution of system state vector. Dynamic estimation is normally associated with studies on the dynamic safety of electric power systems networks in real time. These methods are based on the Kalman filter algorithm; however the implementation of these algorithms brings two kinds of difficulties: the wide scale of problem to be analysed and, simultaneously, the need of reduced time of execution.

The work developed during the writing of this thesis can be divided in three main areas. In the first one, the state estimation process is presented as well as some usual approaches to solve it. Second part is about the bad data detection and identification problem and some methods to deal with this are discussed. In the third and last part of the work, an algorithm for state estimation of an electric power system with bad data detection and identification routines is described and analysed.

Índice

1. Introdução.....	3
1.1 -Introdução	3
1.2 -Objectivo e estrutura da dissertação.....	5
 2. A Estimação de Estado aplicada a SEE.....	 9
2.1 - Introdução.....	9
2.1.1 -Sistemas de Supervisão e Controlo.....	14
2.2 - Modelização da rede.....	15
2.2.1 - Introdução.....	15
2.2.2 - Modelo de representação das linhas e transformadores.....	17
2.3 - Precisão das medidas.....	18
2.4 - Medidas e equações de medida.....	22
2.4.1 -Introdução.....	22
2.4.2 - Tipos de medidas.....	23
2.4.3 - Equações de medida.....	24
2.5 -Algoritmos de Estimação de Estado.....	25
2.5.1 - Estimação de Estado Clássica.....	25

2.5.1.1 -Aproximação Clássica – Algoritmo Base.....	25
2.5.1.2 -Método das equações normais com restrições.....	31
2.5.1.3 -Método de Hachtel.....	33
2.5.1.4 -Método de Factorização Ortogonal.....	33
2.5.1.5 -Método de Peter Wilkinson.....	34
2.5.1.6 -Método WLAV.....	35
2.5.1.7 -Estimação de Estado baseada na lógica Fuzzy.....	37
2.5.1.8 -Modelos desacoplados aplicados à estimação de estado.....	39
2.5.2 -Estimação de Estado Dinâmica.....	47
2.6 -Conclusões.....	51
3. Erros Grosseiros – Metodologias de Detecção e Identificação.....	55
3.1 Introdução.....	55
3.2 Objectivos da rotina de detecção e identificação de erros grosseiros.....	56
3.3 Erros que afectam o estimador de estado.....	58
3.4 Definição de erro grosseiro de medida.....	59
3.5 Detecção de erros grosseiros.....	61
3.5.1 Introdução.....	61
3.5.2 Teste do $J(x)$	63
3.5.3 Teste dos resíduos normalizados e dos resíduos ponderados.....	64
3.5.4 Teste da amplitude do erro grosseiro.....	65
3.6 Identificação de erros grosseiros.....	66
3.6.1 Identificação por eliminação.....	66
3.6.2 Identificação por critérios não-quadráticos.....	68

3.6.3 Identificação por teste de hipóteses.....	71
3.7 Conclusões.....	72
4 Resultados Computacionais.....	77
4.1 Introdução.....	77
4.2 Métodos de simulação usados.....	78
4.2.1 Algoritmos implementados.....	80
4.2.2 Estrutura da matriz Jacobiana – $H(x)$	82
4.3 Redes de teste.....	86
4.3.1 Configurações de medidas.....	90
4.4 Parâmetros em análise.....	92
4.5 Apresentação dos resultados.....	93
4.5.1 Análise dos resultados.....	97
4.6 Detecção de erros grosseiros.....	99
4.6.1 Identificação por eliminação.....	112
4.6.2 Geração de pseudomedidas.....	114
4.7 Conclusões.....	118
5 Conclusão.....	122
Bibliografia.....	125
Apêndice A – Propriedades do estimador WLS / determinação das matrizes covariância.....	134

Apêndice B – Comportamento de r e $J(\hat{x})$ na presença de erros grosseiros.....	137
Apêndice C – Resíduos Normalizados e Resíduos Ponderados.....	140
Apêndice D – Linearização das equações de medida.....	142
Apêndice E – Dados da Rede de 24 barramentos.....	145
Apêndice F – Dados da Rede de 118 barramentos.....	147

Lista de Figuras

Figura 2.1 - Conceito de Estimação de Estado (EE).....	11
Figura 2.2 - Esquema básico de um estimador de estado estático.....	13
Figura 2.3 - Funcionamento do estimador de estado estático.....	15
Figura 2.4 - Equivalente em π de uma linha.....	17
Figura 2.5 - Modelo matemático equivalente de um transformador.....	18
Figura 2.6 - Cadeia de transmissão de medidas.....	19
Figura 2.7 - Estimação de Estado pelo método de Gauss.....	29
Figura 2.8 - Algoritmo de estimação de estado integrando conceitos de lógica fuzzy..	38
Figura 2.9 - Fluxograma de um estimador desacoplado (FDSE).....	46
Figura 2.10 - Etapas de previsão e filtragem de um estimador dinâmico baseado no filtro de Kalman.....	50
Figura 3.1 - Regiões de aceitação e rejeição associadas a um teste unilateral.....	62
Figura 3.2 - Funções de custo não quadráticas utilizadas nos estimadores <i>BDS</i> ''(<i>Bad</i> <i>Data Supression</i> '').....	69
Figura 3.3 - Relação entre os termos de ρ e $G_{ii}^{\#}$ para diversas funções de custo não quadráticas.....	70
Figura 3.4 - Fluxograma sucinto do procedimento HTI.....	72

Figura 4.1 - Estrutura do processo implementado.....	79
Figura 4.2 - Sistema de teste de 24 barramentos.....	88
Figura 4.3 – Sistema de teste de 118 barramentos.....	89
Figura 4.4 - Estimação de estado Integral vs Desacoplada. Tempo de processamento.....	96
Figura 4.5 - Estimação de estado Integral vs Desacoplada. Função Objectivo $J(\hat{x})$	96
Figura 4.6 - Estimação de estado Integral vs Desacoplada. Erro médio do vector estado estimado.....	97
Figura 4.7 - Número de medidas relacionadas com as medidas afectadas por erros grosseiros em cada configuração de medida.....	106
Figura 4.8 - Comparação dos erros de estimação no vector de estado.....	118

Lista de Tabelas

Tabela 2.1 - Equações do filtro de Kalman.....	48
Tabela 2.2 - Equações das etapas de previsão e filtragem.....	49
Tabela 3.1 - Tabela de decisão para um teste de hipóteses.....	62
Tabela 4.1 - Dados da rede de 24 barramentos.....	87
Tabela 4.2 - Dados da rede de 118 barramentos.....	87
Tabela 4.3 - Dados dos sistemas de teste.....	87
Tabela 4.4 - Configuração de medida da rede A (Conf.1)... ..	90
Tabela 4.5 - Configuração de medida da rede A (Conf.2)... ..	91
Tabela 4.6 - Configuração de medida da rede B (conf.1).....	91
Tabela 4.7 - Configuração de medida da rede B (Conf.2).....	92
Tabela 4.8 - Resultados da estimação - versão integral.....	93
Tabela 4.9 - Resultados estatísticos da estimação - versão integral.....	94
Tabela 4.10 - Resultados da estimação - versão desacoplada.....	94
Tabela 4.11 - Resultados estatísticos da estimação - versão desacoplada.....	94
Tabela 4.12 - Resultados da estimação - versão integral.....	94
Tabela 4.13 - Resultados estatísticos da estimação - versão integral.....	95
Tabela 4.14 - Resultados da estimação - versão desacoplada.....	95

Tabela 4.15 - Resultados estatísticos da estimação - versão desacoplada.....	95
Tabela 4.16 - Detecção de um erro grosseiro com amplitude variável na medida V_{17}	100
Tabela 4.17 - Detecção de um erro grosseiro com amplitude variável na medida P_2	101
Tabela 4.18 - Detecção de um erro grosseiro com amplitude variável na medida Q_{1-5}	102
Tabela 4.19 - Detecção de um erro grosseiro com amplitude variável na medida V_{17}	103
Tabela 4.20 – Detecção de um erro grosseiro com amplitude variável na medida P_2	104
Tabela 4.21 - Detecção de um erro grosseiro com amplitude variável na medida Q_{1-5}	105
Tabela 4.22 - Evolução do valor dos índices $J(\hat{x})$, $J_A(\hat{x})$ e $J_R(\hat{x})$ na presença de um erro grosseiro com amplitude variável na medida V_{17}	108
Tabela 4.23 - Evolução do valor dos índices $J(\hat{x})$, $J_A(\hat{x})$ e $J_R(\hat{x})$ na presença de um erro grosseiro com amplitude variável na medida P_2	109
Tabela 4.24 - Evolução do valor dos índices $J(\hat{x})$, $J_A(\hat{x})$ e $J_R(\hat{x})$ na presença de um erro grosseiro com amplitude variável na medida Q_{1-5}	110
Tabela 4.25 - Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$	111
Tabela 4.26 - Resíduos normalizados de maior amplitude – 1º ciclo.....	112
Tabela 4.27 - Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 2º ciclo.....	112
Tabela 4.28 - Resíduos normalizados de maior amplitude – 2º ciclo.....	112
Tabela 4.29 - Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 3º ciclo.....	113
Tabela 4.30 - Resíduos normalizados de maior amplitude – 3º ciclo.....	113

Tabela 4.31 - Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 4º ciclo.....	113
Tabela 4.32 - Precisão das medidas geradas para a medida V_{18}	115
Tabela 4.33 - Precisão das medidas geradas para a medida P_{1-2}	115
Tabela 4.34 - Precisão das medidas geradas para a medida Q_{10-12}	115
Tabela 4.35 - Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 2º ciclo.....	116
Tabela 4.36 - Resíduos normalizados de maior amplitude – 2º ciclo.....	116
Tabela 4.37 - Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 3º ciclo.....	116
Tabela 4.38 - Resíduos normalizados de maior amplitude – 3º ciclo.....	117
Tabela 4.39 - Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 3º ciclo.....	117
Tabela 4.40 - Erros de estimação (médio e máximo) no vector de estado.....	117
Tabela A.1 - Vectors δ_x , δ_h , r e respectivas matrizes covariância.....	136
Tabela E.1 - Dados e resultados do trânsito de potências.....	145
Tabela E.2 - Dados das Linhas e transformadores.....	146
Tabela F.1 - Dados e resultados do trânsito de potências.....	147
Tabela F.2 - Dados das Linhas e transformadores.....	150

Lista de Símbolos e Abreviaturas

De uma forma geral, todos os símbolos utilizados encontram-se definidos e caracterizados no próprio local do texto em que são referidos pela primeira vez. No entanto, por forma a facilitar a leitura desta dissertação, apresenta-se a lista dos símbolos e abreviaturas mais utilizados. Relativamente à notação adoptada na estimação de estado estática de Sistemas Eléctricos de Energia deve salientar-se que, qualquer grandeza estimada será afectada por um acento circunflexo (^).

x :	Vector de estado do Sistema Eléctrico de Energia, $x = [\theta^T, V^T]^T$
$\hat{x}$:	Estimativa do vector de estado x
θ_i :	Fase da tensão no barramento i
V_i :	Módulo da tensão no barramento i
$\underline{Y}$:	Matriz das admitâncias da rede
$\underline{Y}_{ij}$:	Elemento da linha i , coluna j de $\underline{Y}$, $\underline{Y}_{ij} = G_{ij} + jB_{ij}$
P_i :	Potência activa injectada no barramento i
Q_i :	Potência reactiva injectada no barramento i
P_{ij} :	Trânsito de potência activa no ramo que liga os barramentos i e j
Q_{ij} :	Trânsito de potência reactiva no ramo que liga os barramentos i e j
z :	Vector das medidas efectuadas no sistema
z_P :	Vector de medidas activas
z_Q :	Vector de medidas reactivas

$h(.) :$	Vector das funções não lineares que relacionam as medidas com as variáveis de estado
$h_P(.) :$	Vector das funções não lineares que relacionam as medidas activas com as variáveis de estado
$h_Q(.) :$	Vector das funções não lineares que relacionam as medidas reactivas com as variáveis de estado
$H :$	Matriz Jacobiana de h relativamente a x
$\frac{\partial f}{\partial x} :$	Matriz Jacobiana de f relativamente a x
$H_{P\theta} :$	Matriz Jacobiana de h_P relativamente a θ
$H_{PV} :$	Matriz Jacobiana de h_P relativamente a V
$H_{Q\theta} :$	Matriz Jacobiana de h_Q relativamente a θ
$H_{QV} :$	Matriz Jacobiana de h_Q relativamente a V
$G :$	Matriz de ganho (algoritmo de Gauss)
$R :$	Matriz covariância do ruído de medida, $R = \text{diag}(\sigma_i)$
$R_P :$	Matriz covariância do ruído que afecta as medidas activas z_P
$R_Q :$	Matriz covariância do ruído que afecta as medidas reactivas z_Q
$e :$	Vector do ruído total de medida
$v :$	Vector do ruído (normal) de medida
$b :$	Vector dos erros grosseiros de medida
$N :$	Número de barramentos da rede
$m :$	Número total de medidas efectuadas na rede
$m_1 :$	Número total de medidas do tipo P_{ij} e P_i
$m_2 :$	Número total de medidas do tipo Q_{ij} , Q_i e V
$n :$	Número de variáveis de estado do sistema, $n = 2N-1$
$\eta :$	Redundância de medida, $\eta = m / n$
$J(x) :$	Função de custo
$r :$	Vector dos resíduos de medida
$r_N :$	Vector dos resíduos normalizados de medida
$r_W :$	Vector dos resíduos ponderados de medida
$W :$	Matriz sensibilidade dos resíduos aos erros de medida
$\Sigma :$	Matriz covariância do erro de estimação para o vector x

δ_f :	Erro de estimação para f , ou seja das variáveis de estado δ_x e das medidas δ_h
$E[a]$:	Valor esperado de a
$cov(a)$:	Matriz covariância de a
$var(a)$:	Variância de a
$\ a\ $:	Norma do vector a
a_i ou (a_i) :	Elemento i do vector a
$a \sim N(\mu_a, \Sigma_x)$:	Variável aleatória gaussiana (normal) de valor médio μ_a e matriz covariância Σ_x
$a \sim \chi^2$:	Variável aleatória com distribuição qui-quadrado
χ_a^2 :	Valor de uma variável aleatória x com distribuição χ^2 tal que $prob[x \leq \chi_a^2] = a$
$prob[x \leq \lambda]$:	Probabilidade de os valores da variável aleatória x serem inferiores a λ
N_a :	Valor de uma variável aleatória x com distribuição normal reduzida ($x \sim N(0,1)$) tal que $prob[x \leq N_a]$
f_{dp_x} :	Função densidade de probabilidade da variável aleatória x
A^T :	Matriz transposta de A
A^{-1} :	Matriz inversa de A
$r(A)$:	Característica da matriz A
$det A$:	Determinante da matriz A
$diag(a_i)$:	Matriz diagonal cujo termo (i,j) é igual a a_i
I :	Matriz identidade
$O(x)$:	Infinitésimo de ordem superior a x
α :	Probabilidade de incorrer num erro tipo I (teste de hipóteses)
β :	Probabilidade de incorrer num erro tipo II (teste de hipóteses)
δ_m^h :	Erro médio das grandezas medidas. Valor médio da diferença entre as medidas efectuadas e as medidas estimadas.
δ_m^θ :	Erro médio da estimativa de θ .
δ_m^V :	Erro médio da estimativa de V .
Nit :	Número de iterações necessárias à obtenção da convergência
$.(k k-1)$:	Grandeza relativa à etapa de previsão
$.(k k)$:	Grandeza relativa à etapa de filtragem

K :	Matriz de ganho do filtro de Kalman
$\tilde{z}(k k - 1)$:	Vector das inovações, $\tilde{z}(k k - 1) = z(k) - \hat{z}(k k - 1)$
SEE :	Sistema Eléctrico de Energia
WLS :	Método dos mínimos quadrados ponderados
WLAV :	Método dos mínimos valores absolutos ponderados
FDSE :	Estimador de estado desacoplado
IBE :	Metodologia de identificação de erros grosseiros por eliminação
NQC :	Metodologia de identificação de erros grosseiros por critérios não quadráticos
HTI :	Metodologia de identificação de erros grosseiros por teste de hipótese
URT :	Unidade terminal remota
BDS :	Método de supressão de erros grosseiros
CC :	Centro de controlo
EMS :	Sistemas de Gestão de Energia
AGC :	Controlo Automático da Produção
OPF :	Fluxo de potência óptimo
SCADA:	Sistemas de supervisão, controlo e aquisição de dados

CAPÍTULO 1

INTRODUÇÃO

Capítulo 1

INTRODUÇÃO

1.1- DEFINIÇÃO DO PROBLEMA

A elevada complexidade das redes de transporte de energia, aliada à necessidade de uma elevada continuidade de serviço, faz dos estimadores de estado (EE) parte essencial de qualquer Centro de Controlo e Condução (CC). Pedro Zarco e António Gómez Expósito consideram num artigo publicado recentemente [1], a estimação de estado como sendo o órgão vital desses centros de controlo. A optimalidade de qualquer outra função executada nos centros de controlo, tal como a análise de segurança, o despacho económico ou os fluxos de potência óptimos (OPF), está fortemente ligada à precisão dos resultados obtidos pelo estimador de estado.

A função dos CC é monitorizar, controlar e otimizar os Sistemas Eléctricos de Energia (SEE) recorrendo ao uso da cada vez mais avançada tecnologia informática. Para que um CC funcione perfeitamente, é necessário que tenha a cada momento, informação fidedigna sobre o estado da rede que controla. Essa informação é obtida recorrendo aos sistemas SCADA que em conjunto com os estimadores de estado, constroem bases de dados fidedignas que traduzam o estado do sistema eléctrico de energia a controlar.

A estimação de estado recorre a um conjunto redundante de medidas efectuadas na rede e a informação sobre a topologia da mesma, para estimar o real estado do sistema.

Dependendo da qualidade das medidas e do estimador, essa informação é mais ou menos fiável.

Um aspecto importante para que o algoritmo de estimação de estado forneça boas estimativas para as variáveis de estado é a redundância dos seus dados. Com um nível de medidas adequado, consegue-se manter a observabilidade da rede, garantir a qualidade dos resultados e assim a confiabilidade nos mesmos. Uma outra vantagem da redundância dos dados é a possibilidade que se tem de tratar da detecção, identificação e até mesmo da eliminação das medidas afectadas por erros grosseiros.

Da análise do parágrafo anterior, podemos concluir que qualquer processo prático de implementação da função de estimação de estado só terá sucesso se existir um razoável número de medidas que garantam a tão desejada redundância de informação. No entanto, para que haja uma elevada redundância de medidas é necessário na realidade, equipamento para fazer a aquisição e transmissão dos dados. Assim sendo, o aumento da redundância está fortemente ligado ao aumento dos custos investimento.

Como se sabe, o recurso a medidas analógicas efectuadas por aparelhos que estão sujeitos a erros e a sua transmissão para os centros de controlo, tornam o conjunto das medidas exposto a ruídos e erros. Esses erros têm um impacto severo na qualidade da informação disponibilizada pelo estimador de estado [2]. Assim, para que a informação obtida da rede possa ser devidamente processada pelo estimador de estado, terá que ser necessariamente accionada uma rotina de detecção e identificação de possíveis erros grosseiros nos dados.

Poderemos então considerar, que a EE contém aplicações responsáveis pela construção de uma base de dados completa e confiável que será usada em funções de segurança e optimização.

1.2- OBJECTIVO E ESTRUTURA DA DISSERTAÇÃO

O trabalho aqui apresentado está relacionado com o controlo de Sistemas Eléctricos de Energia, cujo principal objectivo é assegurar a condução do sistema dentro de normas de segurança preestabelecidas, sem descuidar as questões económicas e as cada vez mais importantes questões de qualidade de serviço. Para tal, é necessário possuir a cada momento informação fidedigna sobre o verdadeiro estado do sistema.

A informação que chega aos centros de controlo através do sistema de aquisição de dados não é suficiente, nem fiável, para assegurar o conhecimento do estado do sistema. Assim, é função dos algoritmos de estimação de estado o processamento da informação com o objectivo primordial de obtenção em tempo real, de uma base de dados completa, coerente e fiável do SEE.

As cada vez maiores exigências colocadas aos centros de controlo, levam a que os algoritmos clássicos de estimação de estado, actualmente implementados, apresentem algumas dificuldades de resposta. A possibilidade de uso de metodologias de estimação dinâmica acarreta dificuldades a nível de tempos de processamento e recursos computacionais. Metodologias de processamento paralelo e distribuído, bem como a aplicação da lógica fuzzy têm vindo a ser desenvolvidas, de forma a garantir uma cada vez melhor condução da rede por parte dos centros de controlo.

O objectivo desta tese foi desenvolver um algoritmo para estimar o estado de um SEE, com possibilidade de detecção e identificação de erros grosseiros.

O presente trabalho encontra-se desenvolvido por cinco capítulos, sendo esta introdução o primeiro deles.

No segundo capítulo é analisado o problema da estimação de estado de um sistema eléctrico de energia, fazendo-se referência aos métodos normalmente usados na sua análise;

O terceiro capítulo aborda o problema da detecção e identificação de erros grosseiros nas medidas, utilizadas na estimação de estado estática de SEE.

No quarto capítulo são apresentados e analisados os resultados obtidos pelos algoritmos de estimação de estado implementados, de acordo com as diferentes configurações de medidas e tipos de redes usadas para simulação. São também apresentados resultados sobre metodologias de detecção, identificação e correcção de erros grosseiros.

No quinto capítulo são apresentadas conclusões relativas ao trabalho desenvolvido e sugerem-se perspectivas de prosseguimento da investigação nesta área.

Esta dissertação é finalizada com a apresentação de um conjunto de Apêndices com informações complementares.

CAPÍTULO 2

A ESTIMAÇÃO DE ESTADO APLICADA A SISTEMAS ELÉCTRICOS DE ENERGIA

Capítulo 2

A ESTIMAÇÃO DE ESTADO APLICADA A SISTEMAS ELÉCTRICOS DE ENERGIA

2.1- INTRODUÇÃO

Com o objectivo de melhorar a qualidade de serviço e pelas cada vez mais importantes questões de carácter económico, assiste-se actualmente a uma rápida evolução ao nível do controlo e operação das redes de transporte de energia, bem como à interligação de pequenas rede isoladas, formando assim redes de maior dimensão.

Fazendo uso de recursos computacionais cada vez mais avançados, foi possível instalar nos centros de controlo e condução (CC), sistemas de supervisão, controlo e aquisição de dados vulgarmente conhecidos pela sigla SCADA ("Supervisory Control and Data Acquisition"), que para além de fornecerem ao operador algumas informações sobre a rede supervisionada, incorporavam algumas funções específicas como por exemplo, o controlo automático da produção (AGC), o controlo de frequência e o despacho económico. A introdução de um número cada vez maior de funções nos sistemas SCADA fez, com que se evoluísse para os modernos EMS ou Sistemas de Gestão de Energia.

A função do Estimador de Estado, que é uma parte integrante dos referidos EMS, é a monitorização da rede no pressuposto de que as variações de carga e produção são feitas

lentamente, podendo assim ser modelizada como uma rede em regime de funcionamento quase estático.

A informação resultante do estimador de estado, permite ao operador do sistema ter, com alguma precisão, informações sobre o valor complexo das tensões em todos os barramentos da rede, conhecer os trânsitos de potências activas e reactivas em todas linhas, as potências geradas nos diferentes barramentos bem como todo um conjunto de informação relevante para o controlo dos sistemas eléctricos de energia.

Os resultados da estimação de estado podem ser usados *off-line*, no treino dos operadores para a realização de acções de controlo aquando da ocorrência de situações anómalas, pois permitem simular aproximadamente cenários reais de funcionamento. Uma outra aplicação é permitir a elaboração de estudos sobre a precisão e localização dos aparelhos de medida a colocar na rede, bem como a comparação de diferentes configurações de medida que possibilitam uma melhoria substancial das características de detecção e identificação de erros grosseiros.

O uso *on line* das informações obtidas pela estimação de estado permitem, a criação de bases de dados fiáveis e imprescindíveis à correcta operação de qualquer Sistema Eléctrico de Energia (SEE). Recorrendo a estas bases de dados, o sistema pode fornecer ao operador da rede informações sobre:

- análise de contingências,
- as reservas de produção e estimativas das potências nas linhas;
- defeitos do sistema e a sua possível localização;
- análise de segurança.

A grande vantagem da estimação de estado é permitir obter uma base de dados coerente e fiável de todo o sistema, recorrendo a um conjunto redundante de medidas, obtidas fundamentalmente a partir da rede por teletransmissão. Basicamente, essas medidas são:

- os módulos das tensões efectuadas em determinados barramentos;
- as potências activas e reactivas injectadas;

- os fluxos de potência nas linhas.

Essas bases de dados não podem ser criadas directamente pelas teletransmissões das grandezas medidas que chegam aos centros de controlo, porque:

- Não é viável efectuar a medição de todas as grandezas da rede uma vez que algumas das medições estão limitadas devido a questões técnicas (ex. as fases das tensões) e porque também o custo inerente à aquisição de equipamento é considerável;
- As medidas teletransmitidas ao centro de controlo contêm ruído introduzido pela cadeia de transmissão e por isso não podem ser consideradas coerentes;
- As medidas recolhidas podem não ser totalmente fiáveis porque existe o risco de terem sido efectuadas por aparelhos em funcionamento defeituoso.

A figura seguinte, demonstra de uma forma simplificada, o conceito de EE.




Figura 2.1 – Conceito de Estimação de Estado (EE).

É sobre o sistema eléctrico real, que está a ser estudado e do qual não se conhecem todas as informações, que o operador do sistema terá que actuar. As acções de controlo tomadas, terão que ser as mais indicadas para cada situação, pois como se está a actuar a um nível primário da cadeia de energia, uma acção de controlo mal executada ao nível da rede de transporte, pode deixar sem fornecimento de energia milhares de consumidores, ou provocar reacções da rede a jusante difíceis de controlar.

Como não existe informação sobre toda a rede e alguma da informação existente pode estar contaminada por perturbações, é criado um vector de incógnitas do sistema (variáveis de estado do sistema) que é formado pelos módulos e fases das tensões de todos os barramentos da rede, com excepção do barramento de referência sobre o qual se estipula que a fase da tensão é de zero radianos. As medidas efectuadas na rede são funções não lineares das variáveis de estado o que conduzirá à necessidade de uma posterior linearização das equações de medida. A função do estimador é relacionar toda a informação disponível e obter uma estimativa de todas as variáveis de estado do sistema. Com esta informação e atendendo ao modelo matemático que caracteriza a rede, é fácil obter outras informações relevantes.

De uma forma geral, a estrutura de um algoritmo de estimação de estado estática é composto por quatro blocos fundamentais, tal como ilustra a figura 2.2, sendo eles:

- Pré-filtragem;
- Análise de observabilidade;
- Filtragem;
- Detecção de anomalias.

Durante a etapa da pré-filtragem o algoritmo de estimação de estado deverá actuar de forma a assegurar a coerência das medidas. No caso de serem detectados erros grosseiros nas medidas, elas deverão ser eliminadas.

De seguida será executada uma análise de observabilidade da rede, com o objectivo de assegurar que é possível a obtenção de uma primeira estimativa do estado do sistema como um todo. Caso a rede seja não observável, é possível recorrer a pseudomedidas.

A etapa de filtragem tem como objectivo a determinação, baseada na informação disponível, de uma solução para o vector de estado do sistema.

Por último, na fase da detecção de anomalias, serão executados testes (normalmente estatísticos) para avaliar a existência ou não, de erros grosseiros nas medidas. Em caso afirmativo, elas terão que ser identificadas e corrigidas.




Figura 2.2 - Esquema básico de um estimador de estado estático.

2.1.1 Sistemas de Supervisão e Controlo

O desempenho dos actuais sistemas de energia eléctrica está altamente dependente do desempenho dos Centros de Controlo e Condução pelo que eles assumem uma importância ímpar para a qualidade de serviço [3]. A eficiência destes centros só é possível se existirem sistemas capazes de fornecerem informações rápidas e fidedignas sobre a rede. Os sistemas SCADA assumem um papel essencial nos sistemas de supervisão e controlo das redes eléctricas [4].

Os dados que caracterizam um determinado estado de funcionamento do sistema de energia são fornecidos ao CC em tempo real através de um sistema SCADA [5]. A aquisição e transmissão dos dados é feita de forma cíclica adquirindo bastante importância o tempo que o sistema SCADA demora a fazer um ciclo de aquisição de medidas.

