

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

**Metodologia para identificação de
sistemas mal condicionados com
restrições maximizando a amplitude das
perturbações**

DISSERTAÇÃO DE MESTRADO

RAFAEL RAMOS WAGNER

Porto Alegre

2015

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

**Metodologia para identificação de
sistemas mal condicionados com
restrições maximizando a amplitude das
perturbações**

DISSERTAÇÃO DE MESTRADO

RAFAEL RAMOS WAGNER

Dissertação de Mestrado apresentada como
requisito parcial para obtenção do título de
Mestre em Engenharia

Área de concentração: Pesquisa e
desenvolvimento de processos

Orientador:

Prof. Dr. Marcelo Farenzena

Porto Alegre

2015

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

A Comissão Examinadora, abaixo assinada, aprova a Dissertação *Metodologia para identificação de sistemas mal condicionados com restrições maximizando a amplitude das perturbações*, elaborada por Rafael Ramos Wagner, como requisito parcial para obtenção do Grau de Mestre em Engenharia.

Comissão Examinadora:

Prof. Dr. André Rodrigues Muniz

Prof. Dr. Jorge Otávio Trierweiler

Profa. Dra. Lucíola Campestrini

Agradecimentos

Agradeço ao corpo de funcionários do DEQUI (departamento de engenharia química), em especial ao professor Marcelo Farenzena que me orientou com muita paciência, pedindo prazos à comissão de pós-graduação e me orientando à distância durante o último ano. Gostaria de agradecer também a minha namorada Débora por me ajudar com as verificações de ortografia, de formatação, traduções e pelos lanches que ajudaram muito nos momentos de trabalho.

Resumo

Os controladores industriais que usam controle preditivo baseado em modelo, ou MPC (*Model Predictive Control*), frequentemente sofrem de perda de performance ao longo do tempo, decorrente de alterações no processo e da falta de atualização dos modelos. Os métodos habitualmente utilizados para a identificação, que são os testes monovariáveis, com perturbação degrau e malha aberta, gastam muito tempo e têm custo elevado para o processo, podendo comprometer a qualidade dos produtos ou a segurança, portanto a atualização do modelo costuma ser evitada por longos períodos. Além disso, existem processos mal condicionados de difícil identificação, pois apresentam direcionalidades nas suas variáveis.

Neste trabalho, primeiramente foi feita uma comparação entre os métodos de projeto de perturbações não correlacionadas em um caso de sistema mal condicionado. Na comparação nenhum dos métodos foi capaz de identificar com confiabilidade a direção de menor ganho do sistema, porém para a direção de maior ganho algumas diferenças entre os métodos foram levantadas. A metodologia GBN (*Generalized Binary Noise*) conseguiu identificar melhor a direção de maior ganho para uma faixa maior de frequências. O método Degrau identificou bem somente em baixas frequências, enquanto o método PBRs (*Pseudo Random Binary Sequence*) identificou bem somente em altas frequências. Por este motivo, a perturbação GBN foi utilizada como base para a metodologia proposta.

Uma metodologia de projeto de perturbações correlacionadas foi desenvolvida

utilizando as perturbações GBN como base visando a maximização da amplitude de perturbação nas direções de menor ganho, evitando assim que as variáveis de entrada e saída do sistema ultrapassem suas restrições. Essa maximização da amplitude é feita iterativamente através de um problema de otimização que utiliza o modelo identificado na iteração anterior para projetar as perturbações da nova iteração. Também foi proposto um fator de confiabilidade, w , que permite verificar o grau de evolução da qualidade do modelo ao longo das iterações. Este fator se mostrou útil como critério de parada do processo iterativo.

O método proposto foi comparado com métodos de perturbações correlacionadas conhecidos na literatura e que apresentam bons resultados na identificação de processos mal condicionados. A metodologia proposta apresentou uma melhora significativa na identificação da direção de menor ganho, porém foi necessário um tempo maior de identificação. Em poucos momentos as variáveis do processo ultrapassaram suas restrições, demonstrando maior confiabilidade do processo de identificação.

Abstract

Industrial controllers using MPC (*Model Predictive Control*) frequently suffer from loss of performance over time due to process alterations and the non-updating of the models. The methods most often used for identification, which are single variable tests with step perturbation and open-loop, require a lot of time and have high costs for the process, and might even compromise product quality and safety, so the models update is often delayed over long periods of time. Besides, there are ill-conditioned processes that are difficult to identify, because they may present directionalities in their variables.