Um sistema SCADA na sua forma mais simples é constituído apenas por uma unidade central e por uma unidade remota terminal (URT). No entanto, quando se aplica este tipo de sistemas às redes eléctricas de energia, devemos considerar um sistema SCADA de maior dimensão, composto por mais do que uma unidade central e por muitas unidades remotas. As URT deverão ser colocadas nas centrais e subestações com o objectivo de obter a informação e codificá-la de forma a poder ser transmitida ao CC. As URT deverão também ter a capacidade de receber e processar as ordens enviadas pela unidade central. Um outro equipamento constituinte de um sistema SCADA e que assume um papel preponderante, é o sistema de comunicação. A transmissão dos dados deverá ser possível nos dois sentidos ($CC \rightarrow URT$, $URT \rightarrow CC$) sendo a velocidade de transmissão um aspecto importante pois dela depende o ciclo de tempo de um sistema SCADA. Existem várias tecnologias de comunicação implementadas, das quais se destacam as seguintes:

- ❑ Linhas telefónicas;
- ❑ Transmissão por correntes portadoras;
- ❑ Transmissão por feixes hertzianos;
- ❑ Transmissão por fibras ópticas.

Qualquer que seja o canal de transmissão implementado, ele terá que garantir a fiabilidade da transmissão dos dados.

2.2 MODELIZAÇÃO DA REDE

2.2.1 – Introdução

A principal função de um algoritmo de estimação de estado é a obtenção de uma estimativa fiável, $(\hat{x})$, do verdadeiro estado do sistema (x), por forma a tornar mais eficientes as acções de controlo. Para que esse objectivo seja atingido, o estimador de estado usa numerosos tipos de informações existentes nos centros de controlo.

A figura seguinte pretende representar a estrutura utilizada para simular o modo de funcionamento de um estimador de estado estático.




Figura. 2.3 Funcionamento do estimador de estado estático.

Como se pode verificar, a informação sobre o estado do sistema eléctrico em análise, sobre as medidas efectuadas bem como sobre o ruído a que essas medidas estão sujeitas, servem de entrada ao estimador de estado.

O algoritmo de estimação de estado permite obter, após processamento da informação disponível, o vector de estado estimado do sistema, que fornece o valor estimado das tensões, em módulo e fase, nos diferentes barramentos.

Adoptando a formulação em coordenadas polares, podemos definir os vários vectores usados pelo estimador de estado. O vector das variáveis de estado, x , é formado pelas fases e módulos da tensão de todos os barramentos, com excepção da fase do barramento de referência que é considerada nula. Por conveniência da representação dos vectores, iremos considerar o barramento 1 como sendo o barramento de referência de um sistema de N barramentos. Assim,

$$x^T = [\theta_2, \theta_3, \dots, \theta_N, V_1, V_2, \dots, V_N] \quad (2.1)$$

com:

$$E_i = V_i \angle \theta_i, \quad \dim(x) = 2N - 1 = n$$

Como o vector de estado não é directamente acessível, uma estimativa para “ x ” é obtida usando para tal o vector das medidas z , de dimensão m e representado da seguinte forma:

$$z^T = [P_i, \dots, Q_i, \dots, P_{ij}, \dots, Q_{ij}, \dots, V_i, \dots] \quad (2.2)$$

em que:

- P_i - representa a potência activa injectada nos barramentos;
- Q_i - representa a potência reactiva injectada nos barramentos;
- P_{ij} - representa os fluxos de potências activa nas linhas;
- Q_{ij} - representa os fluxos de potências reactiva nas linhas;
- V_i - representa os módulos de tensão nos barramentos.

Estas medidas podem exprimir-se em função do vector de estado através da seguinte equação não linear:

$$z = h(x) + e \quad (2.3)$$

em que:

$h(x)$ – representa o vector das funções não lineares que relacionam o verdadeiro estado do sistema com os valores “ideais” das medidas, a partir da matriz das admitâncias da rede.

x – vector de estado do sistema, com dimensões n .

e – vector de variáveis aleatórias que representam o erro das medidas.

Para caracterizar uma dada configuração de medida, em relação a um maior ou menor número de medidas consideradas, é habitual definir o valor da redundância de medida (η) como:

$$\eta = \frac{m}{n} \quad (2.4)$$

isto é, o quociente entre o número de medidas utilizadas pelo estimador (m) e o número de variáveis de estado (n). É normal η assumir valores no intervalo entre $1,5 < \eta < 2,5$. A possibilidade de se usar redundâncias superiores a 1 permite que se faça uma filtragem do ruído de medida [6].

2.2.2 – Modelo de representação das linhas e transformadores.

Nos SEE, a interligação entre barramentos é efectuada por linhas ou por transformadores. Como estes elementos são parte integrante de qualquer rede, é necessário modelizá-los matematicamente. As figuras seguintes representam os equivalentes matemáticos desses elementos.




Figura.2.4 - Equivalente em π de uma linha

O parâmetro y_{ij} , representa a admitância da linha e $y_{ij,0}$ modeliza metade da susceptância shunt da linha que liga o barramento ‘i’ ao barramento ‘j’.




Figura 2.5 - Modelo matemático equivalente de um transformador.

Quando se pretende representar um transformador com razão de transformação “ a_{ij} ”, y_{ij} representa a admitância nominal do transformador dividida pela razão de transformação. Em série com y_{ij} está representado um transformador ideal.

2.3- PRECISÃO DAS MEDIDAS

A precisão (σ_i) das diferentes medidas obtidas ao longo do SEE, é afectada pelos diversos componentes do sistema de aquisição e transmissão de informação. Apesar de existirem melhorias substanciais em termos de precisão dos aparelhos que constituem esses sistemas, isso também se traduz, na maioria dos casos, num acréscimo do investimento, continuando a existir nos referidos sistemas de aquisição e transmissão de dados, aparelhos com diferentes precisões. A Figura 2.6 representa os elementos constituintes de uma cadeia de medida clássica, susceptíveis de influenciar os dados que são recebidos no centro de controlo, nomeadamente:

- os transformadores de intensidade (TI) e de tensão (TP);
- os conversores de potência: recebem a corrente e a tensão alternadas provenientes dos TI e TP e fornecem uma corrente contínua de reduzida amplitude, proporcional à potência activa (reactiva) correspondente;

- os conversores analógico / digital;
- os meios de transmissão da informação digital.

No final, cada medida que chega ao centro de controlo é afectada por um erro que é dependente do erro individual de cada elemento da cadeia de medida.




Figura 2.6 – Cadeia de transmissão de medidas

Para que a estimação de estado seja credível, terá que contemplar a existência destes erros na informação a processar. Para tal é atribuído um peso ($w_i = 1/\sigma_i$) às medidas recebidas no centro de controlo, que depende da classe de precisão dos diferentes aparelhos usados no processo de medição e teletransmissão dos dados. Como seria de esperar, aparelhos com maior classe de precisão terão que ter um peso maior no processo de estimação tendo por isso um σ_i mais pequeno (na ordem dos 0,001), é o caso das medidas de tensão. Às medidas obtidas por aparelhos menos precisos, caso das medidas de potência, é lhes atribuído um menor peso no processo de estimação.

A totalidade das diferentes fontes de erro existentes deveriam ser modelizadas e obtida a composição das correspondentes distribuições de probabilidade. Como esta modelização é de enorme dificuldade [7], é normal introduzir algumas hipóteses simplificativas.

Assim, considera-se que a generalidade das componentes do erro total em análise, podem ser modelizadas como variáveis aleatórias gaussianas independentes. O erro total será também uma variável aleatória gaussiana cuja média (variância) é a soma das médias (variâncias) das componentes. Note-se que se um ruído de medida apresenta uma média não nula, esse valor médio deve ser calculado e subtraído sistematicamente ao valor obtido para a medida correspondente.

Na prática, pequenas variações dos valores atribuídos a σ_i , não afectam significativamente a qualidade da estimativa obtida [8], no entanto, deve salientar-se que:

- se o desvio padrão atribuído for nitidamente inferior ao verdadeiro valor, então irá ser atribuído um peso excessivamente elevado à medida correspondente, o que resulta numa diminuição da precisão da estimativa obtida. Além disso, na fase de detecção de erros grosseiros essa medida poderá ser indevidamente seleccionada.
- se o desvio padrão (σ_i) atribuído a um erro de medida for nitidamente superior ao respectivo verdadeiro valor, a medida correspondente é rejeitada “numericamente”, podendo por isso diminuir a precisão da estimação obtida em zonas de reduzida redundância local;

As expressões habitualmente usadas no cálculo do desvio padrão para os diferentes tipos de medidas são as seguintes:

Medidas de Potência

$$\sigma = k_1 \cdot |S| + k_2 \cdot F_S \quad (2.5)$$

em que $|S| = \sqrt{P^2 + Q^2}$ representa o verdadeiro valor da potência aparente. Na prática este valor não é conhecido e é substituído pelo valor medido de P e Q . A constante F_S representa o valor de fim de escala do aparelho correspondente. Os valores atribuídos a k_1 e

k_2 dependem das características da cadeia de medida. Os valores habitualmente considerados e referidos na literatura costumam ser $k_1 = 0,012$ e $k_2 = 0,0035$.

Outra expressão usada para o cálculo do desvio padrão é a seguinte:

$$\sigma = k_3.F_S \quad (2.6)$$

em que F_S tem o mesmo significado que na equação anterior. Esta fórmula pode assumir outro aspecto, obtendo-se σ como função da potência nominal da aparelhagem correspondente (S_N) e da respectiva classe de precisão (c). Considere-se fixado o máximo valor possível para a amplitude do erro de medida:

$$e_{\max} = c.F_S \quad (2.7)$$

em que o valor de F_S é ligeiramente superior a S_N , por exemplo:

$$F_S = k S_N \quad \text{com} \quad 1 < k < 1,2 \quad (2.8)$$

Atendendo a que se admite o erro de medida gaussiano, pode considerar-se que o seu valor absoluto máximo $e_{\max}$ é três vezes superior ao respectivo desvio padrão, e assim:

$$\sigma = \frac{c.k.S_N}{3} \quad (2.9)$$

Medidas de tensão

$$\sigma = k_4 V_{NOM} \quad (2.10)$$

em que V_{NOM} é a tensão nominal do barramento considerado. Habitualmente, o valor atribuído a k_4 é 0,002.

Relativamente às pseudomedidas, os correspondentes valores do desvio padrão (σ) dependem ainda dos modelos adoptados para as cargas, das previsões utilizadas, etc., podendo por isso tomar valores bastante superiores.

2.4 - MEDIDAS E EQUAÇÕES DE MEDIDA

2.4.1 Introdução


Como foi referido anteriormente, para que se possa usar o estimador de estado, é necessário à priori, possuir um conjunto de informações sobre a rede. Essas informações passam, essencialmente, pela obtenção de um conjunto redundante de medidas obtidas da rede, pelo conhecimento rigoroso dos parâmetros da mesma, e fundamentalmente da sua topologia. O conjunto das medidas analógicas e lógicas é usado pelo algoritmo de estimação de estado por forma a obter uma estimativa fiável do estado do sistema [9].

Na estimação de estado, o vector das medidas é composto por medidas dos módulos das tensões, por trânsitos de potência activa e reactiva nas linhas, por potências activas e reactivas injectadas em certos barramentos e eventualmente nalguns casos por medidas de correntes nas linhas. Como as equações de medidas são funções não lineares do vector de estado, é necessário linearizá-las em torno de um ponto inicial, sendo a solução final obtida através de um processamento iterativo. Um outro aspecto importante é definir a configuração de medidas e avaliar se as medidas disponíveis são suficientes para garantir a observabilidade da rede. Uma escolha adequada do conjunto de medidas introduz melhorias ao nível da detecção e identificação de erros grosseiros. Existem publicadas algumas soluções desenvolvidas para resolução deste problema [10, 11, 12].

As medidas usadas no processo de estimação de estado da rede são, como seria de esperar, afectadas por erros. No entanto, o uso de modernos processos de sincronização via satélite recorrendo ao uso do GPS, fez com que o vector de medidas alcançasse uma precisão tal, que o torna uma fonte valiosa de informação [13].

2.4.2 Tipos de medidas

Os centros de controlo deverão ter nas suas bases de dados, as medidas recolhidas da rede num dado instante. Essas medidas podem ser classificadas em diversas categorias, como se demonstra no esquema seguinte.



As medidas analógicas englobam os valores registados para os módulos de tensão, trânsitos de potência activa e reactiva e potências activas e reactivas injectadas. Este tipo de medidas pode ainda ser dividido em três subtipos:

- Medidas em tempo real: são medidas efectuadas ciclicamente em vários pontos da rede e transmitidas ao centro de controlo;
- Pseudomedidas: são valores que à priori, e com alguma precisão, podemos atribuir a certas variáveis do sistema. Estes valores poderão ser obtidos recorrendo aos registos históricos dessas variáveis, a previsões de carga a curto prazo ou até mesmo à experiência do operador;
- Medidas virtuais: correspondem às potências injectadas (de valor nulo) em barramentos sem geração e sem carga. Estas medidas estão disponíveis sem qualquer custo em equipamentos de medida ou transmissão, não estando assim sujeitas aos erros introduzidos por esses equipamentos.

As medidas lógicas englobam a informação relativa ao estado de interruptores e disjuntores (aberto/fechado). Estas medidas são utilizadas pelo processador de topologia para determinar a configuração da rede.

2.4.3 Equações de medida

De acordo com o modelo adoptado, as equações de medida usadas para efectuar a estimação de estado, são as seguintes:

a) Fluxos de potência nas linhas,

$$P_{ij} = -V_i^2 G_{ij} a_{ij} + V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.11)$$

$$Q_{ij} = V_i^2 (B_{ij} a_{ij} - y_{ij,0}) + V_i V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2.12)$$

b) Potências injectadas nos barramentos,

$$P_i = V_i \sum_{j=1}^N V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2.13)$$

$$Q_i = V_i \sum_{j=1}^N V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (2.14)$$

em que:

$Y_{ij} = G_{ij} + jB_{ij} = -y_{ij}$: elemento ij da matriz das admitâncias da rede;

$y_{ij,0} = j y_{ij,0}$

$\theta_{ij} = \theta_i - \theta_j$: representa a diferença entre as fases das tensões dos barramentos i e j .

c) Medidas de tensão.

Estas medidas exprimem-se directamente em função do elemento correspondente do vector de estado, isto é, $h_k(x) = x_j$.

2.5- ALGORITMOS DE ESTIMAÇÃO DE ESTADO

2.5.1. Estimação de estado estática

2.5.1.1 Aproximação Clássica - Algoritmo Base

A aproximação clássica mais usada na resolução de problemas de estimação de estado é baseada no método dos mínimos quadrados ponderados (WLS), em que os diferentes tipos de medidas usados, são diferenciados através da atribuição de pesos, de acordo com o grau de confiança correspondente.

Considerando z , de dimensão $(m \times 1)$, como sendo o vector que contém o conjunto das medidas, x o vector das variáveis de estado $(n \times 1)$, h o vector que representa a relação matemática entre as medidas e as variáveis de estado $(m \times n)$ e e , o vector dos erros (ruído) de medida $(m \times 1)$, temos:

$$z = h(x) + e \quad (2.15)$$

O vector do ruído (e) é normalmente modelizado estatisticamente da seguinte forma:

$$e \sim N(0, R) \quad \text{com} \quad R = \text{diag}(\sigma_i^2) \quad (2.16)$$

em que σ_i representa o desvio padrão do ruído da medida i . A matriz covariância R é diagonal porque se admitirá que as componentes de e são não correlacionadas. De salientar que o vector e , simula apenas, a presença de ruído nas medidas. Não representa a presença de erros grosseiros.

A obtenção da estimativa para o vector de estado do sistema, pelo método WLS (mínimos quadrados ponderados), consiste na determinação de um vector $x = \hat{x}$ que minimize a seguinte função objectivo:

$$J(x) = [z - h(x)]^T R^{-1} [z - h(x)] \quad (2.17)$$

Essa estimativa deve necessariamente satisfazer o seguinte sistema de n equações não lineares:

$$\left. \frac{\partial J(x)}{\partial x} \right|_{x=\hat{x}} = -2H^T(\hat{x}) R^{-1} [z - h(\hat{x})] = 0 \quad (2.18)$$

em que $H(\hat{x})$ é a matriz jacobiana de $h(x)$ avaliada para $x = \hat{x}$, isto é:

$$H(\hat{x}) = \left. \frac{\partial h(x)}{\partial x} \right|_{x=\hat{x}} \quad e \quad H_{ij} = \frac{\partial h_i}{\partial x_j} \quad i = 1, \dots, m; \quad j = 1, \dots, n \quad (2.19)$$

Devido à não linearidade do vector das equações das medidas $h(x)$, a solução do sistema de equações (2.18) será obtida por recurso a um processo iterativo [14]. A equação geral deste processo iterativo é a seguinte:

$$G(k)[x(k+1) - x(k)] = H^T[x(k)] R^{-1} [z - h(x(k))] \quad k = 0, 1, 2, \dots \quad (2.20)$$

em que $x(0)$ é a estimativa inicial para arranque do processo iterativo, k indica o número da iteração e G é a matriz de ganho, seleccionada de modo a assegurar uma boa convergência do processo. Seja:

$$g[x(k)] = H^T[x(k)] R^{-1} [z - h(x(k))] \quad (2.21)$$

então, se o processo iterativo definido em (2.20) convergir pode-se concluir que:

$$\lim_{k \rightarrow \infty} g[x(k)] = 0 \quad (2.22)$$

e portanto que a solução procurada foi efectivamente encontrada.

A selecção da matriz de ganho $G(k)$ deve ser feita atendendo aos seguintes aspectos:

- $G(k)$ deve não ser singular para todo o k , permitindo a determinação de uma solução para o sistema de equações lineares (2.20), em cada iteração.
- A escolha da matriz G influencia o número de iterações necessárias à convergência mas não a solução obtida (admitindo que o processo iterativo converge). A situação altera-se, porém, se forem também introduzidas modificações na expressão de $g(x)$, e neste caso a solução obtida poderá ser efectivamente diferente.

Na literatura encontram-se referências a diferentes métodos que se baseiam na selecção de distintas matrizes de ganho [15], como por exemplo:

a) Método do Gradiente

$$G(k) = \alpha(k)I, \quad \alpha(k) > 0 \quad (2.23)$$

b) Método de Newton

$$G(k) = \frac{1}{2} \frac{\partial^2 J(x)}{\partial x^2} \Big|_{x=x(k)} \quad (2.24)$$

sendo a matriz hessiana de $J(x)$, $\frac{\partial^2 J(x)}{\partial x^2}$, dada por:

$$\frac{\partial^2 J(x)}{\partial x^2} = 2 \left[H^T(x) R^{-1} H(x) - \sum_{i=1}^m \left[\frac{\partial^2 h_i(x)}{\partial x^2} \right] R_{ii}^{-1} [z_i - h_i(x)] \right] \quad (2.25)$$

c) Método de Gauss

$$G(k) = H^T(x) R^{-1} H(x) \big|_{x=x(k)} \quad (2.26)$$

este método resulta numa simplificação do método de Newton, considerando para efeito de avaliação de $\frac{\partial^2 J(x)}{\partial x^2}$, que a matriz H é independente de x .

Obtém-se então o seguinte processo iterativo:

$$H^T[x(k)] R^{-1} H[x(k)] \cdot [x(k+1) - x(k)] = H^T[x(k)] R^{-1} [z - h(x(k))] \quad k=0, 1, 2, \dots \quad (2.27)$$

A experiência adquirida na estimação de estado de SEE permite afirmar que o algoritmo de Gauss, proposto inicialmente por Schweppe [14], se adapta bem ao problema a resolver. Na Figura 2.7 apresenta-se um fluxograma do método de Gauss para minimização de $J(x)$ [16].




Figura 2.7 – Estimação de Estado pelo método de Gauss

O algoritmo apresentado possui algumas características importantes, entre as quais se salientam a robustez, porque de um modo geral este algoritmo converge para diferentes situações de carga e para diferentes configurações de medidas e configurações da rede [16]; a forte relação entre a matriz de ganho e a matriz covariância da estimação, o que permite tirar partido do esforço de cálculo relativo à resolução das equações de estimação, para posterior análise da qualidade da estimativa obtida e tratamento dos erros grosseiros e a rapidez de cálculo em comparação com o método de Newton, pois não é necessário proceder ao cálculo das diferentes matrizes hessianas, $\left[\frac{\partial^2 h_i}{\partial x^2} \right]$;

A introdução de determinadas simplificações permitirá desenvolver algumas variantes ao algoritmo de Gauss, visando uma redução do tempo de processamento e da ocupação de memória.

Solução Inicial

Os valores de inicialização das tensões que determinam o arranque do processo iterativo apresentado no algoritmo da Figura 2.7, exige a definição da estimativa inicial $x(0)$ do vector de estado do sistema. No caso de uma solicitação repetitiva do estimador de estado, o vector $x(0)$ poderá ser escolhido num dado instante, de dois modos distintos:

1. se não tiver havido alterações significativas no estado da rede desde a última vez que o programa de estimação de estado foi executado, a solução obtida nesse momento será a escolha adequada para $x(0)$. Os estimadores estáticos que utilizam este método designam-se por “estimadores seguidores”.
2. se o estimador estiver numa fase de inicialização, ou se tiver ocorrido uma alteração importante da topologia da rede, a estimativa inicial $x(0)$ corresponderá ao ponto de funcionamento nominal (isto é, $|V| = 1$ p.u. e $\theta = 0$ rad. para todos os barramentos).

Critério de paragem

Relativamente ao critério de paragem do processo iterativo, é normal encontrar três tipos de soluções diferentes:

1. Critério baseado nas variações sucessivas de x

$$\max_i |\theta_i(k) - \theta_i(k-1)| < \varepsilon_\theta \quad i = 1, \dots, N-1 \quad (2.28)$$

$$\max_i |V_i(k) - V_i(k-1)| < \varepsilon_V \quad i = 1, \dots, N \quad (2.29)$$

2. Critério baseado nas variações sucessivas de J

$$|J(x(k)) - J(x(k-1))| < \varepsilon_J \quad (2.30)$$

3. Critério baseado na anulação do gradiente de J

$$\max_i |g_i(x(k))| < \varepsilon_g \quad i = 1, \dots, n \quad (2.31)$$

O critério mais frequentemente utilizado na estimação de estado dos SEE, é o baseado nas variações sucessivas de x (Figura 2.7) e, como tal, será o critério adoptado nesta dissertação.

2.5.1.2 Método das Equações Normais com restrições.

Um dos tipos de medidas que podem ser usados na estimação de estado dos SEE, são as medidas virtuais (potências injectadas de valor nulo em barramentos sem geração e sem carga). Como não estão afectadas por erros de medida, podem ser incorporadas no processo de estimação sendo-lhes atribuído um peso elevado (assume-se que elas são bastante precisas). No entanto, a presença de medidas com um peso tão elevado, leva a problemas de

convergência do processo. Efectivamente, se dividir-mos o vector das medidas em duas partes, telemedidas ($z = h(x) + e$) e medidas virtuais ($c(x)=0$), a matriz jacobiana terá também que ser dividida em duas submatrizes, H e C .

Assim, a equação $G(x) \Delta x = H^T(x)W\Delta z$, é transformada em

$$[H^T H + rC^T C] \Delta x = H^T \Delta z + rC^T \Delta c \quad (2.32)$$

em que r representa a relação entre o peso atribuído às medidas virtuais e às telemedidas. Quando os valores de r são muito elevados o termo $rC^T C$ da matriz dos coeficientes domina, o que causa problemas de convergência devido à singularidade da matriz.

Uma forma de ultrapassar este problema é separar as medidas virtuais das outras medidas, e tratá-las como restrições de igualdade [17].

Então, a função objectivo é:

$$\min J(x) = [z-h(x)]^T W[z-h(x)], \quad (2.33)$$

sujeita à restrição de igualdade, $c(x)=0$

Para resolver o problema de minimização com restrições pode ser usado o método dos multiplicadores de Lagrange, sendo o vector de estado estimado ($\hat{x}$) obtido por um processo iterativo, que resolve a seguinte equação linear:

$$\begin{bmatrix} H^T(x)WH(x) & C^T(x) \\ C(x) & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ \lambda \end{bmatrix} = \begin{bmatrix} H^T(x)W\Delta z \\ \Delta c \end{bmatrix} \quad (2.34)$$

em que $\Delta z = z - h(x)$,
 $\Delta c = -c(x)$ e
 $x = x^i$ para a i -ésima iteração.

2.5.1.3 Método de HACHTEL (matriz aumentada)

O problema de minimização com restrições equacionado no ponto anterior, pode ser resolvido recorrendo ao método de Hachtel [17], que em cada iteração resolve a seguinte equação:

$$\begin{bmatrix} 0 & 0 & C \\ 0 & \alpha W^{-1} & H \\ C^T & H^T & 0 \end{bmatrix} \begin{bmatrix} -\alpha^{-1} \lambda \\ \alpha^{-1} W \Delta r \\ \Delta x \end{bmatrix} = \begin{bmatrix} \Delta c \\ \Delta z \\ 0 \end{bmatrix} \quad (2.35)$$

em que H e C são as matrizes jacobianas obtidas a partir de:

$$H = \frac{\partial h}{\partial x}(x) \quad \text{e} \quad C = \frac{\partial c}{\partial x}(x) \quad (2.36)$$

$\Delta z = z - h(x)$, $\Delta c = -c(x)$, $\Delta r = \Delta z - H \Delta x$, α é um parâmetro usado para controlar a estabilidade numérica do problema [18] e λ é o multiplicador de Lagrange.

A matriz $\begin{bmatrix} 0 & 0 & C \\ 0 & \alpha W^{-1} & H \\ C^T & H^T & 0 \end{bmatrix}$, representa a matriz dos coeficientes aumentada.

A cada iteração as variáveis a calcular são $\lambda' = -\alpha^{-1} \lambda$, $\Delta r' = \alpha^{-1} W \Delta r$ e Δx .

2.5.1.4 Método de factorização ortogonal

O objectivo do método dos mínimos quadrados ponderados linear [17] é, em cada iteração, minimizar a seguinte equação:

$$\begin{aligned} J(\Delta x) &= [\Delta z - H \Delta x]^T W [\Delta z - H \Delta x] \\ &= [\Delta \tilde{z} - \tilde{H} \Delta x]^T [\Delta \tilde{z} - \tilde{H} \Delta x] \end{aligned} \quad (2.37)$$

$$= || \Delta \tilde{z} - \tilde{H} \Delta x ||^2$$

considerando $\tilde{H} = \sqrt{W}H$ e $\Delta \tilde{z} = \sqrt{W}\Delta z$.

Seja Q uma matriz ortogonal, isto é $Q^T Q = I$, então $Q\tilde{H} = \begin{bmatrix} R \\ 0 \end{bmatrix}$, em que R é uma matriz triangular superior. Então a função objectivo fica:

$$\begin{aligned} J(\Delta x) &= [\Delta \tilde{z} - \tilde{H} \Delta x]^T Q^T Q [\Delta \tilde{z} - \tilde{H} \Delta x] \\ &= || Q\Delta \tilde{z} - Q\tilde{H} \Delta x ||^2 \\ &= || \Delta y_1 - R\Delta x ||^2 + || \Delta y_2 ||^2 \end{aligned} \quad (2.38)$$

em que $Q\Delta \tilde{z} = \begin{bmatrix} \Delta y_1 \\ \Delta y_2 \end{bmatrix}$.

O valor mínimo da função objectivo ocorre quando $R\Delta x = \Delta y_1$.

2.5.1.5 Método de Peter Wilkinson

Este método foi aplicado à estimação de estado dos SEE na década de 80 por Gu, Clements, Krumpholtz e Davis, referência [19]. Este método executa uma minimização por mínimos quadrados num problema que resulta numa transformação do problema inicial. Esta transformação consiste na factorização da matriz $A = W^{-1/2}H(x)$ em duas matrizes L e U , em que L ($m \times n$) é uma matriz trapezoidal inferior e U ($m \times n$) é uma matriz triangular superior, não singular.

$$A = W^{-1/2}H(x) = LU \quad (2.39)$$

Fazendo $y = Ux$, o problema da estimação de estado é solucionado resolvendo o problema dos mínimos quadrados cuja função objectivo é:

$$\begin{aligned} \min \quad & r^T r \\ \text{sujeito a:} \quad & r = Ly - W^{-1/2} z \end{aligned}$$

Para determinar y , devemos resolver a equação seguinte:

$$(L^T L)y = L^T W^{-1/2} z \quad (2.40)$$

A solução do problema original é finalmente obtida resolvendo o sistema de equações $y=Ux$ em que U é triangular superior.

Na abordagem de Clements, Woodzell e Buckhett [20] a factorização da matriz A , necessária à aplicação deste método à estimação de estado dos SEE, é obtida pela expressão seguinte.

$$A = \begin{bmatrix} C(x) \\ W^{-1/2} H(x) \end{bmatrix} = \begin{bmatrix} L_{11} & 0 \\ L_{21} & L_{22} \end{bmatrix} U \quad (2.41)$$

A resolução do problema original baseia-se no seguinte procedimento sequencial:

$$L_{11}w = 0 \quad (2.42)$$

$$L_{22}^T L_{22} y = L_{22}^T W^{-1/2} z \quad (2.43)$$

$$Ux = \begin{bmatrix} w \\ y \end{bmatrix} \quad (2.44)$$

2.5.1.6 WLAV

O método WLAV (Weighted Sum of the Absolute Value) é habitualmente formulado do seguinte modo:

$$\min J(x) = \sum_{i=1}^m w_i |r_i| \quad (2.45)$$

sujeito a

$$z = h(x) + r \quad (2.46)$$

em que z representa o vector das medidas com dimensão $m \times 1$, x é o vector das variáveis de estado e tem dimensão $n \times 1$ e h é o vector das equações não lineares que relacionam as medidas com as variáveis de estado, com dimensão $m \times 1$. O peso atribuído a cada medida depende da precisão da mesma. Tal como em outros métodos, atribui-se um peso maior às medidas mais precisas. O significado de m e n mantém-se o mesmo que tem sido atribuído ao longo deste capítulo.

Uma aproximação de primeira ordem à equação (2.46) em torno do ponto de funcionamento x^0 , é dado por:

$$\Delta z = H(x^0) \Delta x + r \quad (2.47)$$

em que

$$\Delta z = z - h(x^0),$$

$$\Delta x = x - x^0$$

$$H(x^0) = \frac{\partial h(x^0)}{\partial x}$$

e portanto $r = \Delta z - H(x^0) \Delta x$

A minimização de $J(x)$ é obtida resolvendo uma sequência de problemas de programação linear, através de sucessivas linearizações de $h(x)$, introduzindo variáveis de folga [21].

Assim, a formulação final será:

$$\min J^k = \sum_{i=1}^m w_i (s_{2i-1} - s_{2i}) \quad (2.48)$$

sujeito a

$$\begin{bmatrix} H(x^k) \\ U \end{bmatrix} \begin{bmatrix} (\Delta x^k) \\ s \end{bmatrix} = \begin{bmatrix} \Delta z^k \end{bmatrix}, \quad \text{com } (\Delta x)^k, s \geq 0 \quad (2.49)$$

em que k é o índice da sequência, s é o vector das variáveis de folga e tem dimensão $2m \times 1$, $r_i = s_{2i-1} - s_{2i}$ ($i=1, \dots, m$) e

$$U = \begin{bmatrix} 1 & -1 & 0 & 0 & \dots & 0 & 0 \\ 0 & 0 & 1 & -1 & \dots & 0 & 0 \\ 0 & 0 & 0 & 0 & \dots & 0 & 0 \\ 0 & 0 & 0 & 0 & \dots & 1 & -1 \end{bmatrix} \quad (2.50)$$

2.5.1.7 Estimação de Estado baseada na Lógica Fuzzy

O algoritmo que aqui se vai descrever é um algoritmo híbrido, que combina o estimador WLS com conceitos da lógica fuzzy. Informação mais detalhada sobre esta aproximação pode ser encontrada em [22]. Diversas contribuições importantes sobre a aplicação da lógica fuzzy à estimação de estado, podem também ser consultadas em [23, 24, 25].

Este algoritmo híbrido, é uma variante do estimador de Kalman [22] e é baseado na seguinte relação:

$$\hat{x}(k)_{\text{ótimo}} = \alpha \hat{x}(k) + (1 - \alpha) z(k), \quad k = 1, 2, \dots, m$$

O valor óptimo da estimação é controlado pelo parâmetro α , que representa o peso dado à estimação de estado obtida através do método WLS. O valor de α pode ser determinado pelas variâncias dos resíduos ou por conhecimento do funcionamento do sistema. Num sistema em que a relação sinal/ruído seja elevada, o valor a atribuir a α deverá

ser elevado para que as alterações transitórias do vector das medidas ($z(k)$) sejam ignoradas. Neste caso, o estimador fuzzy será, de uma forma geral, preciso e os resíduos serão pequenos. Um valor pequeno a atribuir a α deverá ser escolhido numa situação inversa à descrita anteriormente.

Se o sistema variar ao longo do espectro residual, α adapta-se às alterações permitindo a obtenção estimacões de estado óptimas [22]. A figura (2.8) apresenta o algoritmo usado.

De salientar que devem ser usadas as formas e variações normalmente usadas quando se lida com conjuntos fuzzy, isto é, formas triangulares ou trapezoidais e variações entre 0 e 1.




Figura 2.8- Algoritmo de estimação de estado integrando conceitos de lógica fuzzy.

2.5.1.8 Métodos desacoplados aplicados à estimação de estado.

Considerando que o estimador de estado deve ser executado periodicamente em modo *on-line* e que um sistema eléctrico de energia apresenta, normalmente, uma dimensão elevada, qualquer simplificação que permita a diminuição do tempo de processamento é desejável. Na realidade a aplicação do método WLS na estimação de estado de um sistema com N barramentos, leva à manipulação de um sistema de equações não lineares com dimensão $2N-1$. Se para resolução do problema for aplicado o algoritmo de Gauss (2.27), em cada iteração será necessária a construção e resolução de um sistema linear com a dimensão $2N-1$. No entanto é possível reduzir o volume de cálculo tirando partido das seguintes características do problema:

- diminuição da complexidade do sistema de equações a solucionar, substituindo-o por sistemas de dimensão menor (algoritmos desacoplados) ou recorrendo a algoritmos baseados na utilização de uma matriz de ganho constante;
- esparsidade e simetria das matrizes envolvidas.

A versão simplificada mais comum de um estimador de estado é baseada no desacoplamento das partes activa e reactiva do vector das medidas. A aplicação deste tipo de simplificações, já anteriormente usado nos estudos de fluxos de cargas [26, 27, 28], baseia-se na fraca relação existente entre as potências activas e o módulo da tensão, por um lado, e entre as potências reactivas e a fase da tensão, por outro.

Este tipo de desacoplamento torna-se mais evidente quando os ramos da rede apresentam uma relação elevada para o valor de $\frac{x_{ij}}{r_{ij}}$, em que os parâmetros x_{ij} e r_{ij} são respectivamente a reactância e a resistência série do ramo ij , ou quando o ponto de funcionamento da rede é próximo do ponto de funcionamento nominal ($|V|=1$ p.u. e $\theta=0$ rad.).

Aplicando este tipo de desacoplamento aos algoritmos de estimação de estado, as simplificações que daí resultam permitem tornar estes algoritmos bastante mais rápidos.

Considere-se então, o modelo das medidas (2.15) dividido nas partes activa e reactiva, isto é:

$$z = \begin{bmatrix} z_p \\ - \\ z_q \end{bmatrix} = \begin{bmatrix} h_p(x) \\ - \\ h_q(x) \end{bmatrix} + \begin{bmatrix} e_p \\ - \\ e_q \end{bmatrix} \quad (2.51)$$

em que:

z_p – subvector de z correspondente às medidas de trânsito de potência activa nas linhas e potência activa injectada.

z_q – subvector de z correspondente às medidas de trânsito de potência reactiva nas linhas e potência reactiva injectada.

A divisão correspondente da matriz covariância R é:

$$R = \begin{bmatrix} R_p & | & 0 \\ - & - & - \\ 0 & | & R_q \end{bmatrix} \quad (2.52)$$

Considere-se também os sub vectores $V(k)$ e $\theta(k)$ do vector de estado $x(k)$, relativos respectivamente aos módulos e fases das tensões:

$$x^T(k) = [\theta^T(k) \quad V^T(k)] \quad (2.53)$$

De acordo com as subdivisões estabelecidas para o vector das medidas z e para o vector de estado x , a matriz jacobiana $H(x)$ e a matriz de ganho $G(x)$ podem ser divididas em quatro submatrizes do seguinte modo:

$$H(x) = \begin{bmatrix} H_{P\theta} & | & H_{PV} \\ - & - & | & - & - \\ H_{Q\theta} & | & H_{QV} \end{bmatrix} \quad (2.54)$$

$$G(x) = \begin{bmatrix} G_{a\theta} & | & G_{aV} \\ - & - & | & - & - \\ G_{r\theta} & | & G_{rV} \end{bmatrix} \quad (2.55)$$

em que:

$$G_{a\theta} = H_{P\theta}^T \cdot R_P^{-1} \cdot H_{P\theta} + H_{Q\theta}^T \cdot R_Q^{-1} \cdot H_{Q\theta} \quad (2.56)$$

$$G_{aV} = H_{P\theta}^T \cdot R_P^{-1} \cdot H_{PV} + H_{Q\theta}^T \cdot R_Q^{-1} \cdot H_{QV} \quad (2.57)$$

$$G_{r\theta} = H_{PV}^T \cdot R_P^{-1} \cdot H_{P\theta} + H_{QV}^T \cdot R_Q^{-1} \cdot H_{Q\theta} \quad (2.58)$$

$$G_{rV} = H_{PV}^T \cdot R_P^{-1} \cdot H_{PV} + H_{QV}^T \cdot R_Q^{-1} \cdot H_{QV} \quad (2.59)$$

Relativamente ao vector $g(x)$ dado por (2.21) e correspondente ao segundo membro do processo iterativo descrito pela equação (2.26), podemos representá-lo de um modo simplificado como:

$$g(x) = H^T \cdot R^{-1} \cdot (z - h) = \begin{bmatrix} g_\theta^T & g_V^T \end{bmatrix}^T \quad (2.60)$$

sendo:

$$g_\theta = H_{P\theta}^T \cdot R_P^{-1} \cdot [z_P - h_P] + H_{Q\theta}^T \cdot R_Q^{-1} \cdot [z_Q - h_Q] \quad (2.61)$$

$$g_V = H_{PV}^T \cdot R_P^{-1} \cdot [z_P - h_P] + H_{QV}^T \cdot R_Q^{-1} \cdot [z_Q - h_Q] \quad (2.62)$$

Admitindo como válidos os pressupostos em que se baseia o princípio do desacoplamento, consideram-se as seguintes aproximações:

$$\cos \theta_{ik} \approx 1, \quad |G_{ik} \sin \theta_{ik}| \ll |B_{ik} \cos \theta_{ik}| \quad (2.63)$$

donde resulta:

$$|H_{Q\theta}| \ll |H_{P\theta}| \quad e \quad |H_{PV}| \ll |H_{QV}| \quad (2.64)$$

em que $|H|$ representa o módulo dos elementos de H . A matriz jacobiana H é então aproximada pelas duas submatrizes $H_{P\theta}$ e H_{QV} :

$$H(x) = \begin{bmatrix} H_{P\theta} & | & 0 \\ - & - & - \\ 0 & | & H_{QV} \end{bmatrix} \quad (2.65)$$

O objectivo do desacoplamento é a substituição do sistema de equações lineares (2.27) de dimensão $n = 2N-1$, por dois sistemas de dimensão $N-1$ e N respectivamente:

$$G_{a\theta}[\theta(k), V(k)] [\theta(k+1) - \theta(k)] = g_\theta[\theta(k), V(k)] \quad (N-1) \quad (2.66)$$

$$G_{rV}[\theta(k), V(k)] [V(k+1) - V(k)] = g_V[\theta(k), V(k)] \quad (N) \quad (2.67)$$

Como se pode verificar, as vantagens desta substituição em termos de tempo de processamento e memória ocupada são significativas. Para melhorar a convergência é normal introduzir após resolução do primeiro subsistema, o novo valor do subvector de estado correspondente no outro subsistema, isto é:

$$G_{rV}[\theta(k+1), V(k)][V(k+1) - V(k)] = g_V[\theta(k+1), V(k)] \quad (2.68)$$

Todos os estimadores de estado desacoplados propostos na literatura admitem G_{aV} e $G_{r\theta} = 0$, surgindo no entanto variantes que se distinguem pelo grau de simplificação considerado para as expressões de $G_{a\theta}$ (2.56), G_{rV} (2.59), g_θ (2.61) e g_V (2.62). As mais frequentemente referidas são:

- Estimadores de matriz de ganho desacoplados.

Nestes estimadores o desacoplamento é introduzido a nível da matriz de ganho, mas os segundos membros das equações (2.66) e (2.67) mantêm-se inalterados. Para este tipo de estimadores, é possível encontrar duas abordagens ao método:

- o não desacoplamento da matriz H no cálculo de $G_{a\theta}$ e G_{rV} . Este estimador caracteriza-se por:

$G_{a\theta}$: completa e dada por (2.56)

G_{rV} : completa e dada por (2.59)

G_{aV} e $G_{r\theta} = 0$

g_θ : completo e dado por (2.61)

g_V : completo e dado por (2.62)

- desacoplamento da matriz H no cálculo de $G_{a\theta}$ e G_{rV} . Este estimador caracteriza-se por:

$$G_{a\theta}: H_{P\theta}^T \cdot R_P^{-1} \cdot H_{P\theta}$$

$$G_{rV}: H_{QV}^T \cdot R_Q^{-1} \cdot H_{QV}$$

$$G_{aV} \text{ e } G_{r\theta} = 0$$

$$g_\theta: \text{ completo e dado por (2.61)}$$

$$g_V: \text{ completo e dado por (2.62)}$$

- Estimadores completamente desacoplados.

Nestes estimadores a matriz jacobiana H é desacoplada, quer para o cálculo da matriz de ganho quer para a determinação dos segundos membros das equações (2.66) e (2.67). As relações em que se baseia este estimador são as seguintes:

$$G_{a\theta}: H_{P\theta}^T \cdot R_P^{-1} \cdot H_{P\theta}$$

$$G_{rV}: H_{QV}^T \cdot R_Q^{-1} \cdot H_{QV}$$

$$G_{aV} \text{ e } G_{r\theta} = 0$$

$$g_\theta: H_{P\theta}^T \cdot R_P^{-1} \cdot [z_P - h_P] \quad (2.69)$$

$$g_V: H_{QV}^T \cdot R_Q^{-1} \cdot [z_Q - h_Q] \quad (2.70)$$

- Estimadores linearizados por aplicação do modelo DC .

Tal como na abordagem utilizada nos algoritmos de trânsitos de potências, a aplicação das simplificações utilizadas pelo modelo DC , ajudam a simplificar o processo e melhoram em muitos casos as características de convergência dos estimadores desacoplados. As simplificações consideradas são as seguintes:

- $V_i \approx 1 \text{ p.u.}, (\forall_i)$;
- desprezar as resistências série dos diferentes ramos.

O que se traduz no facto da matriz jacobiana se tornar independente do vector de estado do sistema.

Admitindo também que a submatriz $H_{P\theta}$ é avaliada desprezando as resistências série, pelo que os elementos das matrizes H_P e H_Q ou coincidem com os parâmetros da linha ou,

são uma combinação linear desses parâmetros [27, 28]. Assim, pode evitar-se o cálculo explícito e o armazenamento dos elementos dessas matrizes.

Nestas condições, o processo recursivo traduzido pelas equações (2.66) e (2.67) poderá escrever-se como:

$$\theta(k+1) = \theta(k) + [H_p^T \cdot R_p^{-1} \cdot H_p]^{-1} \cdot H_p^T \cdot R_p^{-1} \cdot [z_p - h_p(\theta(k), V(k))] \quad (2.71)$$

$$V(k+1) = V(k) + [H_Q^T \cdot R_Q^{-1} \cdot H_Q]^{-1} \cdot H_Q^T \cdot R_Q^{-1} \cdot [z_Q - h_Q(\theta(k+1), V(k))] \quad (2.72)$$

em que as sub matrizes de ganho G_θ e G_V , dadas por:

$$G_\theta = H_p^T \cdot R_p^{-1} \cdot H_p \quad (2.73)$$

$$G_V = H_Q^T \cdot R_Q^{-1} \cdot H_Q \quad (2.74)$$

são calculadas, factorizadas e armazenadas apenas uma vez no início do processo iterativo, o que resulta numa considerável redução do tempo de execução relativamente ao algoritmo WLS básico.

No que respeita aos algoritmos desacoplados deve-se salientar que qualquer modificação introduzida no termo independente (segundo membro) do processo iterativo descrito pela equação (2.27), modifica a solução para a qual o algoritmo converge. A solução obtida não é mais óptima, no sentido de minimizar a função $J(x)$. Estão neste caso os estimadores completamente desacoplados e os que utilizam os algoritmos com base no modelo *DC*. Por outro lado os estimadores de matriz de ganho desacoplada, que mantêm intacto o termo independente de (2.27), convergem para a mesma solução do algoritmo base (Gauss).

O diagrama de fluxo de um estimador completamente desacoplado é apresentado na figura 2.9.




Figura 2.9 – Fluxograma de um estimador desacoplado (FDSE) [16].

2.5.2. Estimação de estado dinâmica

Os sistemas eléctricos são, como seria de esperar, variantes no tempo. Assim sendo, uma abordagem estática para a obtenção do vector de estado pode não ser satisfatória [29]. Por esse motivo, houve a tendência para o desenvolvimento de estimadores que explorassem as características de evolução no tempo do vector de estado (x). O objectivo de um estimador de estado dinâmico passa pela determinação do estado do sistema no presente momento e pela previsão do estado do sistema em momentos futuros. Para tal recorre a dois tipos de informação distintas:

- dados “brutos” que chegam a intervalos de tempo regulares ao centro de condução da rede eléctrica;
- conhecimento do passado do sistema e com isso a possibilidade de prever a sua evolução futura.

Este tipo de estimadores recorrem frequentemente ao uso de algoritmos baseados nos filtros de Kalman (EKF - "Extended Kalman Filter") e é a possibilidade de construir uma base de dados preditiva que vai permitir a detecção antecipada de anomalias, com base no vector das inovações, $\tilde{z}(k)$.

Os algoritmos de estimação dinâmica baseados no filtro de Kalman, desenvolvem-se em duas etapas: a etapa de previsão e a etapa de filtragem.

É durante a etapa de previsão, que se procede ao calculo do vector das inovações normalizado, $\tilde{z}_N$. Depois disso é necessário determinar quais as componentes de $\tilde{z}_N$ com valor absoluto superior a um determinado limiar de detecção, λ^* .

Se todos os componentes do referido vector forem inferiores a λ^* , então pode concluir-se que não foram encontradas anomalias no funcionamento do sistema eléctrico em análise.

Na segunda etapa, procede-se à filtragem das medidas recolhidas no instante k , após determinação da matriz ganho $K(k)$. Obtém-se o estado filtrado $\hat{x}(k|k)$ e a matriz covariância do erro de estimação $\Sigma(k|k)$, a partir das seguintes equações:

$$K(k) = \Sigma(k|k-1) H^T(k) [H(k) \Sigma(k|k-1) H^T(k) + R(k)]^{-1} \quad (2.75)$$

$$\hat{x}(k|k) = \hat{x}(k|k-1) + K(k) [z(k) - h(\hat{x}(k|k-1), k)] \quad (2.76)$$

e

$$\Sigma(k|k) = [I - K(k) H(k)] \Sigma(k|k-1) \quad (2.77)$$

com

$$H(k) = \left. \frac{\partial h}{\partial x} \right|_{x=\hat{x}(k|k-1)}$$

As tabelas seguintes resumizam as equações do filtro de Kalman.

Tabela 2.1 – Equações do filtro de Kalman

Modelos	Estado	$x(k+1) = f(x(k), k) + d(x(k), k)w(k)$
	Medidas	$E[w(k)] = 0; E[w(k)w^T(k)] = Q(k)\delta_{kl}$ $z(k) = h(x(k), k) + v(k)$ $E[v(k)] = 0; E[v(k)v^T(l)] = R(k)\delta_{kl}$ $E[v(k)w^T(l)] = 0 \quad \forall_{k,l}$
Condições Iniciais		$\bar{x}_0 = \hat{x}(0 0) \quad ; \quad \Sigma_0 = \Sigma(0 0)$ $E[v(k)x^T(l)] = 0 \quad ; \quad E[w(k)x^T(0)] = 0, \forall_k$

Tabela 2.2 – Equações das etapas de previsão e filtragem

Previsão	$\hat{x}(k k-1) = f(\hat{x}(k-1 k-1), k-1)$ $\Sigma(k k-1) = F(k-1)\Sigma(k-1 k-1)F^T(k-1) + D(k-1)Q(k-1)D^T(k-1)$ $F(k-1) = \left. \frac{\partial f}{\partial x} \right _{x=\hat{x}(k-1 k-1)}$ $D(k-1) = d(\hat{x}(k-1 k-1), k-1)$
Filtragem	$K(k) = \Sigma(k k-1)H^T(k)[H(k)\Sigma(k k-1)H^T(k) + R(k)]^{-1}$ $\hat{x}(k k) = \hat{x}(k k-1) + K(k)[z(k) - H(k)\hat{x}(k k-1)]$ $\Sigma(k k) = [I - K(k)H(k)]\Sigma(k k-1)$ $H(k) = \left. \frac{\partial h}{\partial x} \right _{x=\hat{x}(k k-1)}$


O vector das inovações é calculado a partir de

$$\begin{aligned}
 \hat{z}(k|k-1) &= z(k) - \hat{z}(k|k-1) \\
 &= z(k) - h(\hat{x}(k|k-1))
 \end{aligned} \tag{2.78}$$

Na figura 2.10 podemos ver o encadeamento entre as fases de previsão e filtragem neste tipo de algoritmo.

Os estimadores baseados no filtro de Kalman têm como grande inconveniente a sua elevada complexidade que se traduz depois no aumento do tempo de processamento e em maiores necessidades em termos de recursos computacionais. A abordagem hierárquica ao problema da estimação de estado dinâmica que permita uma diminuição de complexidade, bem como um processo de aquisição e processamento de dados que permita aliviar o esforço de cálculo são áreas onde se tem vindo a desenvolver intensa investigação [30, 31, 32].

A EE dinâmica é uma ferramenta capaz de fornecer informações sobre o estado do sistema no momento actual e em momentos futuros, o que torna este método muito importante quando se pretende uma supervisão eficiente, económica e segura de um sistema eléctrico. A capacidade de previsão pode ser considerada a grande vantagem em relação aos estimadores estáticos [31].






Figura 2.10 – Etapas de previsão e filtragem de um estimador dinâmico baseado no filtro de Kalman.

2.6- CONCLUSÕES

A estimação de estado é nos dias de hoje uma ferramenta essencial nos modernos centros de controlo de SEE. As acções de controlo efectuadas nos SEE têm por objectivo garantir a segurança na condução e exploração do sistema bem como, assegurar as exigências de uma elevada continuidade de serviço. Estes objectivos estão intimamente ligados à qualidade da informação disponível na base de dados existente nos centros de controlo. O desenvolvimento desta base de dados, constitui a principal finalidade para o desenvolvimento e implementação de algoritmos de estimação de estado nos centros de controlo dos SEE.

A função do algoritmo de estimação de estado é estimar o valor da fase e módulo das tensões em todos os barramentos constituintes do SEE. Para que a estimação seja possível é necessário obter informações da estrutura e parâmetros da rede, mas especialmente um conjunto redundante de medidas efectuadas no sistema, obtidas de um modo geral por teletransmissão, e que chegam aos centros de controlo através de um sistema de supervisão, controlo e aquisição de dados denominado de SCADA.

Uma outra função importante da estimação de estado é a de compensar a possível ausência de medidas, que poderá acontecer devido a falhas no sistema de aquisição e transmissão e também a possível contaminação por erros grosseiros das medidas disponíveis para processamento.

Neste capítulo fez-se uma abordagem à constituição dos SEE e dos sistemas de supervisão, controlo e aquisição de dados, bem como uma análise detalhada do método WLS, já que é neste método que se baseiam a generalidade dos algoritmos de estimação de estado desenvolvidos. Fez-se também referência às principais simplificações que podem ser introduzidas no método WLS e uma compilação de vários algoritmos propostos na literatura para resolução das equações de estimação procurando garantir uma maior estabilidade numérica face ao método WLS [17, 18, 19, 21].

Fez-se também neste capítulo, uma pequena referência aos estimadores baseados na lógica fuzzy [22, 23, 24, 25] e aos estimadores dinâmicos [29, 31, 32]. Estes últimos baseiam-se na determinação de um modelo que descreva aproximadamente a evolução no tempo do vector de estado do sistema e as estimativas são obtidas habitualmente recorrendo a algoritmos baseados no filtro de Kalman.

CAPÍTULO 3

ERROS GROSSEIROS - METODOLOGIAS DE DETECÇÃO E IDENTIFICAÇÃO

Capítulo 3

ERROS GROSSEIROS - METODOLOGIAS DE DETECÇÃO E IDENTIFICAÇÃO

3.1- INTRODUÇÃO

A Estimação de Estado quando aplicada aos SEE, usa informações que provêm na sua maioria do equipamento de medida instalado no sistema [33], informação essa que chega aos centros de controlo através do respectivo sistema SCADA. Para assegurar o bom funcionamento do estimador de estado, é fundamental garantir a sua capacidade não só para detectar e identificar medidas afectadas por erros grosseiros, mas também para filtrar toda a informação disponível fornecendo uma base de dados completa, coerente e fiável que ficará disponível para posterior processamento.

A informação que chega aos Centros de Controlo, deverá assentar em medidas fiáveis, por forma a que o operador do sistema possa tomar as decisões mais apropriadas para assegurar o bom funcionamento do sistema eléctrico. No entanto, se as medidas recolhidas estiverem contaminadas por erros grosseiros, isso irá afectar a qualidade da estimação de estado obtida. Para tentar evitar que isso aconteça, é realizada uma acção preliminar de verificação das medidas, com o objectivo de filtrar a maior parte dos erros grosseiros que as possam afectar. Contudo, esses testes preliminares não são suficientes, e podem continuar a existir medidas contaminadas por erros grosseiros que entrem no processo de estimação de estado. As possíveis causas para a existência desses erros poderão assentar no mau

funcionamento dos transdutores ou na existência de intermitências nas comunicações. Assim, justifica-se a necessidade de implementar uma rotina de detecção e identificação de erros grosseiros como parte integrante do próprio estimador de estado.

Ao longo dos anos foram desenvolvidos métodos que permitem aos estimadores de estado, uma abordagem eficiente ao problema da existência de medidas contaminadas por erros. Esses métodos podem ser agrupados em três tipos:

- Métodos de identificação por eliminação;
- Métodos que usam critérios não quadráticos;
- Métodos de identificação por teste de hipóteses.

Normalmente, os métodos mais utilizados na realização desta tarefa, baseiam-se em duas etapas, a primeira é a detecção de erros e a segunda é a identificação da, ou das, medidas afectadas por esses erros.

Mais recentemente, têm vindo a ser desenvolvidos algoritmos baseados em redes neuronais para resolução deste problema. Os resultados têm sido satisfatórios mas a precisão dos mesmos está fortemente ligada à adequação dos conjuntos de treino e à arquitectura da rede neuronal seleccionada [34].

Neste capítulo é efectuada uma análise ao problema da detecção e identificação dos erros grosseiros.

3.2- OBJECTIVO DA ROTINA DE DETECÇÃO E IDENTIFICAÇÃO DE ERROS GROSSEIROS.

Como foi visto no capítulo anterior, os métodos de estimação de estado estão fortemente dependentes da qualidade do vector das medidas. Assim, se o vector das medidas estiver afectado por erros grosseiros, os resultados devolvidos pelo estimador não

serão fiáveis. Normalmente a influência desses erros faz-se notar na convergência do algoritmo e na precisão da estimativa obtida.

O principal objectivo da rotina de detecção e identificação de erros grosseiros é eliminar o efeito destes sobre o vector de estado estimado. Outros objectivos podem ser considerados, tais como, a possibilidade de fornecer ao operador do sistema a lista de medidas afectadas por erros grosseiros, permitindo-lhe a localização do equipamento de medida que poderá eventualmente não estar a funcionar correctamente.

Esta fase crucial de qualquer estimador, deverá culminar com a apresentação de uma estimativa fiável para o vector de estado, obtida no menor tempo possível e possibilitar a criação de uma lista com a indicação de todas as medidas afectadas por erros grosseiros. De salientar que esta rotina deverá ser optimizada em termos de tempo de processamento, para possibilitar a utilização do estimador de estado em tempo real.

O processamento de erros grosseiros vai então assentar em três etapas distintas:

Detecção

Identificação

Correcção

Na primeira fase, é feita a verificação da existência, ou não, de erros grosseiros no vector das medidas.