In this paper, a comparison was carried out between non-correlated perturbation design methods considering an ill-conditioned system. None of the methods was capable of solidly trustworthily identify the system's low-gain direction, however, considering the high gain direction, some differences were noticed. The GBN (*Generalized Binary Noise*) method was the one which best identified the most-gain direction for the upper band of frequencies. The Step method could identify well only in low frequencies, whereas the PBRs (*Pseudo Random Binary Sequence*) method identified well only in high frequencies. For this reason, the proposed method was based on the GBN perturbation.

A method for correlated perturbation building was developed based on the GBN perturbations, aiming for maximum perturbation amplitude in the low-gain direction, avoiding that system input and output variables surpass their restrictions. This maximizing of the amplitude is made iteratively through an optimization problem

which uses the model identified in the previous iteration to predict the perturbations of the upcoming iteration. In addition, a reliability factor w was proposed, which allows the verification of the model's quality evolution throughout iterations. This factor was useful as a criterion for stopping the iteration process.

The proposed method was compared to well-known correlated perturbation methods which present solid results in the identification of ill-conditioned processes. The method showed significant improvement on the identification of the low-gain direction, but it required longer identification time. Within few moments the process variables surpassed their restrictions, that bringing more reliability to the identification process.

Sumário

Introdução	1
1.1 Estrutura da Dissertação.....	5
Revisão Bibliográfica	6
2.1 Identificação de Modelos	6
2.1.1 Identificação para Aplicação em MPC	8
2.1.2 Condicionamento do sistema	9
2.2 Planejamento e Realização dos Testes de Identificação	12
2.2.1 Perturbação Degrau	13
2.2.2 Perturbação PRBS	15
2.2.3 Perturbação GBN (Generalised Binary Noise)	18
2.2.4 Planejamento de Perturbações Propostas por Zhu (2001 e 2006).....	20
<i>Método de Dois Passos com Sinais Concatenados</i>	21
<i>Método de Dois Passos com Sinais Somados</i>	22
2.3 Método de Identificação - PEM (<i>Prediction Error Method</i>)	24
2.4 Métodos de Validação.....	26
Metodologia	28
3.1 Estudo de Caso.....	28
3.1.1 Descrição do Sistema	28
3.1.2 Simulação do Sistema em MATLAB®	33
3.1.3 Definições para Identificação Utilizando a Simulação	35
3.2 Determinação dos Parâmetros para as Perturbações.....	37
3.2.1 Perturbação Degrau	37
3.2.2 Perturbação PRBS	38
3.2.3 Perturbação GBN	39
3.2.4 Perturbações Propostas por Zhu (2001 e 2006)	39
3.3 Método Proposto para Projeto de Perturbação.....	40
3.4.1 Validação Cruzada	44
3.4.2 Erro da Estimativa dos Parâmetros	45
3.4.3 Inversão do Sinal do Ganho Multivariável	46
3.4.4 Erros dos Valores Singulares - Estacionário e Dinâmico	46
3.4.5 Erro no RGA	48
3.4.6 Estabilidade em Malha Fechada.....	48
Resultados	50
4.1 Comparação Entre os Métodos de Identificação Não Correlacionados.....	50
4.1.1 Perturbação Degrau	51
4.1.2 Perturbação PRBS	53
4.1.3 Perturbação GBN	55
4.1.4 Resumo da Comparação.....	58
4.2 Avaliação do método de dois passos e aplicação da metodologia para maximizar a amplitude das perturbações	60
4.2.1 Método de Dois Passos	60

4.2.2	Aplicação da metodologia proposta de maximização da amplitude	64
4.2.3	Resumo da Comparação.....	68
4.2.4	Avaliação do Efeito do Tempo de Duração da Perturbações.....	69
4.2.5	Avaliação do Efeito da Amplitude do Distúrbio Não Medido.....	71
Conclusão e Sugestões para Trabalhos Futuros.....		74
5.1	Sugestões para Trabalhos Futuros.....	75
Apêndice.....		76
A.1	Implementação da Rotina de Simulação	76
A.2	Implementação da Maximização de Amplitude.....	76
A.3	Implementação da Perturbação Degrau.....	77
A.4	Implementação da Perturbação GBN.....	77
A.5	Implementação da Perturbação pelo Método de Dois Passos	78
A.6	Implementação da Perturbação Proposta	79
Referências Bibliográficas.....		81