Após a detecção da existência de erros nas medidas, a fase seguinte tem como objectivo a identificação das medidas afectadas pelos erros.

A última fase serve para corrigir as medidas identificadas anteriormente. Essa correcção pode passar pela simples eliminação das medidas ou pela sua substituição por valores previamente conhecidos ou por estimativas do seu verdadeiro valor; esta última

solução torna-se necessária sempre que a medida afectada seja uma medida importante em termos de observabilidade da rede.

3.3- ERROS QUE AFECTAM O ESTIMADOR DE ESTADO

Os erros que mais frequentemente afectam as medidas usadas no processo de estimação de estado são de vários tipos e encontram-se representados no seguinte esquema.



Os erros de medida são essencialmente devidos ao mau funcionamento dos aparelhos de medida, dos canais de comunicação, ou ainda quando as medidas são efectuadas durante a ocorrência de fenómenos transitórios. A maior parte deste tipo de erros, normalmente de grande amplitude, são detectados na fase de pré processamento da informação, no entanto alguns deles poderão chegar à fase de estimação.

Os erros de modelização resultam, como o próprio nome indica, do uso de modelos matemáticos não adequados aos reais parâmetros da rede. Como demonstra o esquema anterior, eles podem ser divididos em várias categorias, que serão descritas seguidamente.

- Os erros topológicos resultam de informação incorrecta das telessinalizações acerca do verdadeiro estado (aberto/fechado) de interruptores e disjuntores que determinam a estrutura da rede e a configuração de medida;

- Os erros nos parâmetros da rede resultam de incorrecções na informação disponibilizada pelos fabricantes (sobre impedâncias das linhas e/ou transformadores), erros de má calibração dos aparelhos de medida, erros de cálculo ou erros devidos a alterações físicas ocorridas durante o funcionamento da rede. Estes erros também podem resultar de deficientes valores assumidos para as tomadas dos transformadores com regulação em carga [2];
- Os erros na modelização do ruído de medida resultam de incorrecções nos valores assumidos para a precisão dos diferentes aparelhos de medida. Estes erros podem afectar seriamente o tratamento estatístico das medidas.

3.4- DEFINIÇÃO DE ERRO GROSSEIRO DE MEDIDA

O vector das medidas, amplamente descrito no capítulo anterior, é normalmente modelizado da seguinte forma, quando contém erros grosseiros:

$$z = h(x) + v + g \quad (3.1)$$

em que:

v – representa o ruído de medida normal ($v \sim N(0, R)$)

g – representa os erros grosseiros (vector cujas únicas componentes não nulas são as que simulam os erros grosseiros).

O vector v , é modelizado como uma variável aleatória. O valor de g , é considerado como uma grandeza determinística de valor desconhecido e pode ser interpretado como um desvio do ruído de medida.

Deste modo, os erros grosseiros afectam apenas o valor médio do ruído de medida (e) de um valor igual a g , não modificando nem a respectiva densidade de probabilidade que se mantém gaussiana, nem alteram a correspondente matriz covariância R , ou seja:

- Na ausência de erros grosseiros

$$e = v \sim N(0, R) \quad (3.2)$$

- Na presença de erros grosseiros

$$e = v + g \quad (3.3)$$

$$e \sim N(v, R) \quad (3.4)$$

Esta modelização do erro, facilita o estudo das alterações provocadas pela existência de erros grosseiros, no entanto é normal considerar o erro de medida como sendo um valor único obtido pela junção de v e g , obtendo-se o modelo habitual para o vector das medidas:

$$z = h(x) + e \quad (3.5)$$

com $e = [e_i]$, sendo:

$e_i = v_i \sim N(0, \sigma_i^2)$, se a medida i não estiver afectada por um erro grosseiro;
 e_i – indeterminado, caso contrário.

O vector do ruído (e) na ausência de erros grosseiros, é modelizado da seguinte forma:

$$e \sim N(0, R) \quad \text{com} \quad R = \text{diag}(\sigma_i^2) \quad i = 1, \dots, m \quad (3.6)$$

Por análise desta expressão, é possível determinar, para uma dada probabilidade P , um intervalo $[-k\sigma_i, k\sigma_i]$ que tem uma probabilidade P de incluir o erro de medida e_i .

Usualmente, o valor a atribuir a k é 3, podendo estabelecer-se que existe um erro grosseiro a afectar a medida i sempre que e_i estiver fora dos limites do intervalo $[-3\sigma_i, 3\sigma_i]$.

3.5- DETECÇÃO DE ERROS GROSSEIROS

3.5.1 – Introdução

As metodologias de detecção de erros grosseiros mais usadas, baseiam-se fundamentalmente na teoria dos testes de hipóteses [35, 36, 37]. Neste método, são formuladas hipóteses relativas às propriedades estatísticas, das variáveis aleatórias envolvidas.

Quando se fala em métodos de detecção de erros, é necessário ter a percepção de que existem algumas conjugações típicas de erros. Assim, podemos distinguir três casos:

Caso 1 - A existência de apenas um erro grosseiro no vector das medidas;

Caso 2 - Vários erros grosseiros mas não correlacionados;

Caso 3 - Vários erros grosseiros correlacionados.

Enquanto que no caso 1, a existência de uma única medida errada, facilita a etapa seguinte que é a identificação da medida infectada, os casos 2 e 3 tornam essa identificação um pouco mais problemática.

A detecção dos erros grosseiros poderá ser feita recorrendo a um dos seguintes testes, ou à conjugação de alguns deles:

- Teste do $J(\hat{x})$
- Testes dos resíduos normalizados (r_N) e dos resíduos ponderados (r_W)
- Teste da amplitude do erro grosseiro
- Teste de hipóteses

Enquanto que o primeiro é um teste unicamente utilizado para a detecção, os outros servem também para identificação da medida em erro.

O teste de detecção de erros grosseiros é então formulado com base em duas hipóteses:

H_0 : ausência de erros grosseiros

H_1 : presença de erros grosseiros

A metodologia utilizada para verificar qual das duas hipóteses é verdadeira consiste em estimar o estado da rede considerando que H_0 é verdadeira, e seguidamente verificar a veracidade desta hipótese através da análise dos resultados da estimação de estado ($J(\hat{x})$ e r).

Na tabela 3.1 estão representados os diferentes resultados possíveis associados a um teste de hipóteses. Na figura 3.1 representam-se as regiões rejeição e aceitação associadas a um teste de hipóteses unilateral [38].

Tabela 3.1- Tabela de decisão para um teste de hipóteses

Decisão	Hipótese Verdadeira	
	H_0	H_1
Aceitar H_0	Decisão correcta $p = 1-\alpha$	Erro tipo II $p = \beta$
Rejeitar H_0	Erro tipo I $p = \alpha$	Decisão correcta $p = 1-\beta$




Figura 3.1 – Regiões de aceitação e rejeição associadas a um teste unilateral

Para a realização dos testes de hipóteses é necessário fixar-se previamente um valor para o nível de significância do teste. Este nível, normalmente representado por α , traduz a probabilidade de falso alarme, isto é, a probabilidade de se cometer o erro de rejeitar uma hipótese quando ela é verdadeira (erro do tipo I).

Um outro tipo de erro pode acontecer no decurso de um teste de hipótese: rejeitar a hipótese alternativa H_1 (isto é, aceitar H_0) quando H_1 é verdadeira (erro do tipo II).

A probabilidade de se incorrer no erro do tipo II, é habitualmente representada por β . A diferença $(1-\beta)$ designa-se por potência do teste e, traduz a probabilidade de rejeitar H_0 quando esta hipótese é de facto falsa.

3.5.2 – Teste do $J(\hat{x})$

Uma vez que a soma dos quadrados de variáveis aleatórias independentes com distribuição normal, segue uma distribuição χ^2 [46], então considerando como verdadeira a hipótese H_0 (não existem erros grosseiros), a variável aleatória $J(\hat{x})$ definida como:

$$J(\hat{x}) = \sum_{i=1}^m w_{ii} r_i^2 \quad (3.7)$$

Apresenta também distribuição qui-quadrado (χ^2), sendo os graus de liberdade obtidos pela diferença entre o número de medidas (m) e o número de variáveis de estado (n) e portanto, com valor médio e variância dado pelas equações (B.4) e (B.5) do apêndice B. Porém, $J(\hat{x})$ deixará de apresentar distribuição χ^2 se estiver presente uma medida suficientemente errada que faça com que o vector de ruído da medida (e) deixe de ter distribuição normal com valor médio nulo e matriz covariância R .

Após se ter definido um limiar de detecção $\chi^2_{1-\alpha}$ para um teste unilateral, associado a uma probabilidade de falso alarme α (α situa-se habitualmente no intervalo $[0,01, 0,1]$), a decisão a tomar face ao valor assumido por $J(\hat{x})$ é a seguinte:

- Aceitar H_0 se $J(\hat{x}) \leq \chi^2_{1-\alpha}$
- Rejeitar H_0 se $J(\hat{x}) > \chi^2_{1-\alpha}$

Quando o número de graus de liberdade for superior a 30, pode-se considerar que a variável aleatória $J(\hat{x})$ apresenta uma distribuição normal ($N(m-n, 2(m-n))$). Considerando uma probabilidade de falso alarme, α , igual à anterior, dever-se-á aceitar a hipótese H_0 se:

$$\frac{J(\hat{x}) - (m - n)}{\sqrt{2(m - n)}} \leq N_{1-\alpha} \quad (3.8)$$

Como seria de prever, a não ocorrência desta condição implica a rejeição da hipótese.

3.5.3 – Testes dos resíduos normalizados (r_N) e dos resíduos ponderados (r_W)

Considerando a hipótese H_0 verdadeira, o vector dos resíduos r obedece a uma distribuição gaussiana $N(0, WR)$, como se demonstra no apêndice C. Assim, e considerando a definição de resíduos normalizados (C.7) obtém-se:

$$r_{Ni} \sim N(0,1) \quad (3.9)$$

Considerando a probabilidade de falso alarme α , é definido um limiar de detecção $N_{1-\alpha/2}$ (considera-se $\alpha / 2$ porque se trata de um teste bilateral). Então, e para o resíduo de cada medida, devemos:

- Aceitar H_0 se $|r_{Ni}| \leq N_{1-\alpha/2}$, para todo $i = 1, \dots, m$,
- Rejeitar H_0 se $|r_{Ni}| > N_{1-\alpha/2}$, para algum $i = 1, \dots, m$.

Como se pode compreender, este é um método que exige algum esforço computacional, resultante do cálculo dos resíduos normalizados. Como já foi dito anteriormente, o tempo gasto no processamento é um dos aspectos mais importantes em qualquer processo de estimação, pois pode inviabilizar o seu uso na análise de sistemas em tempo real.

Devido a essas imposições, é possível utilizar um método aproximado que requer menor esforço computacional e que se baseia no vector dos resíduos ponderados r_W (apêndice C).

Este é também um teste bilateral, com uma estrutura análoga à do teste r_N . Depois de obtidos os diferentes valores de r_{Wi} $i = 1, \dots, m$ (C.6) e fixado um limiar de detecção λ , o processo de decisão é o seguinte:

- Aceitar H_0 se $|r_{Wi}| \leq \lambda$, para todo o $i = 1, \dots, m$,
- Rejeitar H_0 se $|r_{Wi}| > \lambda$, para algum $i = 1, \dots, m$.

Uma particularidade deste método é a existência de diferentes valores de α para os vários resíduos, pois depende do valor assumido pelo W_{ii} respectivo. Realmente comparar r_{Wi} a λ é equivalente a comparar r_{Ni} a $\lambda / \sqrt{W_{ii}}$.

3.5.4 – Teste da amplitude do erro grosseiro

Depois de obtida a estimativa inicial do vector de estado do sistema, pode detectar-se a existência de erros grosseiros calculando-se os resíduos normalizados associados a cada medida e considerando-se como susceptível de estar contaminada com um erro grosseiro a medida a que corresponda um resíduo normalizado com uma amplitude consideravelmente superior aos restante.

No entanto, sabe-se já que, de um modo geral, a amplitude de um determinado resíduo não pode ser considerada como um indicador seguro da presença ou ausência de um erro grosseiro na medida correspondente. Esta situação agrava-se na presença de erros grosseiros múltiplos correlacionados.

3.6- IDENTIFICAÇÃO DE ERROS GROSSEIROS

Após a execução da etapa da detecção de erros grosseiros e no caso de o resultado indicar a existência de erros no vector das medidas, torna-se imperativo a execução de um processo que identifique as medidas em erro [39].

Qualquer rotina de identificação deverá ser capaz de executar três funções essenciais, que são:

- ❑ Localizar;
- ❑ Corrigir;
- ❑ Informar.

A primeira função é óbvia, pois o método utilizado para identificação deverá localizar eficazmente os erros grosseiros ou indicar uma lista com as medidas afectadas pelos mesmos.

Após a localização da(s) medida(s), a rotina deverá eliminar o efeitos dos erros grosseiros.

Sempre que não for possível identificar as medidas afectadas, essa informação terá que ser dada ao operador, devendo ser elaborada uma lista com as medidas suspeitas.

Existem várias formas de fazer a identificação desses erros, as grandes diferenças entre as várias técnicas, reside na forma de eliminar os erros e de corrigir as bases de dados. Uma outra diferença assenta nas grandezas usadas na identificação dos erros grosseiros.

3.6.1 – Identificação por eliminação (IBE)

Neste método é feita uma análise dos resíduos (normalizados ou ponderados). Assim, se a operação de detecção indicar que existem erros grosseiros nas medidas, deverá ser organizada uma lista com os resíduos que dará informação sobre as medidas suspeitas.

Maior resíduo implica mais probabilidade de a medida correspondente, estar infectada por um erro grosseiro.

Depois deverão ser realizadas operações cíclicas de eliminação, estimação e detecção até que a operação de detecção informe que já não existem erros grosseiros nas medidas.

Quando só existe uma medida afectada por erros grosseiros, este método é eficiente pois, essa medida causará o resíduo mais elevado que será imediatamente eliminado do vector das medidas. No entanto, outros problemas poderão surgir quando ocorrem as seguintes situações:

1. Existência de erros múltiplos não correlacionados;
2. Existência de erros múltiplos correlacionados.

Uma variante desta metodologia consiste na eliminação por grupos de medidas. Como a relação entre a maior amplitude dos resíduos e a contaminação por erros grosseiros das respectivas medidas não é necessariamente verdadeira, opta-se por eliminar grupos de medidas suspeitas. Seguidamente, essas medidas são reintroduzidas uma a uma. Sempre que o teste de detecção forneça um resultado positivo, a medida correspondente é considerada em erro e eliminada do vector das medidas. Uma desvantagem deste método é a necessidade de verificação da observabilidade da rede pois, ao eliminar um grupo de medidas a estimação de estado poderá não ser possível devido à não observabilidade da rede.

Na situação 2, o problema agrava-se pois, para além das dificuldades descritas anteriormente, acresce ainda a possibilidade de não ser possível efectuar a detecção de erros grosseiros devido a um processo de camuflagem dos mesmos que faz com que o teste dos resíduos dê negativo. Um outro problema é a eliminação intempestiva de medidas não afectadas por erros grosseiros levando à diminuição da redundância e consequentemente à diminuição da eficácia dos testes de detecção e ao aumento da correlação dos resíduos;

Esta metodologia tem uma desvantagem que reside no facto de necessitar de inverter a matriz ganho sempre que se faz um ciclo de eliminação-estimação. No entanto, este

esforço de cálculo poderá ser atenuado através da aplicação de métodos eficientes de redução do volume de cálculo.

3.6.2 – Identificação por critérios não-quadráticos (NQC)

Este método executa a identificação e eliminação dos erros grosseiros, não como uma função complementar à estimação de estado, mas sim como parte integrante do processo de estimação de estado. Isto é, quando é apresentada uma solução para o vector de estado, essa solução já vem eliminada de erros grosseiros nas medidas.

O processo consiste em fazer diminuir o peso das medidas em que o resíduo mantém ou adquire um valor elevado. Para tal, é necessário definir um valor limite, γ . Quanto maior for o afastamento do valor do resíduo relativamente a esse limite, menor deverá ser a influência da medida responsável pelo resíduo no processo de estimação de estado.

As medidas que forem classificadas como afectadas por erros grosseiros, são aquelas que no final da estimação de estado apresentam um resíduo de elevada amplitude, isto é, são aquelas medidas que foram rejeitadas pelo estimador de estado [16].

Como se pode verificar, a detecção e a identificação de erros grosseiros, bem como a correcção da estimativa obtida para o vector de estado do sistema, são realizadas simultaneamente num processo único.


A metodologia NQC baseia-se na minimização da seguinte função de custo não quadrática:

$$J(x) = \sum_{i=1}^m g_i \left(\frac{r_i}{\sigma_i} \right) \quad (3.10)$$

em que:

$$r_i = z_i - h_i(x) \quad (3.11)$$

distinguindo-se diferentes variantes na aplicação da metodologia NQC pelas funções g_i seleccionadas, como se demonstra na Figura 3.2.



Q – Quadrático QT – Quadrático-tangente QR – Quadrático-raiz quadrada
 QL – Quadrático-linear QC – Quadrático-constante γ – Limiar de transição

Figura 3.2 - Funções de custo não quadráticas utilizadas nos estimadores BDS”(Bad Data Supression”)

A minimização da função custo (3.10) por aplicação do método de Gauss resulta num processo iterativo com a seguinte forma:

$$x(k+1) = x(k) + \nabla^{-1}(x(k))H^T(x(k))R^{-1}G^\#(x(k))\rho(x(k)) \quad (3.12)$$

em que:

$$\nabla(x(k)) = H^T(x(k))G^\#(x(k))R^{-1}G^\#(x(k))H(x(k)) \quad (3.13)$$

$$H(x(k)) = \left. \frac{\partial h(x)}{\partial x} \right|_{x=x(k)} \quad (3.14)$$

$$G^\#(x(k)) = \left. \frac{\partial \rho(x)}{\partial r} \right|_{x=x(k)} \quad (3.15)$$

e k é o contador de iterações.

Se a amplitude dos resíduos for inferior ao limiar de transição (γ), a matriz $G^\#$, que é uma matriz diagonal, reduz-se à matriz identidade, e o estimador BDS coincide com o estimador WLS. Verificando-se a ocorrência de erros grosseiros nas medidas processadas, alguns dos elementos $G_{ii}^\#$ da matriz $G^\#$ assumirão um valor diferente da unidade, como se pode verificar na Figura 3.3.

CRITÉRIO	ρ_i			$G_{ii}^\#$		
QUADRÁTICO	r_i			1		
QUADRÁTICO-TANGENTE	r_i	se	$\left \frac{r_i}{\sigma_i} \right \leq \gamma$	1	se	$\left \frac{r_i}{\sigma_i} \right \leq \gamma$
	$\gamma \sigma_i \text{sign}(r_i) \left[2 \left \frac{r_i}{\gamma \sigma_i} \right - 1 \right]^{1/2}$	se	$\left \frac{r_i}{\sigma_i} \right > \gamma$	$\left[2 \left \frac{r_i}{\gamma \sigma_i} \right - 1 \right]^{-1/2}$	se	$\left \frac{r_i}{\sigma_i} \right > \gamma$
QUADRÁTICO-RAIZ QUADRADA	r_i	se	$\left \frac{r_i}{\sigma_i} \right \leq \gamma$	1	se	$\left \frac{r_i}{\sigma_i} \right \leq \gamma$
	$\gamma \sigma_i \text{sign}(r_i) \left[4 \left \frac{r_i}{\gamma \sigma_i} \right ^{1/2} - 3 \right]^{1/2}$	se	$\left \frac{r_i}{\sigma_i} \right > \gamma$	$\left \frac{r_i}{\gamma \sigma_i} \right ^{-1/2} \left[4 \left \frac{r_i}{\gamma \sigma_i} \right ^{1/2} - 3 \right]^{1/2}$	se	$\left \frac{r_i}{\sigma_i} \right > \gamma$
QUADRÁTICO-LINEAR	r_i	se	$\left \frac{r_i}{\sigma_i} \right \leq \gamma$	1	se	$\left \frac{r_i}{\sigma_i} \right \leq \gamma$
	$\gamma \sigma_i \text{sign}(r_i) \left \frac{r_i}{\gamma \sigma_i} \right ^{1/2}$	se	$\left \frac{r_i}{\sigma_i} \right > \gamma$	$\frac{1}{2} \left \frac{r_i}{\gamma \sigma_i} \right ^{-1/2}$	se	$\left \frac{r_i}{\sigma_i} \right > \gamma$
QUADRÁTICO-CONSTANTE	r_i	se	$\left \frac{r_i}{\sigma_i} \right \leq \gamma$	1	se	$\left \frac{r_i}{\sigma_i} \right \leq \gamma$
	$\gamma \sigma_i$	se	$\left \frac{r_i}{\sigma_i} \right > \gamma$	0	se	$\left \frac{r_i}{\sigma_i} \right > \gamma$

Figura 3.3 – Relação entre os termos de ρ e $G_{ii}^\#$ para diversas funções de custo não quadráticas.

Os critérios não quadráticos fazem variar em cada iteração o peso atribuído às diferentes medidas em função do valor assumido pelos resíduos correspondentes. Assim, para $|r_i| / \sigma_i < \gamma$, o coeficiente de ponderação da medida ($1 / \sigma^2$) é igual ao utilizado pelo critério quadrático; para $|r_i| / \sigma_i > \gamma$ verifica-se que quanto maior é o resíduo, menor é o peso atribuído à respectiva medida e portanto maior é o grau de rejeição correspondente.

Pode-se concluir também que o valor pré definido γ , é usado como limite inferior e define o o ponto de mudança do critério quadrático para o não quadrático.

3.6.3 – Identificação por testes de hipótese (HTI)

Este método é essencialmente, um método de estimação dos erros de medida e interpretação estatística das estimativas obtidas, tendo como objectivo identificar com precisão as medidas afectadas por erros grosseiros. Este método analisa as estimativas dos erros de medida das medidas suspeitas $\hat{e}_s$, que são calculadas a partir duma adequada subdivisão da equação $r=We$, sendo utilizado um modelo linear. Recorrendo às propriedades estatísticas de cada uma das componentes de $\hat{e}_s$ é realizado um teste de identificação individual que permite decidir se a medida está ou não afectada por um erro grosseiro

As hipóteses a propor são as seguintes:

H_0 : “A medida i está afectada por um erro grosseiro”

H_1 : “ A medida i é uma medida válida”

Terminado o processo de identificação, as medidas consideradas em erro são as medidas eliminadas.

O fluxograma deste método é o seguinte:




Figura 3.4 - Fluxograma sucinto do procedimento HTI.

3.7 CONCLUSÕES

A estimação de estado tem por finalidade o cálculo do verdadeiro valor das variáveis de estado do SEE, a partir da informação disponível na base de dados. Contudo, toda a informação que o algoritmo de estimação de estado processa pode estar sujeita a erros, nomeadamente erros grosseiros que afectam as medidas e podem ser provocados por funcionamento defeituoso dos aparelhos de medição e transmissão. Este tipo de problemas pode afectar gravemente a qualidade da estimativa obtida. Assim sendo, torna-se indispensável a implementação de rotinas que detectem e identifiquem a existência de erros grosseiros evitando a contaminação por esses mesmos erros, da estimativa de estado fornecida pelo estimador.

Uma outra vantagem da existência de um esquema de detecção e identificação de erros é a possibilidade de criação de uma base de dados com a lista de medidas afectadas por erros grosseiros, auxiliando o operador do sistema na localização do equipamento de medida que apresente um funcionamento deficiente.

Neste capítulo, fez-se uma breve referência aos diferentes tipos de erros que podem afectar o estimador de estado. Foi ainda efectuada uma análise aprofundada dos principais métodos actualmente utilizados na detecção e identificação de erros grosseiros no âmbito da estimação de estado estática de SEE.

A detecção de erros grosseiros é baseada na formulação de testes de hipótese (H_0 : ausência de erros grosseiros / H_1 : presença de erros grosseiros), definidos a partir da caracterização estatística das variáveis envolvidas. Neste capítulo foram estudados vários testes de hipótese, nomeadamente os testes do $J(\hat{x})$, do r_N e do r_W .

O teste do $J(\hat{x})$ é o mais utilizado, em detrimento dos outros dois, contudo não é o mais eficiente na presença de redes de elevada dimensão. A escolha entre o teste r_N e o teste r_W resulta de um compromisso entre a simplicidade de implementação e a fiabilidade dos resultados obtidos.

Na fase de identificação de erros grosseiros, as rotinas implementadas para o efeito terão que possuir a capacidade de executar três funções essenciais:

- Localizar;
- Corrigir;
- Informar.

Para esse efeito poderão ser usadas três diferentes metodologias:

- Identificação por eliminação (IBE)
- Identificação por critérios não quadráticos (NQC)
- Identificação por testes de hipóteses (HTI)

O método IBE baseia-se no vector dos resíduos e sempre que exista a informação de existência de erros grosseiros, é criada uma lista de medidas suspeitas de estarem afectadas baseada no vector dos resíduos normalizados ou ponderados. Seguidamente são realizados ciclos sucessivos eliminação-estimação-deteção até que a rotina de detecção indique que já não existem erros grosseiros. Como é de prever este método acarreta um elevado peso computacional.

Na metodologia NQC, o processo de identificação-eliminação dos erros grosseiros é parte integrante do método de estimação de estado propriamente dito. É analisado o vector dos resíduos normalizados ou ponderados quanto à amplitude de cada elemento e é atribuído um peso menor à medida responsável pelo maior resíduo.

A finalizar foi analisada sucintamente a metodologia de identificação por testes de hipóteses (HTI), que assenta num critério individual, particularizado para cada medida suspeita. Neste método as variáveis em análise, são as estimativas dos erros de medida das medidas suspeitas $\hat{e}_s$, que são calculadas a partir da utilização de um modelo linear, contrariamente aos métodos anteriores que recorriam à análise dos resíduos das medidas. Fazendo uso das propriedades estatísticas de cada uma das componentes de $\hat{e}_s$ é realizado um teste de identificação individual que permite decidir se a medida está ou não afectada por um erro grosseiro.

CAPÍTULO 4

RESULTADOS COMPUTACIONAIS

Capítulo 4

RESULTADOS COMPUTACIONAIS

4.1– INTRODUÇÃO

No capítulo que agora se inicia serão apresentados e analisados alguns resultados obtidos pela simulação de dois algoritmos convencionais de estimação de estado, baseados no método dos mínimos quadrados ponderados (WLS). O primeiro é o algoritmo de Gauss-Newton, o segundo é o algoritmo desacoplado MDE (Model Decoupled Estimator). Ambos os métodos foram descritos no capítulo 2. Para as simulações foram usados dois sistemas de teste, um de pequena dimensão, "IEEE 24 barramentos" e um outro de dimensão elevada, "IEEE 118 barramentos". Os dados destes sistemas apresentam-se nos Apêndices E e F respectivamente.


O estado real do sistema é obtido recorrendo ao cálculo de um trânsito de potências para o sistema em análise, daí se retiram os valores, assumidos como reais, para a fase e amplitude da tensão em todos os barramentos do sistema. Este trânsito de potências foi efectuado recorrendo ao software PowerWorld Simulator.

Os algoritmos de estimação de estado implementados foram programados em MATLAB instalado num computador com processador Pentium Mobile a 1,7 GHz e sistema operativo Windows XP.

De seguida serão apresentados os métodos usados para efectuar a estimação de estado, bem como uma descrição das redes de testes usadas. No final será feita uma análise dos resultados obtidos e elaboradas as respectivas conclusões.

4.2– MÉTODOS DE SIMULAÇÃO USADOS

O diagrama seguinte ilustra a sequência do processo, desde a obtenção do estado real do sistema (trânsito de potências) até à apresentação do vector de estado estimado.






Figura. 4.1- Estrutura do processo implementado.

Para que se possa dar início ao processo de estimação de estado, é necessário obter um conjunto redundante de medidas obtidas da rede de teste. Essas informações foram simuladas recorrendo a um programa que executa trânsitos de potência, nomeadamente o PowerWorld Simulator.

Após o tratamento dessa informação, foram então programados, em linguagem Matlab, os dois algoritmos de estimação de estado já anteriormente referidos.

4.2.1 Algoritmos implementados

O primeiro algoritmo a ser implementado foi o de Gauss-Newton, o qual irei denominar de algoritmo de estimação de estado na versão integral.

Para a programação deste algoritmo foram seguidos os seguintes passos:

1. Elaboração do vector de medidas - z
Construção da matriz de ponderação das medidas - W
2. Inicialização do vector de estado - x
 $\theta = 0$ rad
 $V = 1$ pu
3. Construção do vector das equações de medida - $h(x)$
4. Construção da matriz jacobiana - $H(x)$
5. Construção e inversão da matriz de ganho - G e G^{-1}
6. Cálculo dos incrementos do vector de estado - Δx
7. Verificação da convergência - $\Delta x \leq \epsilon$
8. Actualização do vector de estado - x^{k+1}
9. Voltar ao passo 3.

Este processo pára quando no passo 7 for assinalada uma 'flag', que indique que o processo atingiu a convergência. Essa convergência é atingida quando todos os incrementos ao vector

de estado calculados na mesma iteração, forem inferiores a um valor pré estabelecido, ε , que no algoritmo programado assumiu o valor 0,001.

O outro algoritmo implementado foi o MDE e que pode ser resumido pela seguinte sequência de passos:

1. Elaboração do vector de medidas activas - z_a
 Elaboração do vector de medidas reactivas - z_r
 Construção da matriz de ponderação das medidas activas – W_a
 Construção da matriz de ponderação das medidas reactivas - W_r
2. Inicialização do vector de estado- x
 $\theta = 0$ rad
 $V = 1$ pu
3. Cálculo e inversão da matriz ganho das medidas activas - G_a e G_a^{-1}
 Cálculo e inversão da matriz ganho das medidas reactivas – G_r e G_r^{-1}
4. Cálculo da submatriz $H_{p\theta}$
5. Cálculo dos incrementos a efectuar às fases das tensões - $\Delta\theta$
6. Verificação da convergência - $\Delta\theta \leq \varepsilon$
7. Actualização das fases das tensões - θ^{k+1}
8. Cálculo da submatriz H_{QV}
9. Cálculo dos incrementos a efectuar aos módulos das tensões - ΔV
10. Verificação da convergência - $\Delta V \leq \varepsilon$

11. Actualização dos módulos das tensões - V^{k+1}

12. Voltar ao passo 4.

Uma das diferenças deste método em relação ao anterior, é que a matriz ganho é calculada e invertida uma única vez, sendo depois mantida constante em todo o processo. O processo termina quando na mesma iteração, todos os incrementos feitos às fases e aos módulos das tensões forem inferiores a 0,001.

Os fluxogramas destes dois algoritmos foram apresentados no capítulo 2, nas figuras 2.7 e 2.9.

4.2.2 Estrutura da matriz jacobiana - $H(x)$

Como referido no ponto anterior, um dos assuntos que merece alguma importância aquando da programação do algoritmo de estimação de estado, é a estrutura e organização da matriz jacobiana.

Na obtenção dos resultados que à frente serão apresentados, foi implementado um algoritmo em que a matriz jacobiana $H(x)$, pode ser dividida em quatro submatrizes, assumindo a seguinte forma:

$$H(x) = \begin{matrix} & \begin{matrix} N-1 & N \end{matrix} \\ \begin{matrix} m_1 \\ m_2 \end{matrix} \begin{bmatrix} H_{P\theta} & | & H_{PV} \\ - & - & - \\ H_{Q\theta} & | & H_{QV} \end{bmatrix} & = & \begin{matrix} \begin{matrix} N-1 & N \end{matrix} \\ \begin{bmatrix} \frac{\partial P_{ij}}{\partial \theta} & | & \frac{\partial P_{ij}}{\partial V} \\ \dots & \dots & \dots \\ \frac{\partial P_i}{\partial \theta} & | & \frac{\partial P_i}{\partial V} \\ - & - & - \\ \frac{\partial Q_{ij}}{\partial \theta} & | & \frac{\partial Q_{ij}}{\partial V} \\ \dots & \dots & \dots \\ \frac{\partial Q_i}{\partial \theta} & | & \frac{\partial Q_i}{\partial V} \\ \dots & \dots & \dots \\ \frac{\partial V_i}{\partial \theta} & | & \frac{\partial V_i}{\partial V} \end{bmatrix} \end{matrix} \end{matrix} \quad (4.1)$$

em que:

N – número total de barramentos

m_1 - número total de medidas do tipo P_{ij} e P_i

m_2 - número total de medidas do tipo Q_{ij} e Q_i e V_i

$m = m_1 + m_2$ - número total de medidas disponíveis

Assim sendo, as submatrizes têm a seguinte forma e dimensão:

$$\square \quad H_{p\theta} = \frac{\partial h_p}{\partial \theta} \quad , \text{ com dimensão } (m_1 \times (N-1))$$

$$\square \quad H_{pV} = \frac{\partial h_p}{\partial V} \quad , \text{ com dimensão } (m_1 \times N)$$

$$\square \quad H_{q\theta} = \frac{\partial h_q}{\partial \theta} \quad , \text{ com dimensão } (m_2 \times (N-1))$$

$$\square \quad H_{qV} = \frac{\partial h_q}{\partial V} \quad , \text{ com dimensão } (m_2 \times N)$$

As expressões correspondentes aos diferentes elementos da matriz jacobiana são as seguintes:

$$\frac{\partial P_{ij}}{\partial \theta} \rightarrow \begin{cases} \frac{\partial P_{ij}}{\partial \theta_i} = V_i V_j (-G_{ij} \sin \theta_{ij} + B_{ij} \cos \theta_{ij}) & (4.2) \\ \frac{\partial P_{ij}}{\partial \theta_j} = V_i V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) & (4.3) \end{cases}$$

$$\frac{\partial P_{ij}}{\partial V} \rightarrow \begin{cases} \frac{\partial P_{ij}}{\partial V_i} = -2a_{ij} G_{ij} V_i + V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) & (4.4) \\ \frac{\partial P_{ij}}{\partial V_j} = V_i (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) & (4.5) \end{cases}$$

$$\frac{\partial P_i}{\partial \theta} \rightarrow \begin{cases} \frac{\partial P_i}{\partial \theta_i} = V_i \sum_{\substack{j=1 \\ j \neq i}}^N V_j (-G_{ij} \sin \theta_{ij} + B_{ij} \cos \theta_{ij}) \end{cases} \quad (4.6)$$

$$\frac{\partial P_i}{\partial \theta} \rightarrow \begin{cases} \frac{\partial P_i}{\partial \theta_j} = V_i V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (4.7)$$

$$\frac{\partial P_i}{\partial V} \rightarrow \begin{cases} \frac{\partial P_i}{\partial V_i} = 2G_{ii}V_i + \sum_{\substack{j=1 \\ j \neq i}}^N V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \end{cases} \quad (4.8)$$

$$\frac{\partial P_i}{\partial V} \rightarrow \begin{cases} \frac{\partial P_i}{\partial V_j} = V_i (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \end{cases} \quad (4.9)$$

$$\frac{\partial Q_{ij}}{\partial \theta} \rightarrow \begin{cases} \frac{\partial Q_{ij}}{\partial \theta_i} = V_i V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \end{cases} \quad (4.10)$$

$$\frac{\partial Q_{ij}}{\partial \theta} \rightarrow \begin{cases} \frac{\partial Q_{ij}}{\partial \theta_j} = V_i V_j (-G_{ij} \cos \theta_{ij} - B_{ij} \sin \theta_{ij}) \end{cases} \quad (4.11)$$

$$\frac{\partial Q_{ij}}{\partial V} \rightarrow \begin{cases} \frac{\partial Q_{ij}}{\partial V_i} = 2V_i (a_{ij} B_{ij} - y_{ij,0}) + V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (4.12)$$

$$\frac{\partial Q_{ij}}{\partial V} \rightarrow \begin{cases} \frac{\partial Q_{ij}}{\partial V_j} = V_i (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (4.13)$$

$$\frac{\partial Q_i}{\partial \theta} \rightarrow \begin{cases} \frac{\partial Q_i}{\partial \theta_i} = V_i \sum_{\substack{j=1 \\ j \neq i}}^N V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \end{cases} \quad (4.14)$$

$$\frac{\partial Q_i}{\partial \theta} \rightarrow \begin{cases} \frac{\partial Q_i}{\partial \theta_j} = V_i V_j (-G_{ij} \cos \theta_{ij} - B_{ij} \sin \theta_{ij}) \end{cases} \quad (4.15)$$

$$\frac{\partial Q_i}{\partial V} \rightarrow \begin{cases} \frac{\partial Q_i}{\partial V_i} = -2B_{ii}V_i + \sum_{\substack{j=1 \\ j \neq i}}^N V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (4.16)$$

$$\frac{\partial Q_i}{\partial V} \rightarrow \begin{cases} \frac{\partial Q_i}{\partial V_j} = V_i (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (4.17)$$

$$\frac{\partial V_i}{\partial \theta} \rightarrow \frac{\partial V_i}{\partial \theta_j} = 0 \quad , \quad \forall j \quad (4.18)$$

$$\frac{\partial V_i}{\partial V} \rightarrow \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases} \quad (4.19)$$

Um outro processo que foi necessário programar nos algoritmos de estimação de estado implementados, foi o da construção e inversão da matriz ganho (G). Essa matriz é dada, como já vimos no capítulo 2, pela equação (2.26) e efectivamente, partindo dessa expressão obtemos:

$$G_{ij} = \sum_{k=1}^m (H^T)_{ik} R_{kk}^{-1} (H^T)_{jk} \quad (4.20)$$

A matriz G é uma matriz simétrica. Por outro lado, o número de elementos não nulos da matriz H é bastante reduzido. Este facto resulta de cada medida envolver um número relativamente restrito de variáveis de estado (topologicamente próximas da medida) dando assim origem a um pequeno número de derivadas parciais não nulas. Assim:

- a medida do módulo da tensão no barramento i envolve apenas a variável de estado V_i e dá origem a um único elemento não nulo na linha correspondente da matriz H ;
- a medida do trânsito de potência (activa ou reactiva) na linha ligando os barramentos i e j envolve apenas as variáveis de estado relativas a esses barramentos e a linha correspondente de H não terá mais de quatro elementos não nulos;
- a medida da potência injectada (activa ou reactiva) no barramento i envolve as variáveis de estado deste barramento e de todos os barramentos extremidade de linhas incidentes no barramento i . Assim, a linha correspondente H não terá

mais de $2l+2$ elementos não nulos, em que l representa o número de linhas incidentes no barramento i .

Como a matriz jacobiana H é muito esparsa, isso induz a que G seja também uma matriz esparsa embora em menor grau do que H . Efectivamente a partir da equação (4.20) podemos concluir que $G_{ij} \neq 0$ se, e só se, existir pelo menos uma medida k que envolva simultaneamente as variáveis aleatórias i e j . Atendendo a que cada medida envolve apenas as variáveis de estado dos barramentos adjacentes, muitos elementos de G serão nulos. Em contrapartida, os elementos da diagonal principal da matriz de ganho assumem valores estritamente positivos.

Um dos objectivos principais do estimador de estado consiste na possibilidade de poder ser usado para processamento em tempo real. Para tal, terá que ser feita uma eficiente ocupação do sistema de memória e minimização do tempo de processamento. Uma forma possível de realização deste objectivo passa pelo maior aproveitamento possível das características de simetria e esparsidade das matrizes envolvidas.

4.3 – REDES DE TESTE

Para a elaboração das simulações e respectiva obtenção de resultados, foram escolhidos dois sistemas de teste do IEEE, sobre os quais se conhecem todas as informações necessárias à simulação. As redes usadas foram a de 24 barramentos e a de 118 barramentos. A diferente dimensão das redes foi escolhida para se poder comparar a variação no tempo gasto no processamento da estimação de estado. Algumas características das redes são apresentadas nas tabelas seguintes. As informações referentes às linhas e barramentos bem como os resultados dos trânsitos de potência encontram-se nos apêndices E e F para as redes de 24 e 118 barramentos, respectivamente.

□ Rede de 24 barramentos

Tabela 4.1 – Dados da rede de 24 barramentos

Barramentos	Linhas	PT's	Geradores	Cargas
24	29	5	11	17

□ Rede de 118 barramentos

Tabela 4.2 – Dados da rede de 118 barramentos

Barramentos	Linhas	PT's	Geradores	Cargas
118	170	9	54	91

Para cada um destes sistemas de teste foram simuladas duas situações correspondentes a redundâncias de medida diferentes. Essa redundância, que foi já definida pela equação 2.4, toma valores superiores a 1, por forma a ser possível fazer uma filtragem do ruído de medida. As redundâncias aplicadas a cada sistema de teste encontram-se sintetizados na tabela 4.3.

Tabela 4.3 - Dados dos sistemas de teste

Teste	Redundância	Nº de medidas
Rede A	1.5	71
Rede A	2.5	118
Rede B	2.27	535
Rede B	3.2	752

A estrutura das redes de teste utilizadas encontra-se representada nas figuras seguintes.




Figura 4.2- Sistema de teste de 24 barramentos




Figura 4.3- Sistema de teste de 118 barramentos

4.3.1 Configurações de medida

Como foi já referido anteriormente, foram usadas duas configurações de medida, para cada sistema de teste, na execução da estimação de estado. O verdadeiro valor das medidas foi encontrado através do resultado obtido pelo programa que executa o trânsito de potências. Ao verdadeiro valor das medidas foi, ainda, adicionado um valor aleatório que varia entre -0,001 e 0,001 para as medidas de tensão e entre -0,01 e 0,01 para as medidas de potência, que pretende simular o ruído que contamina cada medida que chega ao centro de controlo.

As configurações de medidas foram escolhidas tendo como preocupação a observabilidade da rede, por esse motivo na rede de teste de 118 barramentos, a redundância menor é de 2.27 pois, ao usar menos medidas a rede tornava-se inobservável.

Um resumo das configurações de medidas usadas, encontra-se nas tabelas 4.4, 4.5, 4.6 e 4.7, sendo as duas primeiras referentes à rede A e as restantes referentes à rede B.

Tabela 4.4 - Configuração de medida da rede A (Conf.1)

Tipos de medidas		Nº de Medidas
Potência activa	P_{ij}	25
	P_i	7
	TOTAL	32
Potência reactiva	Q_{ij}	25
	Q_i	7
	TOTAL	32
Tensão	V_i	7
TOTAL		71
Nº de barramentos		Redundância
24		1,5

Tabela 4.5 - Configuração de medida da rede A (Conf.2)

Tipos de medidas		Nº de Medidas
Potência activa	P_{ij}	32
	P_i	18
	TOTAL	50
Potência reactiva	Q_{ij}	32
	Q_i	18
	TOTAL	50
Tensão	V_i	18
TOTAL		118
Nº de barramentos		Redundância
24		2,5

Tabela 4.6 - Configuração de medida da rede B (conf.1)

Tipos de medidas		Nº de Medidas
Potência activa	P_{ij}	179
	P_i	59
	TOTAL	238
Potência reactiva	Q_{ij}	179
	Q_i	59
	TOTAL	238
Tensão	V_i	59
TOTAL		535
Nº de barramentos		Redundância
118		2,27

Tabela 4.7 - Configuração de medida da rede B (Conf.2)

Tipos de medidas		Nº de Medidas
Potência activa	P_{ij}	212
	P_i	105
	TOTAL	317
Potência reactiva	Q_{ij}	212
	Q_i	105
	TOTAL	317
Tensão	V_i	118
TOTAL		752
Nº de barramentos		Redundância
118		3,2

4.4 - PARÂMETROS EM ANÁLISE

A análise do desempenho dos algoritmos implementados, foi efectuada para todas as configurações de medida na presença e ausência de erros grosseiros. Os aspectos que estarão na base da avaliação do desempenho do estimador de estado serão:

- ❑ Número de iterações - Nit ;
- ❑ Tempo de processamento - $t(s)$;
- ❑ Valor da função objectivo - $J(\hat{x})$;
- ❑ Erro máximo das grandezas medidas;

$$\delta_{max}^h = \max |z - h(\hat{x})|$$

- ❑ Erro médio das grandezas medidas;

$$\delta_{med}^h = \frac{\sum_{i=1}^m |z_i - h(\hat{x}_i)|}{m}, \quad m = n^\circ \text{ de medidas}$$

- ❑ Erro máximo e médio do valor estimado para as fases das tensões;

$$\delta_{med}^{\theta} = \frac{\sum_{i=1}^{N-1} |\theta_i - \hat{\theta}_i|}{N-1}, \quad \delta_{max}^{\theta} = \max |\theta_i - \hat{\theta}_i|$$

□ Erro máximo e médio do valor estimado para os módulos das tensões.

$$\delta_{med}^V = \frac{\sum_{i=1}^N |V_i - \hat{V}_i|}{N}, \quad \delta_{max}^V = \max |V_i - \hat{V}_i|$$

sendo N o número de barramentos.

Para todas as simulações efectuadas foi considerado um factor de convergência de 0,001 pu para os módulos e 0,001 rad. para as fases das tensões.

4.5 - APRESENTAÇÃO DOS RESULTADOS

Para simplificação na apresentação dos resultados optou-se por seguir o seguinte critério:

1º - Apresentação dos resultados da rede de 14 barramentos -versão integral - tabela 4.8 e 4.9.

2º - Apresentação dos resultados da rede de 14 barramentos -versão desacoplada - tabela 4.10 e 4.11.

3º - Apresentação dos resultados da rede de 118 barramentos -versão integral - tabela 4.12 e 4.13.

4º - Apresentação dos resultados da rede de 118 barramentos -versão desacoplada - tabela 4.14 e 4.15.

Para além das tabelas serão também apresentados alguns gráficos comparativos dos parâmetros em análise.

Tabela 4.8 - Resultados da estimação - versão integral

	Configuração de medidas	$t(s)$	Nit	$J(\hat{x})$
REDE	Conf.1	0,11	3	28,12
A	Conf.2	0,11	3	62,15

Tabela 4.9 - Resultados estatísticos da estimação - versão integral

	Configuração de medidas	δ_{max}^h (pu)	δ_{med}^h (pu)	δ_{max}^θ (rad)	δ_{med}^θ (rad)	δ_{max}^V (pu)	δ_{med}^V (pu)
REDE A	Conf.1	0,0193	3,866E-03	1,489E-03	3,908E-04	4,800E-03	9,625E-04
	Conf.2	0,0223	4,227E-03	9,914E-04	3,490E-04	3,200E-03	5,958E-04

Tabela 4.10 - Resultados da estimação - versão desacoplada

	Configuração de medidas	$t(s)$	Nit	$J(\hat{x})$
REDE A	Conf.1	0,14	4	28,77
	Conf.2	0,14	4	62,83

Tabela 4.11 - Resultados estatísticos da estimação - versão desacoplada

	Configuração de medidas	δ_{max}^h (pu)	δ_{med}^h (pu)	δ_{max}^θ (rad)	δ_{med}^θ (rad)	δ_{max}^V (pu)	δ_{med}^V (pu)
REDE A	Conf.1	0,0202	3,841E-03	1,615E-03	3,557E-04	4,800E-03	9,625E-04
	Conf.2	0,0231	4,244E-03	8,914E-04	2,846E-04	3,200E-03	6,000E-04

Tabela 4.12 - Resultados da estimação - versão integral

	Configuração de medidas	$t(s)$	Nit	$J(\hat{x})$
REDE B	Conf.1	1,1	3	202,17
	Conf.2	1,8	3	278,14

Tabela 4.13 - Resultados estatísticos da estimação - versão integral

	Configuração de medidas	δ_{max}^h (pu)	δ_{med}^h (pu)	δ_{max}^θ (rad)	δ_{med}^θ (rad)	δ_{max}^V (pu)	δ_{med}^V (pu)
REDE	Conf.1	0,0331	3,220E-03	1,157E-03	3,753E-04	9,100E-03	4,440E-04
B	Conf.2	0,0400	3,340E-03	1,220E-03	3,157E-04	9,500E-03	3,042E-04

Tabela 4.14 - Resultados da estimação - versão desacoplada

	Configuração de medidas	$t(s)$	Nit	$J(\hat{x})$
REDE	Conf.1	0,5	5	349,14
B	Conf.2	0,9	8	481,95

Tabela 4.15 - Resultados estatísticos da estimação - versão desacoplada

	Configuração de medidas	δ_{max}^h (pu)	δ_{med}^h (pu)	δ_{max}^θ (rad)	δ_{med}^θ (rad)	δ_{max}^V (pu)	δ_{med}^V (pu)
REDE	Conf.1	0,0877	3,628E-03	3,650E-03	4,108E-04	9,100E-03	4,788E-04
B	Conf.2	0,0945	3,857E-03	5,850E-03	4,447E-04	9,500E-03	3,313E-04

Seguidamente são apresentados alguns gráficos que comparam os resultados obtidos pelos estimadores de estado implementados.

Com os resultados obtidos pela simulação da rede de teste de 24 barramentos, serão elaborados gráficos que demonstrem o diferente comportamento que os dois algoritmos apresentam em termos de tempo de processamento até a convergência ser atingida, bem como a evolução da função objectivo devido à variação do número de medidas. Com o sistema de teste de 118 barramentos será construído um gráfico que relaciona a variação do erro médio do vector de estado estimado para os dois algoritmos e para as duas configurações de medida.




Figura 4.4 - Estimação de estado Integral vs Desacoplada. Tempo de processamento.




Figura 4.5 - Estimação de estado Integral vs Desacoplada. Função Objectivo $J(\hat{x})$.

Da análise das figuras 4.4 e 4.5 torna-se legítimo efectuar as seguintes conclusões:

- ❑ A versão desacoplada é bastante mais rápida a atingir a convergência, sendo o tempo de processamento, aproximadamente metade do usado pela versão integral. Esta característica deve-se ao facto da não necessidade de, a cada iteração, inverter a matriz ganho.
- ❑ A versão integral é a que melhor resolve o problema de minimização da função objectivo. Sendo a referida função definida pela equação 3.7, podemos então afirmar que esta versão conduz a resíduos de medida de menor amplitude.




Figura 4.6 - Estimação de estado Integral vs Desacoplada. Erro médio do vector de estado estimado.

Da figura 4.6 conclui-se que o vector de estado estimado através da versão desacoplada apresenta alguma depreciação em termos de precisão quando comparado com a versão integral. É possível ainda verificar que o erro médio diminui com o aumento da redundância das medidas. No entanto o aumento exagerado do número de medidas levanta problemas com o tempo de processamento.

4.5.1 Análise dos resultados

Analisando as várias tabelas e gráficos que traduzem os resultados obtidos pelos algoritmos implementados, podemos concluir que ambos têm vantagens e desvantagens na sua utilização.

Torna-se por demais evidente que executar a estimação de estado usando o algoritmo na sua versão integral, produz resultados muito aproximados aos valores reais. De acordo com as tabelas e gráficos apresentados, verifica-se que os erros médios das grandezas estimadas são bastante pequenos. Não é alheio a esta característica o facto de não serem efectuadas grandes simplificações ao processo de estimação. No entanto, quando na presença de redes

de elevada dimensão e principalmente quando a redundância das medidas é elevada, o tempo de processamento aumenta consideravelmente, podendo mesmo impedir a sua utilização *online*.

Dado que o estimador de estado deverá ser executado periodicamente e em modo online, qualquer simplificação que possa baixar o tempo de processamento é desejável, mesmo que isso leve a uma ligeira perda de precisão dos resultados. Isso é o que acontece com o uso da versão desacoplada.

Como se pode verificar pelos resultados, a precisão dos valores estimados é um pouco menor, mas o tempo de processamento é aproximadamente metade. Isto porque é necessário realizar menos de metade das operações em comparação com a versão integral e também porque as matrizes de ganho são construídas e factorizadas apenas uma vez.

Quanto ao número de iterações, verifica-se que aumentam na versão desacoplada, não sendo isso um aspecto muito significativo visto que o tempo gasto por iteração é consideravelmente menor.

Um outro aspecto que pode ser alvo de análise é a influência da redundância das medidas na precisão do estimador. Pela análise dos resultados verifica-se que os erros médios são bastante pequenos para as duas redundâncias de medida usadas nas duas redes de teste, não se notando muito a influência deste factor. No entanto, os vectores de medidas usados apresentam um equilíbrio entre os vários tipos de medidas, podendo ser esse o factor que leva à similaridade dos resultados obtidos. O aspecto da redundância de medida pode ser importante também na fase de detecção dos erros grosseiros, pois a existência de um maior número de medidas próximas da medida afectada por um erro grosseiro leva a uma menor influência desse erro grosseiro no vector estimado e por isso a sua influência só se fará sentir para amplitudes superiores desse mesmo erro, sendo nessa altura detectado pela rotina correspondente. Isto pode ser comprovado pelos resultados apresentados no capítulo seguinte.

4.6 - DETECÇÃO DE ERROS GROSSEIROS

Como já explicado em capítulos anteriores, qualquer algoritmo de estimação de estado deverá possuir uma rotina para detecção e identificação de erros grosseiros eventualmente presentes no vector das medidas. Apesar de existir uma filtragem prévia que elimina muitas das inconsistências do conjunto de medidas, alguns erros poderão escapar a essa rotina de pré-filtragem. Assim, aproveitando as propriedades estatísticas do vector dos resíduos podem-se implementar os métodos de detecção e identificação de erros grosseiros já analisados no capítulo 3.

O algoritmo desenvolvido e que serve de base a este trabalho, recorre ao método da função objectivo, $J(\hat{x})$ para efectuar a detecção de erros grosseiros e executa a identificação pelo método do maior resíduo normalizado do vector de medidas.

Para efectuar a análise da detecção dos erros grosseiros foi utilizada a rede de 24 barramentos (Rede A). Na rede de maior dimensão o comportamento do estimador é semelhante. Foram também usadas as duas configurações de medida para que se possa tirar conclusões sobre a influência do número de medidas na detecção dos erros grosseiros.

Para avaliar a capacidade de detecção pelo método $J(\hat{x})$, foram simulados três tipos de erros grosseiros, um nas medidas de tensão, outro nas medidas de potência injectada e um terceiro nas medidas de fluxo de potência. Para cada um dos erros, fez-se variar a sua amplitude no intervalo -20σ a 20σ , obtendo-se a estimativa do estado do sistema e o correspondente valor da função objectivo, $J(\hat{x})$, para cada nível de erro grosseiro considerado.

As medidas utilizadas para simular os erros foram as seguintes:

- V_{17}
- P_2
- Q_{1-5}

Os resultados são apresentados nas tabelas seguintes.

TAB.4.16 – Detecção de um erro grosseiro com amplitude variável na medida V_{17} .

MEDIDA: V_{17}				
Amplitude do erro grosseiro	$J(\hat{x})$	$J(\hat{x}) / \chi^2$	r_N	$r_N / N_{1-\alpha/2}$
20σ	334,20	7,772 (D)	17,526	8,941 (D)
15σ	204,44	4,754 (D)	13,315	6,793 (D)
10σ	110,18	2,563 (D)	9,104	4,645 (D)
9σ	95,59	2,223 (D)	8,202	4,185 (D)
8σ	82,42	1,917 (D)	7,420	3,786 (D)
7σ	70,66	1,643 (D)	6,578	3,356 (D)
6σ	60,33	1,403 (D)	5,736	2,926 (D)
5σ	51,41	1,196 (D)	4,894	2,497 (D)
4σ	43,91	1,021 (D)	4,052	2,067 (D)
3σ	37,84	0,880	3,210	1,638 (D)
2σ	33,18	0,772	2,368	1,208 (D)
1σ	29,94	0,696	1,526	0,778
0	28,12	0,654	0,684	0,349
-1σ	27,72	0,645	0,158	0,081
-2σ	28,73	0,668	1,000	0,510
-3σ	31,17	0,725	1,842	0,939
-4σ	35,02	0,814	2,684	1,369 (D)
-5σ	40,29	0,937	3,526	1,799 (D)
-6σ	46,99	1,093 (D)	4,367	2,228 (D)
-7σ	55,09	1,281 (D)	5,209	2,657 (D)
-8σ	64,62	1,503 (D)	6,051	3,087 (D)
-9σ	75,57	1,757 (D)	6,893	3,517 (D)
-10σ	87,93	2,045 (D)	7,734	3,946 (D)
-15σ	171,02	3,977 (D)	11,943	6,093 (D)
-20σ	289,56	6,734 (D)	16,151	8,240 (D)

$$\chi^2_{0,99} = 43,0$$

$$\lambda = N_{1-\alpha/2} = 1,96$$

Graus de liberdade = 24

Redundância = 1,5

(D) – indica detecção de erros grosseiros

TAB.4.17 – Detecção de um erro grosseiro com amplitude variável na medida P_2 .

MEDIDA: P_2				
Amplitude do erro grosseiro	$J(\hat{x})$	$J(\hat{x}) / \chi^2$	r_N	$r_N / N_{1-\alpha/2}$
20x σ	151,53	3,524 (D)	11,45	5,686 (D)
15x σ	96,46	2,243 (D)	8,305	4,237 (D)
10x σ	57,54	1,338 (D)	5,464	2,788 (D)
9x σ	51,68	1,202 (D)	4,896	2,498 (D)
8x σ	46,49	1,092 (D)	4,328	2,208 (D)
7x σ	41,93	0,975	3,759	1,918 (D)
6x σ	38,02	0,884	3,191	1,628 (D)
5x σ	34,76	0,808	2,623	1,338 (D)
4x σ	32,14	0,747	2,055	1,048 (D)
3x σ	30,16	0,701	1,487	0,759
2x σ	28,84	0,671	0,919	0,469
1x σ	28,16	0,653	0,350	0,179
0	28,12	0,654	0,218	0,111
-1x σ	28,72	0,668	0,786	0,401
-2x σ	29,98	0,697	1,354	0,691
-3x σ	31,89	0,742	1,923	0,981
-4x σ	34,44	0,801	2,491	1,271 (D)
-5x σ	37,63	0,875	3,059	1,561 (D)
-6x σ	41,47	0,964	3,627	1,851 (D)
-7x σ	45,96	1,069 (D)	4,196	2,141 (D)
-8x σ	51,09	1,188 (D)	4,764	2,431 (D)
-9x σ	56,87	1,322 (D)	5,332	2,721 (D)
-10x σ	63,30	1,472 (D)	5,901	3,010 (D)
-15x σ	105,13	2,445 (D)	8,742	4,460 (D)
-20x σ	163,11	3,793 (D)	11,584	5,910 (D)

$$\chi^2_{0,99} = 43,0$$

$$\lambda = N_{1-\alpha/2} = 1,96$$

Graus de liberdade = 24

Redundância = 1,5

(D) – indica detecção de erros grosseiros

TAB.4.18 – Detecção de um erro grosseiro com amplitude variável na medida Q_{1-5} .

MEDIDA: Q_{1-5}				
Amplitude do erro grosseiro	$J(\hat{x})$	$J(\hat{x}) / \chi^2$	r_N	$r_N / N_{1-\alpha/2}$
20x σ	183,81	4,275 (D)	12,522	6,389 (D)
15x σ	109,96	2,487 (D)	9,111	4,648 (D)
10x σ	59,36	1,380 (D)	5,696	2,906 (D)
9x σ	52,03	1,210 (D)	5,013	2,558 (D)
8x σ	45,64	1,061 (D)	4,330	2,209 (D)
7x σ	40,18	0,934	3,647	1,861 (D)
6x σ	35,65	0,829	2,963	1,512 (D)
5x σ	32,06	0,746	2,280	1,163 (D)
4x σ	29,40	0,684	1,596	0,814
3x σ	27,68	0,644	0,912	0,466
2x σ	26,89	0,625	0,229	0,117
1x σ	27,03	0,629	0,455	0,232
0	28,12	0,654	1,139	0,581
-1x σ	30,14	0,701	1,823	0,930
-2x σ	33,09	0,769	2,508	1,279 (D)
-3x σ	36,98	0,860	3,192	1,629 (D)
-4x σ	41,81	0,972	3,876	1,978 (D)
-5x σ	47,58	1,107 (D)	4,561	2,327 (D)
-6x σ	54,29	1,263 (D)	5,245	2,676 (D)
-7x σ	61,94	1,440 (D)	5,930	3,026 (D)
-8x σ	70,52	1,640 (D)	6,615	3,375 (D)
-9x σ	80,04	1,861 (D)	7,300	3,724 (D)
-10x σ	90,51	2,105 (D)	7,985	4,074 (D)
-15x σ	156,95	3,650 (D)	11,411	5,822 (D)
-20x σ	246,95	5,743 (D)	14,840	7,571 (D)

$$\chi^2_{0,99} = 43,0$$

$$\lambda = N_{1-\alpha/2} = 1,96$$

Graus de liberdade = 24

Redundância = 1,5

(D) – indica detecção de erros grosseiros

TAB.4.19 – Detecção de um erro grosseiro com amplitude variável na medida V_{17} .

MEDIDA: V_{17}				
Amplitude do erro grosseiro	$J(\hat{x})$	$J(\hat{x}) / \chi^2$	r_N	$r_N / N_{1-\alpha/2}$
20x σ	424,92	4,191 (D)	19,064	9,727 (D)
15x σ	267,76	2,641 (D)	14,358	7,326 (D)
10x σ	154,92	1,528 (D)	9,653	4,925 (D)
9x σ	137,66	1,357 (D)	8,711	4,445 (D)
8x σ	122,18	1,205 (D)	7,770	3,964 (D)
7x σ	108,48	1,069 (D)	6,829	3,484 (D)
6x σ	96,54	0,952	5,888	3,004 (D)
5x σ	86,38	0,852	4,947	2,524 (D)
4x σ	77,99	0,769	4,006	2,044 (D)
3x σ	71,37	0,704	3,065	1,564 (D)
2x σ	66,52	0,656	2,123	1,083 (D)
1x σ	63,45	0,626	1,182	0,603
0	62,15	0,613	0,241	0,123
-1x σ	62,62	0,617	0,700	0,357
-2x σ	64,86	0,639	1,641	0,837
-3x σ	68,87	0,659	2,582	1,317 (D)
-4x σ	74,66	0,736	3,523	1,798 (D)
-5x σ	82,22	0,811	4,464	2,278 (D)
-6x σ	91,55	0,903	5,405	2,758 (D)
-7x σ	102,65	1,012 (D)	6,347	3,238 (D)
-8x σ	115,52	1,139 (D)	7,288	3,718 (D)
-9x σ	130,17	1,284 (D)	8,229	4,198 (D)
-10x σ	146,59	1,446 (D)	9,170	4,678 (D)
-15x σ	255,25	2,517 (D)	13,875	7,079 (D)
-20x σ	408,21	4,026 (D)	18,580	9,480 (D)

$$\chi^2_{0,99} = 101,4$$

$$\lambda = N_{1-\alpha/2} = 1,96$$

Graus de liberdade = 71

Redundância = 2,5

(D) – indica detecção de erros grosseiros

TAB.4.20 – Detecção de um erro grosseiro com amplitude variável na medida P_2 .

MEDIDA: P_2				
Amplitude do erro grosseiro	$J(\hat{x})$	$J(\hat{x}) / \chi^2$	r_N	$r_N / N_{1-\alpha/2}$
20x σ	187,87	1,853 (D)	11,303	5,767 (D)
15x σ	128,15	1,264 (D)*	8,232	4,200 (D)
10x σ	87,29	0,861	5,161	2,633 (D)
9x σ	81,38	0,803	4,547	2,320 (D)
8x σ	76,22	0,752	3,932	2,006 (D)
7x σ	71,82	0,708	3,318	1,693 (D)
6x σ	68,18	0,672	2,704	1,379 (D)
5x σ	65,28	0,643	2,089	1,066 (D)
4x σ	63,15	0,623	1,475	0,752
3x σ	61,77	0,609	0,860	0,439
2x σ	61,14	0,603	0,246	0,126
1x σ	61,27	0,604	0,368	0,188
0	62,15	0,613	0,983	0,501
-1x σ	63,78	0,629	1,597	0,815
-2x σ	66,18	0,653	2,212	1,128 (D)
-3x σ	69,32	0,684	2,826	1,442 (D)
-4x σ	73,22	0,722	3,441	1,756 (D)
-5x σ	77,88	0,768	4,055	2,069 (D)
-6x σ	83,29	0,821	4,670	2,383 (D)
-7x σ	89,46	0,882	5,284	2,696 (D)
-8x σ	96,38	0,950	5,899	3,010 (D)
-9x σ	104,06	1,026 (D)	6,514	3,323 (D)
-10x σ	112,49	1,109 (D)	7,128	3,637 (D)
-15x σ	165,99	1,637 (D)	10,201	5,205 (D)
-20x σ	238,38	2,356 (D)	13,275	6,773 (D)

* - A detecção foi conseguida para 12x σ .

$$\chi^2_{0,99} = 101,4$$

$$\lambda = N_{1-\alpha/2} = 1,96$$

Graus de liberdade = 71

Redundância = 2,5

(D) – indica detecção de erros grosseiros

TAB.4.21 – Detecção de um erro grosseiro com amplitude variável na medida Q_{1-5} .

MEDIDA: Q_{1-5}				
Amplitude do erro grosseiro	$J(\hat{x})$	$J(\hat{x}) / \chi^2$	r_N	$r_N / N_{1-\alpha/2}$
20x σ	275,06	2,713 (D)	14,588	7,443 (D)
15x σ	177,38	1,749 (D)	10,742	5,481 (D)
10x σ	109,30	1,078 (D)	6,894	3,518 (D)
9x σ	99,24	0,979	6,125	3,125 (D)
8x σ	90,37	0,891	5,355	2,732 (D)
7x σ	82,69	0,815	4,585	2,339 (D)
6x σ	76,19	0,751	3,815	1,946 (D)
5x σ	70,88	0,699	3,045	1,554 (D)
4x σ	66,75	0,658	2,275	1,161 (D)
3x σ	53,82	0,531	1,505	0,768
2x σ	62,07	0,612	0,734	0,375
1x σ	61,52	0,608	0,036	0,018
0	62,15	0,613	0,807	0,411
-1x σ	63,97	0,631	1,577	0,805
-2x σ	66,98	0,661	2,348	1,198 (D)
-3x σ	71,18	0,702	3,118	1,591 (D)
-4x σ	76,57	0,755	3,889	1,984 (D)
-5x σ	83,16	0,820	4,660	2,377 (D)
-6x σ	90,93	0,897	5,431	2,771 (D)
-7x σ	99,90	0,985	6,202	3,164 (D)
-8x σ	110,06	1,085 (D)	6,973	3,558 (D)
-9x σ	121,41	1,197 (D)	7,744	3,951 (D)
-10x σ	133,95	1,321 (D)	8,515	4,344 (D)
-15x σ	214,57	2,116 (D)	12,372	6,312 (D)
-20x σ	325,07	3,206 (D)	16,231	8,281 (D)

$$\chi^2_{0,99} = 101,4$$

$$\lambda = N_{1-\alpha/2} = 1,96$$

$$\text{Graus de liberdade} = 71$$

$$\text{Redundância} = 2,5$$

(D) – indica detecção de erros grosseiros

Analisando os resultados apresentados nas tabelas anteriores, podemos concluir que a rotina de detecção de erros grosseiros nas medidas pelo método $J(\hat{x})$ tem um melhor desempenho quando os erros ocorrem nas medidas de tensão. Isso pode ser explicado com o maior peso que é atribuído no processo de estimação pelo método dos mínimos quadrados ponderados, a este tipo de medidas. Quando os erros ocorrem nas medidas de potência injectada ou fluxos de potência nas linhas, a rotina não é tão eficiente, sendo necessárias amplitudes de erros grosseiros superiores para que possam ser detectados.

Uma outra evidência é a influência da redundância das medidas no desempenho da rotina de detecção. Como se pode observar pelas tabelas 4.19, 4.20 e 4.21, a simulação dos erros grosseiros nas mesmas medidas originou que só fossem detectados para amplitudes superiores. Uma das explicações para esse facto pode ser a existência de um maior número de medidas junto das medidas afectadas pelos erros grosseiros. O gráfico seguinte indica a quantidade de medidas existente em cada uma das configurações de medidas, relacionadas com aquelas nas quais foram simulados os erros grosseiros.




Figura 4.7 – Número de medidas relacionadas com as medidas afectadas por erros grosseiros em cada configuração de medida.

Como se pode observar o número de medidas efectuadas nos barramentos onde se simularam os erros grosseiros e em barramentos vizinhos aumentou na configuração 2 (Conf.2), levando a uma menor influência da medida afectada no cálculo da função objectivo ($J(\hat{x})$) que serve de base à detecção de erros grosseiros nas medidas em erro.

Se for usado o método dos resíduos normalizados para efectuar a detecção de erros grosseiros nas medidas e considerando uma probabilidade de falso alarme (α) de 10%, pode-se concluir com base nos resultados apresentados pelas tabelas anteriores, que este tipo de teste apresenta uma melhor eficiência pois consegue detectar a presença do erro grosseiro para um menor valor da amplitude deste.

De salientar que para a simulação dos resultados anteriormente descritos, foi considerada a presença de apenas uma medida afectada por erro grosseiro. Nessas condições, a amplitude do resíduo identificou sempre correctamente a medida afectada.

Este método de detecção pode também ser aplicado à versão desacoplada isto porque, o $J(\hat{x})$ pode ser também desacoplado numa componente activa ($J_A(\hat{x})$) e outra reactiva ($J_R(\hat{x})$). Este desacoplamento do índice $J(\hat{x})$ torna-se vantajoso na fase de identificação pois, no caso de haver um erro grosseiro, a componente que obtiver maior valor, indica o tipo de medida afectada pelo erro, levando a uma mais rápida identificação da medida. Como se pode verificar pelas tabelas 4.22, 4.23 e 4.24, a componente activa ou reactiva do $J(\hat{x})$ vai variar de acordo com o tipo de medida afectada por erro grosseiro. Estas tabelas foram elaboradas com base na configuração de medida (Conf.1) da rede de 24 barramentos. Este procedimento foi efectuado para as duas configurações de medida das duas redes de teste e considerando a estimação de estado efectuada pela versão integral e desacoplada, tendo-se verificado um comportamento semelhante.

TAB.4.22 – Evolução do valor dos índices $J(\hat{x})$, $J_A(\hat{x})$ e $J_R(\hat{x})$ na presença de um erro grosseiro com amplitude variável na medida V_{17} .

MEDIDA: V_{17}			
Amplitude do erro grosseiro	$J(\hat{x})$	$J_A(\hat{x})$	$J_R(\hat{x})$
20x σ	334,20	5,57	328,63
15x σ	204,44	5,55	198,89
10x σ	110,18	5,53	104,65
9x σ	95,59	5,52	90,07
8x σ	82,42	5,52	76,90
7x σ	70,66	5,50	65,16
6x σ	60,33	5,50	54,83
5x σ	51,41	5,50	45,91
4x σ	43,91	5,49	38,42
3x σ	37,84	5,49	32,35
2x σ	33,18	5,49	27,71
1x σ	29,94	5,48	24,46
0	28,12	5,48	22,64
-1x σ	27,72	5,48	22,24
-2x σ	28,73	5,48	23,25
-3x σ	31,17	5,48	25,69
-4x σ	35,02	5,49	29,53
-5x σ	40,29	5,49	34,80
-6x σ	46,99	5,50	41,49
-7x σ	55,09	5,50	49,59
-8x σ	64,62	5,50	59,12
-9x σ	75,57	5,51	70,06
-10x σ	87,93	5,51	82,42
-15x σ	171,02	5,55	165,47
-20x σ	289,56	5,57	283,99

TAB.4.23 – Evolução do valor dos índices $J(\hat{x})$, $J_A(\hat{x})$ e $J_R(\hat{x})$ na presença de um erro grosseiro com amplitude variável na medida P_2 .

MEDIDA: P_2			
Amplitude do erro grosseiro	$J(\hat{x})$	$J_A(\hat{x})$	$J_R(\hat{x})$
20 $\times\sigma$	151,53	126,29	25,24
15 $\times\sigma$	96,46	71,71	24,75
10 $\times\sigma$	57,54	33,98	23,56
9 $\times\sigma$	51,68	28,31	23,37
8 $\times\sigma$	46,49	23,18	23,31
7 $\times\sigma$	41,93	18,68	23,25
6 $\times\sigma$	38,02	14,89	23,13
5 $\times\sigma$	34,76	11,68	23,08
4 $\times\sigma$	32,14	9,13	23,01
3 $\times\sigma$	30,16	7,20	22,96
2 $\times\sigma$	28,84	5,95	22,89
1 $\times\sigma$	28,16	5,59	22,67
0	28,12	5,48	22,64
-1 $\times\sigma$	28,72	6,29	22,43
-2 $\times\sigma$	29,98	7,74	22,24
-3 $\times\sigma$	31,89	9,83	22,06
-4 $\times\sigma$	34,44	12,57	21,87
-5 $\times\sigma$	37,63	15,94	21,69
-6 $\times\sigma$	41,47	19,96	21,51
-7 $\times\sigma$	45,96	24,62	21,34
-8 $\times\sigma$	51,09	29,92	21,17
-9 $\times\sigma$	56,87	35,77	21,10
-10 $\times\sigma$	63,30	42,46	20,84
-15 $\times\sigma$	105,13	85,04	20,09
-20 $\times\sigma$	163,11	143,69	19,42

TAB.4.24 – Evolução do valor dos índices $J(\hat{x})$, $J_A(\hat{x})$ e $J_R(\hat{x})$ na presença de um erro grosseiro com amplitude variável na medida Q_{1-5} .

MEDIDA: Q_{1-5}			
Amplitude do erro grosseiro	$J(\hat{x})$	$J_A(\hat{x})$	$J_R(\hat{x})$
20xσ	183,81	5,00	178,81
15xσ	109,96	5,09	104,87
10xσ	59,36	5,37	53,99
9xσ	52,03	5,40	46,63
8xσ	45,64	5,44	40,20
7xσ	40,18	5,46	34,72
6xσ	35,65	5,48	30,17
5xσ	32,06	5,50	26,56
4xσ	29,40	5,51	23,89
3xσ	27,68	5,52	22,16
2xσ	26,89	5,51	21,38
1xσ	27,03	5,50	21,53
0	28,12	5,48	22,64
-1xσ	30,14	5,48	24,66
-2xσ	33,09	5,45	27,64
-3xσ	36,98	5,41	31,57
-4xσ	41,81	5,38	36,43
-5xσ	47,58	5,34	42,24
-6xσ	54,29	5,29	49,00
-7xσ	61,94	5,25	56,69
-8xσ	70,52	5,18	65,34
-9xσ	80,04	5,11	74,93
-10xσ	90,51	5,05	85,46
-15xσ	156,95	4,62	152,33
-20xσ	246,95	4,03	242,92

Quando a rotina de detecção informa que existem medidas afectadas por erros grosseiros, na realidade não se tem conhecimento, à partida, de quantas medidas estão afectadas. Por esse motivo, é importante para além de detectar a presença ou não de erros grosseiros, poder identificá-los. O processo de identificação, já referido no capítulo 3, pode basear-se em vários métodos. O método escolhido para implementação nesta tese foi o dos resíduos normalizados. Quando só existe uma medida afectada por erro grosseiro este método já mostrou ser eficaz. De seguida será avaliado o desempenho do mesmo método na presença de mais do que uma medida afectada de erros grosseiros. Para isso, simulou-se a presença de erros grosseiros nas medidas P_{1-2} , Q_{10-12} e V_{18} de amplitude igual respectivamente a $20\sigma_i$, $15\sigma_i$ e $30\sigma_i$.

Obtida a primeira estimativa do estado do sistema ($\hat{x}$), a realização do teste do $J(\hat{x})$ detectou a presença de pelo menos uma medida afectada por erro grosseiro (Tabela 4.25). Seguidamente serão calculados os resíduos normalizados (Tabela 4.26) sendo apresentados os cinco resíduos normalizados de maior amplitude. Após a primeira identificação das possíveis medidas afectadas por erros grosseiros, existem várias formas de lidar com esse problema. Uma delas é a eliminação da medida responsável pelo maior resíduo e de seguida voltar a estimar o estado do sistema sem essa medida. Este procedimento deverá ser executado até que o teste do $J(\hat{x})$ não detecte a presença de erros grosseiros. Outro método consiste na substituição das medidas identificadas, por pseudomedidas.

Estes dois métodos serão implementados de seguida e no final serão retiradas as conclusões.

Tabela 4.25 – Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$

	$J(\hat{x})$	$J(\hat{x}) / \chi^2$
1º ciclo	1048,1	24,37 (D)

$$\chi^2_{0,99} = 43,0$$

(D) – indica detecção

Tabela 4.26 – Resíduos normalizados de maior amplitude – 1º ciclo

Medida	V ₁₈	Q ₁₀₋₁₂	P ₁₋₂	P ₂	P ₁₋₃
Amplitude do resíduo normalizado	27,21	15,00	14,65	9,27	9,03

4.6.1 – Identificação por eliminação

O método proposto irá fazer a cada ciclo de estimação – detecção/identificação - reestimação, a eliminação da medida responsável pelo maior resíduo. O processo repete-se até que não sejam detectados erros grosseiros, estando os resultados obtidos nos diferentes ciclos indicados nas tabelas 4.27, 4.28, 4.29, 4.30 e 4.31.

- 2º ciclo - eliminada a medida V₁₈

Tabela 4.27 – Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 2º ciclo

	$J(\hat{x})$	$J(\hat{x}) / \chi^2$
2º ciclo	306,9	7,13 (D)

$$\chi^2_{0,99} = 43,0$$

(D) – indica detecção de erros grosseiros

Tabela 4.28– Resíduos normalizados de maior amplitude – 2º ciclo

Medida	P ₁₋₂	P ₁₋₃	P ₁	P ₂	Q ₁₀₋₁₂
Amplitude do resíduo normalizado	14,67	9,17	9,16	9,15	8,67

- 3º ciclo - eliminada a medida P_{1-2}

Tabela 4.29 – Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 3º ciclo

	$J(\hat{x})$	$J(\hat{x}) / \chi^2$
3º ciclo	91,6	2,13 (D)

$$\chi^2_{0,99} = 43,0$$

(D) – indica detecção de erros grosseiros

Tabela 4.30 – Resíduos normalizados de maior amplitude – 3º ciclo

Medida	Q_{10-12}	P_{10-12}	V_6	Q_{12-13}	V_{17}
Amplitude do resíduo normalizado	8,75	8,31	4,26	4,16	4,11

- 4º ciclo - eliminada a medida Q_{10-12}

Tabela 4.31 – Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 4º ciclo

	$J(\hat{x})$	$J(\hat{x}) / \chi^2$
4º ciclo	27,3	0,63

$$\chi^2_{0,99} = 43,0$$

Neste ciclo o teste do $J(\hat{x})$ não detectou a presença de erros grosseiros nas medidas.

Como se pode verificar, o método detectou e identificou correctamente as medidas afectadas pelos erros grosseiros, no entanto a eliminação de medidas que poderão, ou não estar afectadas por erros grosseiros leva à diminuição da redundância de medidas e a um aumento do correlacionamento dos resíduos. Estes factos têm como consequência a diminuição da eficácia do teste de detecção e a possibilidade de tornar a rede inobservável

4.6.2 – Geração de pseudomedidas

As pseudomedidas são valores que com alguma precisão se podem atribuir a certas medidas do sistema. Elas poderão ser obtidas recorrendo a valores das medidas respectivas guardadas em bases de dados, por recurso a previsões de carga a curto prazo ou até mesmo à experiência do operador. Uma outra forma de gerar um valor mais preciso para a medida afectada por erro pode ser determinada à custa de uma fórmula baseada na matriz covariância dos resíduos.

O novo valor a usar para a medida em erro (z_i^n) poderá ser obtido de:

$$z_i^n = z_i^m - \frac{\sigma_i^2}{cov(r_{ii})} (z_i^m - z_i^c) \quad (4.21)$$

em que:

- z_i^m - Valor atribuído a z_i , na qual foi posteriormente detectada a presença de um erro grosseiro.
- z_i^c - Valor de z_i calculado a partir dos valores estimados inicialmente para V e θ .
- σ^2 - Variância associada ao ruído de medida de z_i .
- $cov(r_{ii})$ - Elemento i da diagonal principal da matriz covariância dos resíduos.

A eficácia deste método de geração de pseudomedidas, foi comprovada pela realização de diversos testes. Nas tabelas 4.32, 4.33 e 4.34 encontram-se compilados os resultados obtidos. Da análise dos resultados pode concluir-se que os valores gerados para as pseudomedidas são muito próximos dos verdadeiros valores das grandezas medidas e consequentemente a estimativa do estado do sistema após reestimação será fiável.

Tabela 4.32 – Precisão das medidas geradas para a medida V_{18} .

Medida	Amplitude do erro grosseiro	Verdadeiro valor (pu)	Valor medido (pu)	Valor estimado (pu)	Valor gerado (pu)
V_{18}	$20\times\sigma$	1,0000	1,0200	1,0060	0,9999
	$15\times\sigma$	1,0000	1,015	1,0044	0,9998
	$7\times\sigma$	1,0000	1,0070	1,0020	0,9998
	$-7\times\sigma$	1,0000	0,9930	0,9978	0,9998
	$-15\times\sigma$	1,0000	0,9850	0,9954	0,9998
	$-20\times\sigma$	1,0000	0,9800	0,9939	0,9999

Tabela 4.33 – Precisão das medidas geradas para a medida P_{1-2} .

Medida	Amplitude do erro grosseiro	Verdadeiro valor (pu)	Valor medido (pu)	Valor estimado (pu)	Valor gerado (pu)
P_{1-2}	$20\times\sigma$	0,0742	0,2742	0,1701	0,0632
	$15\times\sigma$	0,0742	0,2242	0,1147	0,0630
	$7\times\sigma$	0,0742	0,1442	0,1042	0,0631
	$-7\times\sigma$	0,0742	0,0042	0,0333	0,0631
	$-15\times\sigma$	0,0742	-0,0758	-0,0072	0,0631
	$-20\times\sigma$	0,0742	-0,1258	-0,0325	0,0631

Tabela 4.34 – Precisão das medidas geradas para a medida Q_{10-12} .

Medida	Amplitude do erro grosseiro	Verdadeiro valor (pu)	Valor medido (pu)	Valor estimado (pu)	Valor gerado (pu)
Q_{10-12}	$20\times\sigma$	0,0843	0,2843	0,2229	0,0761
	$15\times\sigma$	0,0843	0,2343	0,1876	0,0860
	$7\times\sigma$	0,0843	0,1543	0,1313	0,0773
	$-7\times\sigma$	0,0843	0,0143	0,0333	0,0770
	$-15\times\sigma$	0,0843	-0,0657	-0,0222	0,0767
	$-20\times\sigma$	0,0843	-0,1157	-0,0568	0,0762

De seguida será demonstrado o comportamento do algoritmo desenvolvido, na presença de mais do que uma medida afectada por erros grosseiros. As medidas afectadas e as amplitudes dos erros grosseiros serão os mesmo que foram usados no ponto 4.6.1.

Os resultados do primeiro ciclo de estimação - detecção estão representados nas tabelas 4.25 e 4.26.

- 2º ciclo - Corrigir a medida V_{18}

O valor gerado para a medida V_{18} foi 0,9976 pu

Tabela 4.35 – Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 2º ciclo

	$J(\hat{x})$	$J(\hat{x}) / \chi^2$
2º ciclo	317	7,37 (D)

$$\chi^2_{0,99} = 43,0$$

(D) – indica detecção de erros grosseiros

Tabela 4.36 – Resíduos normalizados de maior amplitude – 2º ciclo

Medida	P_{1-2}	P_2	P_{1-3}	P_1	Q_{10-12}
Amplitude do resíduo normalizado	14,78	9,33	9,10	9,09	8,03

- 3º ciclo - Corrigir a medida P_{1-2}

O valor gerado para a medida P_{1-2} foi 0,0637 pu

Tabela 4.37 – Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 3º ciclo

	$J(\hat{x})$	$J(\hat{x}) / \chi^2$
3º ciclo	98	2,37 (D)

$$\chi^2_{0,99} = 43,0$$

(D) – indica detecção de erros grosseiros

Tabela 4.38 – Resíduos normalizados de maior amplitude – 3º ciclo

Medida	Q_{10-12}	V_6	Q_{16}	Q_{12-13}	Q_{11-13}
Amplitude do resíduo normalizado	8,10	4,90	4,15	3,90	3,85

- 4º ciclo - Corrigir a medida Q_{10-12}

O valor gerado para a medida Q_{10-12} foi 0,0855 pu

Tabela 4.39 – Valores de $J(\hat{x})$ e $J(\hat{x}) / \chi^2$ – 3º ciclo

	$J(\hat{x})$	$J(\hat{x}) / \chi^2$
4º ciclo	31,2	0,72

$$\chi^2_{0,99} = 43,0$$

Uma comparação da precisão das estimativas obtidas pode avaliar-se pela análise da figura 4.8 e da tabela 4.40 onde estão representados os erros médios e máximo na estimação do vector de estado. Foram comparadas as estimativas considerando:

- o vector de medidas sem erros grosseiros;
- o vector de medidas sem as medidas identificadas como erradas (Medidas eliminadas);
- o vector de medidas com as medidas identificadas corrigidas (Medidas corrigidas).

Tabela 4.40 – Erros de estimação (médio e máximo) no vector de estado.

	θ_{med}	θ_{max}	V_{med}	V_{max}
Sem erros grosseiros	3,91E-04	1,49E-03	9,62E-04	4,80E-03
Medidas eliminadas	5,21E-04	2,09E-03	9,33E-04	4,80E-03
Medidas corrigidas	3,28E-04	1,49E-03	1,14E-03	4,80E-03




Figura 4.8 – Comparação dos erros de estimação no vector de estado.

4.7 - CONCLUSÕES

Neste capítulo foi analisado o comportamento dos algoritmos de estimação de estado implementados, nomeadamente o método WLS na sua versão integral e na versão desacoplada.

No início foi efectuada uma descrição dos métodos de estimação de estado implementados, uma descrição das redes de teste e das configurações de medidas usadas nas simulações.

Na análise dos resultados estudou-se com particular atenção o comportamento do vector de estado estimado para os diversos algoritmos implementados e para as diversas configurações de medidas, na presença e ausência de erros grosseiros.

Foram também testados métodos de detecção e identificação de erros grosseiros nas medidas, um baseado no teste do $J(\hat{x})$ e outro no cálculo dos resíduos normalizados.

Finalmente foi ainda testado um método correcção do vector das medidas por eliminação das medidas prováveis de estarem afectadas por erros grosseiros e um outro método de correcção das possíveis medidas afectadas por erros baseado na substituição das mesmas por pseudomedidas.

Os resultados e a análise dos vários testes foram apresentados ao longo do desenvolvimento do capítulo.

CAPÍTULO 5

CONCLUSÃO

Capítulo 5

CONCLUSÃO

Nesta tese foi desenvolvida investigação sobre algoritmos para estimação de estado estática de SEE, baseados no método dos mínimos quadrados ponderados.

A estimação de estado é uma ferramenta importante dentro dos centros de controlo e condução dos sistemas eléctricos de energia. Dela depende a criação de uma base de dados coerente e fiável que auxilia as acções a tomar pelos operadores do sistema, para que a condução do mesmo se faça dentro de parâmetros, de qualidade técnica e económica preestabelecidos.

O conhecimento do estado da rede em tempo real é uma necessidade imposta pelas novas exigências relativas ao funcionamento dos mercados de energia. A liberalização do sector eléctrico e o aparecimento da competitividade leva à exploração dos SEE muito próxima dos limites de segurança e capacidade. Para garantir o assegurar de todas estas necessidades, novas funções foram acrescentadas aos tradicionais centros de controlo que se transformaram em sistemas de gestão de energia (EMS). Também nestes EMS, a existência de uma base de dados confiável e coerente é imprescindível, assumindo a estimação de estado um papel preponderante.

Neste trabalho de investigação foram implementados algoritmos para a estimação de estado estática em SEE, baseados no método dos mínimos quadrados ponderados.

Neste método, a melhor estimativa do estado do sistema é atingida quando, a soma ponderada do quadrado dos resíduos é mínima, sendo a ponderação atribuída de acordo com a precisão das medidas efectuadas.

O método implementado foi dividido em duas versões, a versão standard integral (WLS) e uma versão que recorre ao desacoplamento das matrizes ganho e jacobiana (MDE).

Da análise dos resultados pode concluir-se que a versão integral é a que produz estimativas mais precisas para o vector de estado e com menor número de iterações, contudo a versão desacoplada, compensa a menor precisão das estimativas com uma boa eficiência computacional, quer ao nível da rapidez de cálculo quer ao nível de memória necessária.

Uma característica importante do método dos mínimos quadrados ponderados é o facto da matriz $[H^T R^{-1} H]^{-1}$ ser interpretada como sendo a matriz covariância do erro de estimação, que podendo ser calculada previamente à implementação do estimador de estado, permite estudar a influência da localização, tipo e precisão da aparelhagem de medida na precisão da estimativa obtida.

A qualidade e o desempenho do algoritmo de estimação de estado depende da sua capacidade em detectar, identificar e corrigir as medidas afectadas por erros grosseiros. Uma vantagem do uso do método dos mínimos quadrados ponderados é a simplicidade de implementação dos métodos de detecção e identificação de erros grosseiros que lhe estão associados. Sobre este assunto, foram analisados no capítulo 3, algumas das metodologias normalmente utilizadas.

Foi implementado o teste da soma pesada do quadrado dos resíduos, ou da função critério $J(\hat{x})$ e um teste baseado nos resíduos normalizados, para a detecção de erros grosseiros nas medidas e um processo de geração de pseudomedidas que determina o novo valor das medidas consideradas como estando afectadas por erros grosseiros à custa de uma fórmula baseada na matriz covariância dos resíduos. Os testes realizados com erros

múltiplos não correlacionados indicam que o estimador necessita de tantos ciclos de detecção / eliminação e reestimação quanto o número de medidas afectadas com erros, o que torna o processo de estimação de estado bastante demorado.

O trabalho que serviu de base a esta tese não está totalmente finalizado. Poderia ser desenvolvido e melhorado em vários aspectos, dos quais destaco:

- o desenvolvimento de algoritmos para obtenção da observabilidade do SEE em estudo;
- o desenvolvimento de um algoritmo que permita escolher a configuração de medidas que melhor satisfaça os objectivos predefinidos.

A dissertação aqui apresentada abre caminho para novas perspectivas de investigação na área da estimação de estado de SEE que pretendo realizar, nomeadamente o desenvolvimento de uma metodologia de processamento paralelo e distribuído para a estimação de estado dinâmica. Uma outra área interessante seria a utilização da lógica fuzzy na estimação de estado tendo por base métodos alternativos ao convencional WLS.

BIBLIOGRAFIA

Bibliografia

- [1] Pedro Zarco and António Gómez Expósito, - *Power System Parameter Estimation: A Survey*. IEEE, Vol. 3, 13-17 July 2003.
- [2] W.-H. Edwin Liu, Swee-Lian Lim, - *Parameter Error Identification and Estimation in Power System State Estimation*. IEEE Trans. On Power Systems, vol. 10, no. 1, Feb. 1995.
- [3] Zita A. Vale, - *Exploração dos Sistemas Eléctricos de Energia*. Revista da Universidade Moderna do Porto, Colecção Ciências da Engenharia, pag.83-131, Março 2001.
- [4] W. Ackerman, W. Block, - *Understanding Supervisory Systems*. IEEE Computer Applications in Power, vol. 5, n. 4, pp. 37-40, EUA, Oct. 1992.
- [5] Zita A. Vale, - *Knowledge-Based Systems Techniques and Applications in Power Systems Control Centers*, em “Intelligent Systems Technologies and Applications”, Ed. Cornelius T.Leondes, CRC Press, vol. 6, pag. 61-110.
- [6] José B. Carvalho, - *O processamento Distribuído na Estimação de Estado de Sistemas Eléctricos de Energia*. Tese de Doutoramento, FEUP, 1999.
- [7] Papoulis, A. - *Probability, Random Variables and Stochastic Processes*. McGraw-Hill Publishing Company Ltd, New York, 1969

- [8] Dopazo, J.F.; Klitin, O. e Van Slyck, L.S. – *Implementation of the AEP Real-Time Monitoring System*. Proc. of the IEEE /PES Winter Meeting and Tesla Symposium, New York, January 1976.
- [9] Peter J. Katsikas, George N. Korres. – *Unified Observability and Measurement Placement in Generalized State Estimation*. IEEE Trans. Power Systems, Vol. 18, No.1, pp.324-333, Feb. 2003.
- [10] M.K. Celikand W-H. E Liu. – *An Incremental Measurement Placement Algorithm for State estimation*. IEEE trans. Power Systems, vol. 10(3), pp. 1698-1703, 1995.
- [11] Mafaakher, F., Brameller, A. e Bermudez, J.F.- *Optimal Metering Design Using Fast Decoupled Estimator*. Proceedings of IEE, Vol. 126, January 1979.
- [12] Korres, G.N. e Contaxis, G.C. – *A tool for the Evaluation and Selection os State Estimator Measurement Schemes*. IEEE Trans. Power Syst., Vol. 9, nº 2, May 1994.
- [13] A. Radovanovic. – *Using the Internet in Networking of Synchronized Phasor measurement Units*. ELSEVIER - International Journal of Electrical Power & Energy Systems, no. 23 (2001), pp. 245- 250.
- [14] Schweppe, F.C.; Wildes J. e Rom, D.B. – *Power System Static-State Estimation, Parts I, II, III*. IEEE Trans. On Pas, Vol. Pas-89, January 1970.
- [15] Do Couto Filho, M.B.; Leite da Silva, A.M. e Falcão, D.M., - *Bibliography On Power System State Estimation (1968-1989)*. IEEE Trans. on PWRS, Vol. 5, August 1990.
- [16] Isabel Maria Ferreira, –*A Estimação de Estado de Sistemas Eléctricos de Energia*. Tese de Doutoramento, FEUP, 1995.

- [17] Lars Holten, Anders Gjelsvik, Sverre Aam, Felix F. Wu, Wen-Hsiung E. Liu, – *Comparison of Different Methods for State Estimation*. vol. 3, No. 4, pp. 1798-1806, Nov. 1988.
- [18] F.C. Schweppe and E.J. Handschin, –*Static State Estimation in Electric Power Systems*. Proc. IEEE, vol. 62, pp.972-983, July 1974.
- [19] J.W. Gu, K.A. Clements, G.R. Krumpholtz, P.W. Davis. –*The Solution of Ill-Conditioned Power System State Estimation Problems via the Method of Peters and Wilkinson*. IEEE Trans. On Power Apparatus and Systems, vol. 102, pp. 3473-3480, Oct 1983.
- [20] K. A. Clements, G. W. Woodzell, R. C. Burchett, “A New Method for Solving Equality-Constrained Power System Static State Estimation”, IEEE Transactions on Power Systems, Vol. 5, No. 4, pp. 1260-1266, Nov. 1990.
- [21] J.M.Ramírez, E.E. Barocio. –*Solving State Estimation in Power Systems by an Interior Point method*. ELSEVIER- International Journal of Electrical Power & Energy Systems, no. 22, pp. 355-365, Jun 2000.
- [22] Faridoon Shababi, Nadipuran R. Prasad, Howard A.Smolleck, –*A fuzzy-logic-supported weighted least squares state estimation*. ELSEVIER- Electric Power Systems Research (39), pp. 55-60, 1996.
- [23] V. Miranda, Jorge Pereira, J. Tomé Saraiva, –*Load Allocation in DMS with a Fuzzy State Estimator*. IEEE Transactions on Power Systems, Vol. 15, No. 2, pp. 529-534, May 2000.

- [24] V. Miranda, J. Pereira, J. T. Saraiva, – *Experiences in State Estimation Models for Distribution Systems Including Fuzzy Systems*, Proceedings of StockholmPower Tech, Stockholm, Sweden, June 1995.
- [25] V. Miranda, M. Matos, J. T. Saraiva, – *Fuzzy Load Flow - New Algorithms Incorporating Uncertain Generation and Load Representation*. 10th PSCC, Graz, August 1990; Proceedings of the 10th PSCC, Butterworths, London, 1990.
- [26] Stott,B. e Alsac, O. -*Fast Decoupled Load Flow*. IEEE Trans. on PWRS, Vol.PAS-93, nº3, May /June, 1974.
- [27] Horisberger, H.P.; Richard, J. e Rossier, C. -*Fast Decoupled Static State Estimator for Electric Power Systems*. IEEE Trans. on PWRS, Vol.PAS-98, nº1, January /February, 1976.
- [28] Monticelli, A. e Garcia, A. -*Fast Decoupled State Estimators*. IEEE Trans. on PWRS, Vol. 5, May 1990.
- [29] I.M. Ferreira, F.M. Barbosa. –*Uma Visão Global da Estimação de Estado de S.E.E.*, Proc. of 'Jornadas Luso-Espanholas de Engenharia Electrotécnica, July 7-9, 1999. Lisboa, Portugal.
- [30] J.K. Mandal,A.K. Sinha. –*Hierarchical Dynamic State Estimation Incorporating Measurement Function Non-linearities*. Electrical Power & Energy Systemas, Vol. 19, no 19,1997.
- [31] Kevin Judd, –*Nonlinear State Estimation, indistinguishable States, and the Extended Kalman Filter*. ELSEVIER-Physica D (183), pp. 273-281, 2003

- [32] G. Durga Prasad, S.S.Thakur, – *A New Approach to dynamic State Estimation of Power Systems*. Electric Power System Research 45 (1998) pag. 173-180.
- [33] C. Madtharad, S. Premrudeepreechacharn, N.R. Watson, D. Saenrak.- *Measurement Placement Method for Power System State Estimation: PartI*. IEEE, Vol. 3, 13-17 July 2003.
- [34] Nabil H. Abbasy, Wael El-hassawy, – *Power system State Estimation: ANN Application to bad data detection and identification*. IEEE pp 611-615, 1996
- [35] Neter, J., Wasserman, W. e Whitmore, G. A. – *Applied Statistics*. Allyn and Bacon, Needham Heights, 1993.
- [36] Berenson, M.L. e Levine, D.M. – *Basic Business Statistics*. Prentice-Hall, Inc., Englewood Clifs, New Jersey, 1992.
- [37] Dougherty, E.R. – *Probability and Statistics for the Engineering, Computing and Physical Sciences*. Prentice-Hall, Inc., Englewood Clifs, New Jersey, 1990.
- [38] Spiegel, M.R. – *Theory and Problems of Probability and Statistics*. McGraw-Hill, New York, 1977.
- [39] A. Monticelli, – *Electric Power System State Estimation*. Proc. IEEE, vol. 88, No. 2, Feb. 2000
- [40] Sorenson, H.W. – *Parameter Estimation*. Marcel Dekker, New York, 1980.
- [41] Goodwin, G.C. e Payne, R.L. – *Dynamic System Identification: Experiment Design and Data Analysis*. Academic Press, New York, 1977.

- [42] Lo, K.L., Ong, P.S.; McColl, Moffatt, e Sulley. – *Development of a Static-State Estimator, Part I: Estimation and Bad Data Suppression*. IEEE Trans. On Pas, Vol. Pas-102, August 1983.
- [43] Handschin, E.; Schweppe, F.C. e Fietcher, A. - *Bad Data Analysis For Power System State Estimation*. IEEE Trans. on PWRS, Vol. PAS-94, March / April 1975.
- [44] Merrill, H.; Schweppe, F.C. - *Bad Data Supression in Power System Static State Estimation*. IEEE Trans. on PWRS, Vol. PAS-90, November / December, 1971
- [45] Mili, L.; Van Cutsem, e Pavella, R., –*Hypothesis Testing Identification*. IEEE Trans. on PWRS, Vol. 103, nº 11, November 1984.
- [46] Dougherty, E.R. – *Probability and Statitics for the Engineering, Computing and Phisical Sciences*. Prentice-Hall, New Jersey, 1990.

APÊNDICES

Apêndice A

Propriedades do Estimador WLS / Determinação das Matrizes Covariância

A introdução de algumas hipóteses relativas à modelização estatística do ruído de medida permite, com base nos resultados obtidos por linearização das equações de estimação, caracterizar o estimador WLS. Assim:

1. Se e tiver média nula, o estimador WLS é não enviesado. Se atendermos à equação (D.7) obtemos:

$$E(\delta_x) = E\left(-\sum_x H^T R^{-1} e\right) = -\sum_x H^T R^{-1} E(e) = 0 \quad (\text{A.1})$$

de um modo análogo pode-se concluir que:

$$E(\delta_h) = E(r) = 0 \quad (\text{A.2})$$

2. Se e tiver média nula e matriz covariância R , então as expressões para $cov(\delta_h)$ e $cov(r)$ são:

$$cov(\delta_h) = H \sum_x H^T \quad (\text{A.3})$$

$$cov(r) = R - H \sum_x H^T = WR \quad (\text{A.4})$$

em que W é a matriz sensibilidade dos resíduos aos erros de medida, definida no Apêndice D.

Para demonstrar as equações anteriores começa-se por obter a matriz covariância de δ_x .

Assumindo que $\delta_x = -\sum_x H^T R^{-1} e$, em que

$$\sum_x = \left[H^T R^{-1} H \right]^{-1},$$

vem:

$$E[\delta_x \delta_x^T] = \sum_x H^T R^{-1} E[ee^T] R^{-1} H \sum_x = \sum_x \quad (A.5)$$

Atendendo a que

$$\delta_h = H \delta_x = -H \sum_x H^T R^{-1} e = -S e \quad (A.6)$$

em que:

$$S = H [H^T R^{-1} H]^{-1} H^T R^{-1} \quad (A.7)$$

é a matriz sensibilidade dos erros de estimação das grandezas medidas, aos erros de medida, e considerando que:

$$\begin{aligned} r &= z - h(\hat{x}) = h(x) + e - h(\hat{x}) \\ &= H \delta_x + e = -H [H^T R^{-1} H]^{-1} H^T R^{-1} e + e \\ &= [I - H (H^T R^{-1} H)^{-1} H^T R^{-1}] e \\ &= W e \end{aligned} \quad (A.8)$$

Atendendo às equações (A. 6), (A.8) e (A.2) obtém-se:

$$\begin{aligned} cov(\delta_h) &= E[\delta_h \delta_h^T] = E[H \delta_x \delta_x^T H^T] \\ &= H cov(\delta_x) H^T = H \sum_x H^T \\ cov(r) &= E[r r^T] = E[W e e^T W^T] \\ &= [I - H \sum_x H^T R^{-1}] R [I - R^{-1} H \sum_x H^T] \\ &= [R - H \sum_x H^T] [I - R^{-1} H \sum_x H^T] \end{aligned} \quad (A.9)$$

$$\begin{aligned}
&= R - H \sum_x H^T - H \sum_x H^T + H \sum_x H^T R^{-1} H \sum_x H^T \\
&= R - H \sum_x H^T - H \sum_x H^T + H \sum_x H^T \\
&= R - H \sum_x H^T = \sum_r
\end{aligned} \tag{A.10}$$

As expressões obtidas para os vectores δ_x , δ_h , r e respectivas matrizes covariância, apresentam-se compiladas na tabela seguinte.

Tabela A.1 – Vectores δ_x , δ_h , r e respectivas matrizes covariância.

Grandeza	Definição	$\sum_x = [H^T R^{-1} H]^{-1}$ $E(\delta_x) = E(\delta_h) = E(r) = 0$
δ_x	$= x - \hat{x}$	$= -\sum_x H^T R^{-1} e$
δ_h	$= h(x) - h(\hat{x})$	$= -H \sum_x H^T R^{-1} e = -S e$
r	$= z - h(\hat{x})$	$= [I - H \sum_x H^T R^{-1}] e = W e$
$cov(\delta_x)$	$= E[\delta_x \delta_x^T]$	$= \sum_x$
$cov(\delta_h)$	$= E[\delta_h \delta_h^T]$	$= H \sum_x H^T$
$cov(r)$	$= E[r \cdot r^T]$	$= R - H \sum_x H^T = W R$

3. Se e tiver distribuição normal os vectores δ_x , δ_h e r também apresentam distribuição normal.

Esta conclusão resulta das relações lineares expressas anteriormente pelas equações (D.7), (D.10), (D.13) e da seguinte propriedade [7]: “transformações lineares de variáveis aleatórias gaussianas são também variáveis aleatórias gaussianas”.

4. Se e tiver distribuição normal, $N(0, R)$, o estimador dos mínimos quadrados ponderados que temos vindo a analisar é um estimador eficaz.

Apêndice B

Comportamento de r e $J(\hat{x})$ na Presença de Erros Grosseiros

A metodologia de detecção dos erros grosseiros que poderão eventualmente afectar as medidas recolhidas ao longo da rede, assenta fundamentalmente no conhecimento da variável aleatória $J(\hat{x})$ que é definida por:

$$J(\hat{x}) = [z - h(\hat{x})]^T R^{-1} [z - h(\hat{x})] \quad (\text{B.1})$$

Para implementar esta metodologia é necessário o conhecimento prévio da função densidade de probabilidade de $J(\hat{x})$ na ausência de erros grosseiros, sendo possível demonstrar a seguinte afirmação:

“Se $e \sim N(0, R)$ com $R = \text{diag}(\sigma_i^2)$, então $J(\hat{x})$ tem distribuição qui-quadrado com $(m - n)$ graus de liberdade”.

em que, n representa o número de variáveis de estado do sistema e m o número de medidas.

Realmente, considerando a equação (B.1) e atendendo a que $r = z - h(\hat{x}) = W.e$, obtém-se:

$$J(\hat{x}) = r^T R^{-1} r = e^T W^T R^{-1} W e \quad (\text{B.2})$$

Dado que $W^T R^{-1} W = R^{-1} W$, vem:

$$\begin{aligned}
 J(\hat{x}) &= e^T R^{-1} W e = e^T R^{-1} (I - H \Sigma_x H^T R^{-1}) e \\
 &= e^T R^{-1/2} (I - R^{-1/2} H \Sigma_x H^T R^{-1/2}) R^{-1/2} e \\
 &= (R^{-1/2} e)^T R^{-1/2} W R^{1/2} (R^{-1/2} e)
 \end{aligned} \tag{B.3}$$

em que:

$$R^{1/2} = \sqrt{R} = \text{diag}(\sigma_i) \quad i = 1, \dots, m$$

A caracterização da função densidade de probabilidade de $J(\hat{x})$ resulta da equação (B.3) e da seguinte propriedade [40, 41]:

“Seja y ($m \times 1$) uma variável aleatória com distribuição normal, $y \sim N(0, I)$ e seja A uma matriz simétrica, semi-definida positiva, idempotente e de característica $k < m$. Então a forma quadrática $y^T A y$ tem distribuição χ^2 (qui-quadrado) com k graus de liberdade”.

Verificando que a matriz $R^{-1/2} W R^{1/2}$ e o vector $R^{-1/2} e$ satisfazem realmente as condições da propriedade anteriormente enunciada e como $r(R^{-1/2} W R^{1/2}) = m - n$, pode-se concluir que $J(\hat{x}) \sim \chi^2$, sendo o número de graus de liberdade definidos por $m - n$ e portanto:

$$E[J(\hat{x})] = m - n \tag{B.4}$$

$$\text{var}[J(\hat{x})] = 2(m - n) \tag{B.5}$$

Sempre que o número de graus de liberdade aumenta, a distribuição χ^2 tende para uma distribuição normal com o mesmo valor médio e o mesmo desvio padrão. Habitualmente faz-se a aproximação χ^2 pela distribuição normal quando o número de graus de liberdade é superior a 30, definindo-se então uma variável aleatória auxiliar ξ com distribuição $N(0,1)$:

$$\xi = \frac{J(\hat{x}) - (m - n)}{\sqrt{2(m - n)}} \tag{B.6}$$

As conclusões até aqui obtidas, baseiam-se na linearização do modelo que relaciona o vector das medidas (z) recebidas no centro de controlo, com o vector de estado (x), em torno da estimativa $\hat{x}$ e nas relações daí decorrentes. Esta hipótese simplificativa garante de um modo geral, bons resultados relativamente à detecção e identificação de erros grosseiros. Uma vez que $r = W e$ e substituindo e por $(v + g)$, cuja definição se encontra no capítulo 3, obtém-se:

$$r = W(v + g) = W v + W g \quad (\text{B.7})$$

e consequentemente:

$$E(r) = W g \quad \text{cov}(r) = W R \quad (\text{B.8})$$

Nesta situação, o vector dos resíduos tem a seguinte caracterização estatística:

$$r \sim N(Wg, WR) \quad (\text{B.9})$$

Para a variável aleatória $J(\hat{x})$ e considerando a equação (B.3), obtém-se:

$$\begin{aligned} J(\hat{x}) &= e^T R^{-1} W e \\ &= (v + g)^T R^{-1} W (v + g) \\ &= v^T R^{-1} W v + 2g^T R^{-1} W v + g^T R^{-1} W g \end{aligned} \quad (\text{B.10})$$

Por análise da equação (B.10) pode-se verificar que o primeiro termo que aí aparece corresponde à expressão de $J(\hat{x})$ na ausência de erros grosseiros, (B.3). Como atrás se referiu, esse termo possui distribuição χ^2 com $m - n$ graus de liberdade. O segundo termo tem distribuição normal e o último termo é uma constante. Pode-se então afirmar que, quando o número de graus de liberdade for superior a 30, a distribuição de $J(\hat{x})$ pode ser aproximada por uma distribuição normal.

Apêndice C

Resíduos Normalizados e Resíduos Ponderados

Quando não existem erros grosseiros a contaminar as medidas, a equação $r \sim N(0, WR)$, caracteriza estatisticamente o vector dos resíduos. A partir de r , podem-se definir dois novos vectores de resíduos, o vector dos resíduos normalizados (r_N) e o vector dos resíduos ponderados (r_W), usualmente utilizados para a detecção de erros grosseiros [42, 43, 44, 45]. Estes vectores são definidos da seguinte forma:

$$r_W = \sqrt{R^{-1}} \cdot r \quad (C.1)$$

$$r_N = \sqrt{D^{-1}} \cdot r \quad (C.2)$$

em que:

$$D = \text{diag}(WR) \quad (C.3)$$

sendo as respectivas matrizes covariância dadas por:

$$\text{cov}(r_W) = \sqrt{R^{-1}} \cdot W \cdot \sqrt{R} \quad (C.4)$$

$$\text{cov}(r_N) = \sqrt{D^{-1}} \cdot WR \cdot \sqrt{D^{-1}} \quad (C.5)$$

De forma equivalente a (C.1) e (C.2), mas abandonando a representação matricial, os resíduos ponderados (r_W), podem ser definidos como:

$$r_{Wi} = \frac{r_i}{\sigma_i} \quad i = 1, \dots, m \quad (C.6)$$

e os resíduos normalizados (r_N), como:

$$r_{Ni} = \frac{r_i}{\sqrt{\text{var}(r_i)}} = \frac{r_i}{\sqrt{(WR)_{ii}}} = \frac{r_i}{\sigma_i \sqrt{W_{ii}}} \quad i = 1, \dots, m \quad (C.7)$$

Se não existirem erros grosseiros, os resíduos r_i ($i=1, \dots, m$), apresentam distribuição $N(0, (WR)_{ii})$ e como tal:

$$r_{Wi} \sim N(0, W_{ii}) \quad (C.8)$$

$$r_{Ni} \sim N(0, 1) \quad (C.9)$$

Apêndice D

Linearização das Equações de Medida

Na estimação do vector de estado pelo método dos mínimos quadrados ponderados (WLS), pretende-se obter o vector de estado $\hat{x}$, que minimiza a função objectivo $J(x)$, isto é:

$$\min J(x) = \frac{\partial J(x)}{\partial x} \Big|_{x=\hat{x}} = -2H^T(\hat{x})R^{-1}[z - h(\hat{x})] = 0 \quad (\text{D.1})$$

Por simplicidade de notação passa-se a representar $H(x)$ por H . Atendendo à equação (2.15), a equação (D.1), pode escrever-se como:

$$H^T R^{-1}[h(x) + e - h(\hat{x})] = 0 \quad (\text{D.2})$$

Considere-se o desenvolvimento em série de $h(x)$ em torno do valor estimado $\hat{x}$, para o vector de estado:

$$h(x) = h(\hat{x}) + H.\delta_x + O(\|\delta_x\|^2) \quad (\text{D.3})$$

em que δ_x representa o erro de estimação do vector de estado do sistema e é calculado por:

$$\delta_x = x - \hat{x} \quad (\text{D.4})$$

Desprezando em (D.3) os termos de ordem superior a dois obtém-se:

$$h(x) = h(\hat{x}) + H.\delta_x \quad (\text{D.5})$$

A linearização de $h(x)$ em torno do valor estimado $\hat{x}$, assumindo valores pequenos para δ_x , resulta da equação (D.2) que:

$$H^T R^{-1} H \delta_x + H^T R^{-1} e = 0 \quad (D.6)$$

Assumindo que a matriz $H^T R^{-1} H$ é invertível vem:

$$\delta_x = -\sum_x H^T R^{-1} e \quad (D.7)$$

em que:

$$\sum_x = \left[H^T R^{-1} H \right]^{-1} \quad (D.8)$$

Na ausência de erros grosseiros esta linearização justifica-se pela reduzida amplitude do ruído de medida. Neste caso, o erro da estimação é suficientemente pequeno, permitindo limitar o desenvolvimento em série da equação de medida ao termo de primeira ordem. Na presença de erros grosseiros consideráveis, a experiência tem demonstrado que a utilização da relação (D.5) para a análise de erros grosseiros continua a fornecer bons resultados.

Para além do erro da estimação δ_x , interessa na prática também analisar o erro da estimação das grandezas medidas δ_h , definido por:

$$\delta_h = h(x) - h(\hat{x}) \quad (D.9)$$

isto é, a diferença entre o verdadeiro valor das medidas $h(x)$ e o valor estimado $h(\hat{x})$. Considerando a linearização referida em (D.5) obtém-se:

$$\delta_h = H \delta_x = -H \left[H^T R^{-1} H \right]^{-1} H^T R^{-1} e = -S \cdot e \quad (D.10)$$

em que:

$$S = H \left[H^T R^{-1} H \right]^{-1} H^T R^{-1} \quad (D.11)$$

é a matriz sensibilidade dos erros de estimação das grandezas medidas, aos erros de medida.

Outra grandeza importante na análise de erros grosseiros são os resíduos de medida, obtidos pela diferença entre os valores medidos z e os respectivos valores estimados $h(\hat{x})$, isto é:

$$r = z - h(\hat{x}) \quad (D.12)$$

e, considerando as equações (2.15), (D.8) e (D.9), obtém-se:

$$\begin{aligned} r &= h(x) + e - h(\hat{x}) \\ &= H\delta_x + e = -H[H^T R^{-1} H]^{-1} H^T R^{-1} e + e \\ &= [I - H(H^T R^{-1} H)^{-1} H^T R^{-1}] \cdot e \\ &= W \cdot e \end{aligned} \quad (D.13)$$

em que:

$$W = I - H(H^T R^{-1} H)^{-1} H^T R^{-1} \quad (D.14)$$

é a matriz sensibilidade dos resíduos aos erros de medida.

De salientar que em situações reais de utilização do estimador de estado, as únicas grandezas que podem ser efectivamente calculadas após a estimativa do vector de estado do sistema, são os resíduos de medida, pois o verdadeiro valor das medidas (assim como o verdadeiro valor do vector de estado) será sempre desconhecido.

Apêndice E

Dados da Rede de Teste de 24 Barramentos

Neste apêndice serão apresentados os resultados do trânsito de potências obtido pelo programa PowerWorld Simulator, bem como os dados necessários para a simulação da rede de 24 barramentos. Foi considerada uma potência de base de 100MVA.

Tabela E1-Dados e resultados do trânsito de potências.

Barramentos		Tensão		Produção		Carga	
Nº	Tipo	(pu)	(rad)	P(MW)	Q(MVAr)	P(MW)	Q(MVAr)
1	PV	1,0000	-0,3810	170,00	65,13	108,00	22,00
2	PV	1,0000	-0,3821	170,00	69,81	97,00	20,00
3	PQ	0,9440	-0,3679	0,00	0,00	180,00	37,00
4	PQ	0,9525	-0,4178	0,00	0,00	74,00	15,00
5	PQ	0,9622	-0,4213	0,00	0,00	71,00	14,00
6a)	PQ	0,9164	-0,4599	0,00	0,00	136,00	28,00
7	PV	1,0000	-0,3276	270,00	76,11	125,00	25,00
8	PQ	0,9549	-0,4129	0,00	0,00	171,00	35,00
9	PQ	0,9510	-0,3681	0,00	0,00	175,00	36,00
10	PQ	0,9533	-0,4012	0,00	0,00	195,00	40,00
11	PQ	0,9783	-0,2714	0,00	0,00	0,00	0,00
12	PQ	0,9623	-0,2461	0,00	0,00	0,00	0,00
13	PV	1,0000	-0,2044	300,00	189,50	265,00	54,00
14b)	PQ	1,0035	-0,2260	0,00	0,00	194,00	39,00
15	PV	1,0000	-0,1091	185,00	169,23	317,00	64,00
16	PV	1,0000	-0,1033	130,00	97,92	100,00	20,00
17	REF	1,0000	0,0000	233,99	-13,72	0,00	0,00
18	PV	1,0000	0,0131	350,00	65,23	333,00	68,00
19	PQ	0,9870	-0,1190	0,00	0,00	81,00	37,00
20	PQ	0,9888	-0,0748	0,00	0,00	120,00	26,00
21	PV	1,0000	0,0323	295,00	-22,88	0,00	0,00
22	PV	1,0000	0,0761	135,00	-22,25	0,00	0,00
23	PV	1,0000	-0,0256	655,00	23,03	0,00	0,00
24	PQ	0,9658	-0,2031	0,00	0,00	0,00	0,00

- a) Este barramento tem um shunt capacitivo de 100 MVAr
- b) Este barramento tem um shunt capacitivo de 150 MVAr

Tabela E2- Dados das Linhas e transformadores

Barramentos de extremidade		Resistência	Reactância	Susceptância	Razão de transformação
(i)	(j)	(pu)	(pu)	(pu)	(pu)
1	2	0,0026	0,0139	0,2305	0,00
1	3	0,0546	0,2112	0,0286	0,00
1	5	0,0218	0,0845	0,0115	0,00
2	4	0,0328	0,1267	0,0172	0,00
2	6	0,0497	0,1920	0,0260	0,00
3	9	0,0308	0,1190	0,0161	0,00
3	24	0,0023	0,0839	0,0000	1,00
4	9	0,0268	0,1037	0,0141	0,00
5	10	0,0228	0,0833	0,0119	0,00
6	10	0,0139	0,0605	1,2295	0,00
7	8	0,0159	0,0614	0,0083	0,00
8	9	0,0427	0,1651	0,0223	0,00
8	10	0,0427	0,1651	0,0223	0,00
9	11	0,0023	0,0839	0,0000	1,00
9	12	0,0023	0,0839	0,0000	1,00
10	11	0,0023	0,0839	0,0000	1,00
10	12	0,0023	0,0839	0,0000	1,00
11	13	0,0061	0,0476	0,0499	0,00
11	14	0,0054	0,0418	0,0439	0,00
12	13	0,0061	0,0476	0,0499	0,00
12	23	0,0214	0,0966	0,1015	0,00
13	23	0,0111	0,0865	0,0909	0,00
14	16	0,0050	0,0389	0,0409	0,00
15	16	0,0022	0,0173	0,0182	0,00
15	21	0,0063	0,0490	0,0505	0,00
15	21	0,0063	0,0490	0,0505	0,00
15	24	0,0067	0,0519	0,0545	0,00
16	17	0,0033	0,0259	0,0273	0,00
16	19	0,0030	0,0231	0,0243	0,00
17	18	0,0018	0,0144	0,0152	0,00
17	22	0,0135	0,1053	0,1106	0,00
18	21	0,0033	0,0259	0,0273	0,00
18	21	0,0033	0,0259	0,0273	0,00
19	20	0,0051	0,0396	0,0417	0,00
19	20	0,0051	0,0396	0,0417	0,00
20	23	0,0028	0,0216	0,0227	0,00
20	23	0,0028	0,0216	0,0227	0,00
21	22	0,0087	0,0678	0,0712	0,00

Apêndice F

Dados da Rede de Teste de 118 Barramentos

Os dados da rede de 118 barramentos, bem como os resultados do trânsito de potências serão apresentados nas tabelas seguintes. Todos os valores por unidade são calculados para uma potência de base de 100MVA.

Tabela F1-Dados e resultados do trânsito de potências.

Barramentos		Tensão		Produção		Carga	
Nº	Tipo	(pu)	(rad)	P(MW)	Q(MVAr)	P(MW)	Q(MVAr)
1	PV	0,9559	-0.3245	0,00	-5,00	51,00	27,00
2	PQ	0,9725	-0.3152	0,00	0,00	20,00	9,00
3	PQ	0,9686	-0.3091	0,00	0,00	39,00	10,00
4	PV	0,9980	-0.2442	-9,00	16,47	30,00	12,00
5 a)	PQ	0,9994	-0.2840	0,00	0,00	0,00	0,00
6	PV	0,9900	-0.2916	0,00	19,43	52,00	22,00
7	PQ	0,9894	-0.1468	0,00	0,00	19,00	2,00
8	PV	1,0150	-0.0274	-28,00	-297,68	0,00	0,00
9	PQ	1,0802	0.0970	0,00	0,00	0,00	0,00
10	PV	1,0820	-0.2890	450,00	-147,00	0,00	0,00
11	PQ	0,9855	-0.2978	0,00	0,00	70,00	23,00
12	PV	0,9900	-0.3136	85,00	69,56	47,00	10,00
13	PQ	0,9718	-0.3108	0,00	0,00	34,00	16,00
14	PQ	0,9864	-0.3157	0,00	0,00	14,00	1,00
15	PV	0,9740	-0.3037	0,00	-10,00	90,00	30,00
16	PQ	0,9869	-0.2721	0,00	0,00	25,00	10,00
17	PQ	0,9984	-0.3096	0,00	0,00	11,00	3,00
18	PV	0,9730	-0.3190	0,00	8,37	60,00	34,00
19	PV	0,9683	-0.3056	0,00	-8,00	45,00	25,00
20	PQ	0,9683	-0.2793	0,00	0,00	18,00	3,00
21	PQ	0,9705	-0.2358	0,00	0,00	14,00	8,00
22	PQ	0,9810	-0.1508	0,00	0,00	10,00	5,00
23	PQ	1,0047	-0.1525	0,00	0,00	7,00	3,00
24	PV	0,9920	-0.0291	-13,00	-33,99	0,00	0,00
25	PV	1,0489	0.0028	220,00	140,00	0,00	0,00
26	PV	1,0150	-0.2464	314,00	-208,86	0,00	0,00
27	PV	0,9680	-0.2763	-9,00	-17,84	62,00	13,00
28	PQ	0,9629	-0.2927	0,00	0,00	17,00	7,00
29	PQ	0,9639	-0.1845	0,00	0,00	24,00	4,00

Barramentos		Tensão		Produção		Carga	
Nº	Tipo	(pu)	(rad)	P(MW)	Q(MVAr)	P(MW)	Q(MVAr)
30	PQ	1,0437	-0.2902	0,00	0,00	0,00	0,00
31	PV	0,9670	-0.2566	7,00	20,55	43,00	27,00
32	PV	0,9675	-0.3267	0,00	-14,00	59,00	23,00
33	PQ	0,9803	-0.3150	0,00	0,00	23,00	9,00
34 b)	PV	0,9954	-0.3218	0,00	-8,00	59,00	26,00
35	PQ	0,9893	-0.2840	0,00	0,00	33,00	9,00
36	PV	0,9884	-0.3218	0,00	-8,00	31,00	17,00
37 c)	PQ	1,0011	-0.3067	0,00	0,00	0,00	0,00
38	PQ	1,0377	-0.2166	0,00	0,00	0,00	0,00
39	PQ	0,9746	-0.3648	0,00	0,00	27,00	11,00
40	PV	0,9700	-0.3831	-46,00	7,88	20,00	23,00
41	PQ	0,9677	-0.3918	0,00	0,00	37,00	10,00
42	PV	0,9850	-0.3658	-59,00	27,66	37,00	23,00
43	PQ	0,9954	-0.3196	0,00	0,00	18,00	7,00
44 d)	PQ	0,9993	-0.2798	0,00	0,00	16,00	8,00
45 e)	PQ	0,9957	-0.2484	0,00	0,00	53,00	22,00
46 f)	PV	1,0050	-0.1979	19,00	-20,01	28,00	10,00
47	PQ	1,0193	-0.1602	0,00	0,00	34,00	0,00
48 g)	PQ	1,0219	-0.1735	0,00	0,00	20,00	11,00
49	PV	1,0250	-0.1557	204,00	66,51	87,00	30,00
50	PQ	1,0033	-0.1920	0,00	0,00	17,00	4,00
51	PQ	0,9720	-0.2382	0,00	0,00	17,00	8,00
52	PQ	0,9631	-0.2550	0,00	0,00	18,00	5,00
53	PQ	0,9511	-0.2712	0,00	0,00	23,00	11,00
54	PV	0,9550	-0.2541	48,00	-16,90	113,00	32,00
55	PV	0,9520	-0.2592	0,00	-1,96	63,00	22,00
56	PV	0,9545	-0.2560	0,00	-8,00	84,00	18,00
57	PQ	0,9734	-0.2360	0,00	0,00	12,00	3,00
58	PQ	0,9630	-0.2512	0,00	0,00	12,00	3,00
59	PV	0,9850	-0.1829	155,00	67,70	277,00	113,00
60	PQ	0,9945	-0.1178	0,00	0,00	78,00	3,00
61	PV	0,9963	-0.1023	160,00	-100,00	0,00	0,00
62	PV	0,9980	-0.1131	0,00	-11,83	77,00	14,00
63	PQ	1,0059	-0.1234	0,00	0,00	0,00	0,00
64	PQ	1,0164	-0.0941	0,00	0,00	0,00	0,00
65	PV	1,0395	-0.0428	391,00	-67,00	0,00	0,00
66	PV	1,0500	-0.0438	392,00	89,86	39,00	18,00
67	PQ	1,0213	-0.0895	0,00	0,00	28,00	7,00
68	PQ	1,0214	-0.0433	0,00	0,00	0,00	0,00
69	REF	1,0350	0.0000	511,82	29,63	0,00	0,00
70	PV	0,9851	-0.1281	0,00	-10,00	66,00	20,00
71	PQ	0,9880	-0.1351	0,00	0,00	0,00	0,00
72	PV	0,9800	-0.1534	-12,00	-16,23	0,00	0,00
73	PV	0,9910	-0.1386	-6,00	6,60	0,00	0,00
74 h)	PV	0,9621	-0.1459	0,00	-6,00	68,00	27,00
75	PQ	0,9715	-0.1244	0,00	0,00	47,00	11,00
76	PV	0,9430	-0.1433	0,00	-1,55	68,00	36,00
77	PV	1,0062	-0.0578	0,00	-20,00	61,00	28,00
78	PQ	1,0038	-0.0634	0,00	0,00	71,00	26,00

Barramentos		Tensão		Produção		Carga	
Nº	Tipo	(pu)	(rad)	P(MW)	Q(MVAr)	P(MW)	Q(MVAr)
79 i)	PQ	1,0098	-0.0583	0,00	0,00	39,00	32,00
80	PV	1,0400	-0.0195	477,00	153,42	130,00	26,00
81	PQ	1,0393	-0.0358	0,00	0,00	0,00	0,00
82 j)	PQ	0,9982	-0.0515	0,00	0,00	54,00	27,00
83 k)	PQ	0,9952	-0.0314	0,00	0,00	20,00	10,00
84	PQ	0,9899	0.0124	0,00	0,00	11,00	7,00
85	PV	0,9936	0.0398	0,00	-8,00	24,00	15,00
86	PQ	0,9950	0.0164	0,00	0,00	21,00	10,00
87	PV	1,0150	0.0220	4,00	4,70	0,00	0,00
88	PQ	0,9920	0.0944	0,00	0,00	48,00	10,00
89	PV	1,0050	0.1658	607,00	-51,48	0,00	0,00
90	PV	0,9850	0.0555	-85,00	49,00	78,00	42,00
91	PV	0,9800	0.0632	-10,00	-21,62	0,00	0,00
92	PV	0,9977	0.0106	0,00	-3,00	65,00	10,00
93	PQ	0,9939	-0.0264	0,00	0,00	12,00	7,00
94	PQ	0,9974	-0.0435	0,00	0,00	30,00	16,00
95	PQ	0,9888	-0.0464	0,00	0,00	42,00	31,00
96	PQ	1,0010	-0.0393	0,00	0,00	38,00	15,00
97	PQ	1,0168	-0.0469	0,00	0,00	15,00	9,00
98	PQ	1,0262	-0.0527	0,00	0,00	34,00	8,00
99	PV	1,0100	-0.0351	-42,00	-21,43	0,00	0,00
100	PV	1,0170	-0.0091	252,00	60,53	37,00	18,00
101	PQ	0,9977	0.0372	0,00	0,00	22,00	15,00
102	PQ	0,9972	-0.0986	0,00	0,00	5,00	3,00
103	PV	1,0036	-0.1456	40,00	40,00	23,00	16,00
104	PV	0,9710	-0.1658	0,00	-8,00	38,00	25,00
105 l)	PV	0,9687	-0.1703	0,00	-8,00	31,00	26,00
106	PQ	0,9657	-0.2178	0,00	0,00	43,00	16,00
107 m)	PV	0,9520	-0.1866	-22,00	-2,11	28,00	12,00
108	PQ	0,9694	-0.1943	0,00	0,00	2,00	1,00
109	PQ	0,9696	-0.2080	0,00	0,00	8,00	3,00
110 n)	PV	0,9730	-0.1794	0,00	-6,52	39,00	30,00
111	PV	0,9800	-0.2621	36,00	-2,80	0,00	0,00
112	PV	0,9750	-0.2714	-43,00	38,56	25,00	13,00
113	PV	0,9930	-0.2621	-6,00	-9,32	0,00	0,00
114	PQ	0,9634	-0.2623	0,00	0,00	8,00	3,00
115	PQ	0,9630	-0.0494	0,00	0,00	22,00	7,00
116	PV	1,0050	-0.2991	-184,00	-413,37	0,00	0,00
117	PQ	0,9827	-0.1412	0,00	0,00	20,00	8,00
118	PQ	0,9520	0.0106	0,00	0,00	33,00	15,00

- a) Este barramento tem um shunt capacitivo de -40 MVAr
- b) Este barramento tem um shunt capacitivo de 14 MVAr
- c) Este barramento tem um shunt capacitivo de -25 MVAr
- d) Este barramento tem um shunt capacitivo de 10 MVAr
- e) Este barramento tem um shunt capacitivo de 10 MVAr
- f) Este barramento tem um shunt capacitivo de 10 MVAr
- g) Este barramento tem um shunt capacitivo de 15 MVAr
- h) Este barramento tem um shunt capacitivo de 12 MVAr

- i) Este barramento tem um shunt capacitivo de 20 MVar
- j) Este barramento tem um shunt capacitivo de 20 MVar
- k) Este barramento tem um shunt capacitivo de 10 MVar
- l) Este barramento tem um shunt capacitivo de 20 MVar
- m) Este barramento tem um shunt capacitivo de 6 MVar
- n) Este barramento tem um shunt capacitivo de 6 MVar

Tabela F2- Dados das Linhas e transformadores

Barramentos de extremidade		Resistência	Reactância	Susceptância	Razão de transformação
(i)	(j)	(pu)	(pu)	(pu)	(pu)
1	2	0,0303	0,0999	0,0508	0,00
1	3	0,0129	0,0424	0,0216	0,00
2	12	0,0187	0,0616	0,0312	0,00
3	5	0,0241	0,1080	0,0568	0,00
3	12	0,0484	0,1600	0,0812	0,00
4	5	0,0018	0,0080	0,0040	0,00
4	11	0,0209	0,0688	0,0348	0,00
5	6	0,0119	0,0540	0,0284	0,00
5	8	0,0000	0,0267	0,0000	0,960
5	11	0,0203	0,0682	0,0348	0,00
6	7	0,0045	0,0208	0,0108	0,00
7	12	0,0086	0,0340	0,0172	0,00
8	9	0,0024	0,0305	2,3240	0,00
8	30	0,0043	0,0504	1,0280	0,00
9	10	0,0026	0,0322	2,4700	0,00
11	12	0,0059	0,0196	0,0100	0,00
11	13	0,0222	0,0731	0,0376	0,00
12	14	0,0215	0,0707	0,0364	0,00
12	16	0,0212	0,0834	0,0428	0,00
12	117	0,0329	0,1400	0,0716	0,00
13	15	0,0744	0,2444	0,1252	0,00
14	15	0,0595	0,1950	0,1004	0,00
15	17	0,0132	0,0437	0,0888	0,00
15	19	0,0120	0,0394	0,0200	0,00
15	33	0,0380	0,1244	0,0640	0,00
16	17	0,0454	0,1801	0,0932	0,00
17	18	0,0123	0,0505	0,0256	0,00
17	30	0,0000	0,0388	0,0000	1,11
17	31	0,0474	0,1563	0,0800	0,00
17	113	0,0091	0,0301	0,0152	0,00
18	19	0,0111	0,0493	0,0228	0,00
19	20	0,0252	0,1170	0,0596	0,00
19	34	0,0752	0,2470	0,1264	0,00
20	21	0,0183	0,0849	0,0432	0,00
21	22	0,0209	0,0976	0,0492	0,00

Barramentos de extremidade		Resistência	Reactância	Susceptância	Razão de transformação
(i)	(j)	(pu)	(pu)	(pu)	(pu)
22	23	0,0342	0,1590	0,0808	0,00
23	24	0,0135	0,0492	0,0984	0,00
23	25	0,0156	0,0800	0,1728	0,00
23	32	0,0317	0,1153	0,2344	0,00
24	70	0,1022	0,4115	0,2040	0,00
24	72	0,0488	0,1960	0,0976	0,00
25	26	0,0000	0,0382	0,0000	1,11
25	27	0,0318	0,1630	0,3528	0,00
26	30	0,0079	0,0860	1,8160	0,00
27	28	0,0191	0,0855	0,0432	0,00
27	32	0,0229	0,0755	0,0384	0,00
27	115	0,0164	0,0741	0,0396	0,00
28	29	0,0237	0,0943	0,0476	0,00
29	31	0,0108	0,0331	0,0164	0,00
30	38	0,0046	0,0540	0,8440	0,00
31	32	0,0298	0,0985	0,0500	0,00
32	113	0,0615	0,2030	0,1036	0,00
32	114	0,0135	0,0612	0,0324	0,00
33	37	0,0415	0,1420	0,0732	0,00
34	36	0,0087	0,0268	0,0112	0,00
34	37	0,0026	0,0094	0,0196	0,00
34	43	0,0413	0,1681	0,0844	0,00
35	36	0,0022	0,0102	0,0052	0,00
35	37	0,0110	0,0497	0,0264	0,00
37	38	0,0000	0,0375	0,0000	1,11
37	39	0,0321	0,1060	0,0540	0,00
37	40	0,0593	0,1680	0,0840	0,00
38	65	0,0090	0,0986	2,0920	0,00
39	40	0,0184	0,0605	0,0310	0,00
40	41	0,0145	0,0487	0,0244	0,00
40	42	0,0555	0,1830	0,0932	0,00
41	42	0,0410	0,1350	0,0688	0,00
42	49	0,0358	0,1610	0,3440	0,00
43	44	0,0608	0,2454	0,1212	0,00
44	45	0,0224	0,0901	0,0484	0,00
45	46	0,0400	0,1356	0,0666	0,00
45	49	0,0684	0,1860	0,0888	0,00
46	47	0,0380	0,1270	0,0632	0,00
46	48	0,0601	0,1890	0,0944	0,00
47	49	0,0191	0,0625	0,0320	0,00
47	69	0,0844	0,2778	0,1420	0,00
48	49	0,0179	0,0505	0,0252	0,00
49	50	0,0267	0,0752	0,0372	0,00
49	51	0,0486	0,1370	0,0684	0,00
49	54	0,0398	0,1450	0,2936	0,00

Barramentos de extremidade		Resistência	Reactância	Susceptância	Razão de transformação
(i)	(j)	(pu)	(pu)	(pu)	(pu)
48	49	0,0179	0,0505	0,0252	0,00
49	50	0,0267	0,0752	0,0372	0,00
49	51	0,0486	0,1370	0,0684	0,00
49	54	0,0398	0,1450	0,2936	0,00
49	66	0,0090	0,0459	0,0992	0,00
49	69	0,0985	0,3240	0,1656	0,00
50	57	0,0474	0,1340	0,0664	0,00
51	52	0,0203	0,0588	0,0280	0,00
51	58	0,0255	0,0719	0,0356	0,00
52	53	0,0405	0,1635	0,0808	0,00
53	54	0,0263	0,1220	0,0620	0,00
54	55	0,0169	0,0707	0,0404	0,00
54	56	0,0027	0,0095	0,0144	0,00
54	59	0,0503	0,2293	0,1196	0,00
55	56	0,0048	0,0151	0,0076	0,00
55	59	0,0473	0,2158	0,1128	0,00
56	57	0,0343	0,0966	0,0484	0,00
56	58	0,0343	0,0966	0,0484	0,00
56	59	0,0407	0,1200	0,2228	0,00
59	60	0,0317	0,1450	0,0752	0,00
59	61	0,0328	0,1500	0,0776	0,00
59	63	0,0000	0,0386	0,0000	1,11
60	61	0,0026	0,0135	0,0292	0,00
60	62	0,0123	0,0561	0,0292	0,00
61	62	0,0082	0,0376	0,0196	0,00
61	64	0,0000	0,0268	0,0000	0,91
62	66	0,0482	0,2180	0,1156	0,00
62	67	0,0258	0,1170	0,0620	0,00
63	64	0,0017	0,0200	0,4320	0,00
64	65	0,0027	0,0302	0,7600	0,00
65	66	0,0000	0,0370	0,0000	0,00
65	68	0,0014	0,0160	1,2760	0,00
66	67	0,0224	0,1015	0,0536	0,00
68	69	0,0000	0,0370	0,0000	1,01
68	81	0,0017	0,0202	1,6160	0,00
68	116	0,0003	0,0040	0,3280	0,00
69	70	0,0300	0,1270	0,2440	0,00
69	75	0,0405	0,1220	0,2480	0,00
69	77	0,0309	0,1010	0,2076	0,00
70	71	0,0088	0,0355	0,0172	0,00
70	74	0,0401	0,1323	0,0672	0,00
70	75	0,0428	0,1410	0,0720	0,00
71	72	0,0446	0,1800	0,0888	0,00
71	73	0,0087	0,0454	0,0236	0,00
74	75	0,0123	0,0406	0,0204	0,00
75	77	0,0601	0,1999	0,0996	0,00

Barramentos de extremidade		Resistência	Reactância	Susceptância	Razão de transformação
(i)	(j)	(pu)	(pu)	(pu)	(pu)
75	118	0,0145	0,0481	0,0220	0,00
76	77	0,0444	0,0148	0,0736	0,00
76	118	0,0164	0,0544	0,0272	0,00
77	78	0,0037	0,0124	0,0252	0,00
77	80	0,0108	0,0331	0,1400	0,00
77	82	0,0298	0,0853	0,1636	0,00
78	79	0,0054	0,0244	0,0128	0,00
79	80	0,0156	0,0704	0,0372	0,00
80	96	0,0356	0,1820	0,0988	0,00
80	97	0,0183	0,0934	0,0508	0,00
80	98	0,0238	0,1080	0,0572	0,00
80	99	0,0454	0,2060	0,1092	0,00
81	80	0,0000	0,0370	0,0000	1,11
82	83	0,0112	0,0366	0,0760	0,00
82	96	0,0162	0,0530	0,1088	0,00
83	84	0,0625	0,1320	0,0516	0,00
83	85	0,0430	0,1480	0,0696	0,00
84	85	0,0302	0,0641	0,0244	0,00
85	86	0,0350	0,1230	0,0552	0,00
85	88	0,0200	0,1020	0,0552	0,00
85	89	0,0239	0,1730	0,0940	0,00
86	87	0,0282	0,2074	0,0888	0,00
88	89	0,0139	0,0712	0,0384	0,00
89	90	0,0158	0,0653	0,3176	0,00
89	92	0,0079	0,0380	0,1924	0,00
90	91	0,0254	0,0836	0,0428	0,00
91	92	0,0387	0,1272	0,0652	0,00
92	93	0,0258	0,0848	0,0436	0,00
92	94	0,0481	0,1580	0,0812	0,00
92	100	0,0648	0,2950	0,1544	0,00
92	102	0,0123	0,0559	0,0292	0,00
93	94	0,0223	0,0732	0,0376	0,00
94	95	0,0132	0,0434	0,0220	0,00
94	96	0,0269	0,0869	0,0460	0,00
94	100	0,0178	0,0580	0,1208	0,00
95	96	0,0171	0,0547	0,0296	0,00
96	97	0,0173	0,0885	0,0480	0,00
98	100	0,0397	0,1790	0,0952	0,00
99	100	0,0180	0,0813	0,0432	0,00
100	101	0,0277	0,1262	0,0656	0,00
100	103	0,0160	0,0525	0,1072	0,00
100	104	0,0451	0,2040	0,1080	0,00
100	106	0,0605	0,2290	0,1240	0,00

Barramentos de extremidade		Resistência	Reactância	Susceptância	Razão de transformação
(i)	(j)	(pu)	(pu)	(pu)	(pu)
101	102	0,0246	0,1120	0,0588	0,00
103	104	0,0466	0,1584	0,0812	0,00
103	105	0,0535	0,1625	0,0816	0,00
103	110	0,0391	0,1813	0,0920	0,00
104	105	0,0099	0,0378	0,0196	0,00
105	106	0,0140	0,0547	0,0288	0,00
105	107	0,0530	0,1830	0,0944	0,00
105	108	0,0261	0,0703	0,0368	0,00
106	107	0,0530	0,1830	0,0944	0,00
108	109	0,0105	0,0288	0,0152	0,00
109	110	0,0278	0,0762	0,0404	0,00
110	111	0,0220	0,0755	0,0400	0,00
110	112	0,0247	0,0640	0,1240	0,00
114	115	0,0023	0,0104	0,0056	0,00