Lista de figuras

Figura 2.1:	Algoritmo do processo de identificação.....	7
Figura 2.2:	Perturbação degrau para um sistema multivariável.	14
Figura 2.3:	Perturbação PRBS para um sistema multivariável.....	17
Figura 2.4:	Comparação do espectro de frequências de um sinal GBN para diversos valores de p (Tulleken, 1990).	19
Figura 2.5:	Comparação da perturbação GBN para p igual a $\frac{1}{4}$, $\frac{1}{2}$ e $\frac{3}{4}$, respectivamente, em um mesmo intervalo de frequência.	20
Figura 2.6:	Perturbação do segundo passo do método de dois passos com sinais concatenados.	23
Figura 2.7:	Perturbação do segundo passo do método de dois passos com sinais concatenados.	23
Figura 3.1:	Coluna de destilação de alta pureza na configuração de controle LV (Skogestad, 1997).....	29
Figura 3.2:	Perturbação com a mesma amplitude nas direções de maior e menor ganho.	32
Figura 3.3:	Perturbação com amplitudes diferentes nas direções de maior e menor ganho.	33
Figura 3.4:	Simulação do estudo de caso em MATLAB - Simulink®.....	34
Figura 3.5:	Exemplo de distúrbio não medido aplicado nas variáveis de saída do sistema.....	34
Figura 3.6:	Escolha do tempo de amostragem através do fator FPE.....	36
Figura 3.7:	Defasagem entre as direções do processo (linha preta) e do modelo identificado (linha azul).	41
Figura 3.8:	Determinação das variáveis da equação 3.9 para atualização do fator w	43
Figura 3.9:	Dados selecionados para validação cruzada dos modelos identificados.	45
Figura 3.10:	Valores singulares do estudo de caso avaliados para uma faixa de frequências.	47
Figura 4.1:	Perturbação Degrau aplicada ao estudo de caso em um procedimento de identificação.	51
Figura 4.2:	Comparação dos valores singulares dos cinquenta modelos identificados com a perturbação Degrau (linhas vermelhas) com os valores singulares do processo real (linha azul).	52
Figura 4.3:	Dispersão típica dos dados para uma identificação utilizando perturbação Degrau.	53
Figura 4.4:	Perturbação PRBS aplicada ao estudo de caso em um procedimento de identificação.	54
Figura 4.5:	Comparação dos valores singulares dos cinquenta modelos identificados com a perturbação PRBS (linhas vermelhas) com os valores singulares do processo real (linha azul).	54
Figura 4.6:	Dispersão típica dos dados gerados para uma identificação utilizando perturbação PRBS.	55
Figura 4.7:	Perturbação GBN aplicada ao estudo de caso em um procedimento de identificação com p igual a 0,8.	56

Figura 4.8:	Comparação dos valores singulares dos cinquenta modelos identificados com a perturbação GBN (linhas vermelhas) com os valores singulares do processo real (linha azul).	57
Figura 4.9:	Dispersão típica dos dados gerados para uma identificação utilizando perturbação GBN.	58
Figura 4.10:	Validação cruzada para os melhores modelos identificados com os métodos Degrau, PRBS e GBN.	60
Figura 4.11:	Perturbação de dois passos com sinais concatenados aplicada ao estudo de caso em um procedimento de identificação.	61
Figura 4.12:	Perturbação de dois passos com sinais somados aplicada ao estudo de caso em um procedimento de identificação.	61
Figura 4.13:	Dispersão típica dos dados gerados para uma identificação utilizando perturbação de dois passos com sinais concatenados (esquerda) e perturbação de dois passos com sinais somados (direita).	62
Figura 4.14:	Comparação dos valores singulares dos cinquenta modelos obtidos com a perturbação de dois passos com sinais concatenados (esquerda) e com a perturbação de dois passos com sinais somados (direita).	63
Figura 4.15:	Validação cruzada para os melhores modelos identificados com os métodos de dois passos.	63
Figura 4.16:	Atualização da direção de menor ganho em uma identificação utilizando a metodologia proposta.	65
Figura 4.17:	Perturbação proposta com sinais concatenados aplicada ao estudo de caso em um procedimento de identificação.	65
Figura 4.18:	Perturbação proposta com sinais somados aplicada ao estudo de caso em um procedimento de identificação.	66
Figura 4.19:	Dispersão típica dos dados gerados para identificação utilizando a metodologia proposta com sinais concatenados (esquerda) e com sinais somados (direita).	67
Figura 4.20:	Comparação dos valores singulares modelos obtidos com a metodologia proposta e com sinais concatenados (esquerda) e com sinais somados (direita).	67
Figura 4.21:	Validação cruzada para os melhores modelos identificados com a metodologia proposta.	68
Figura 4.22:	Evolução do fator w para as identificações utilizando a metodologia proposta com sinais concatenados.	70
Figura 4.23:	Evolução do fator w para as identificações utilizando a metodologia proposta com sinais somados.	70

Lista de tabelas

Tabela 2.1: Valores dos a_k parâmetros do polinômio $P(q)$ para cada ordem n da perturbação PRBS.	16
Tabela 2.2: Estruturas de identificação discreta.....	25
Tabela 3.1: Ponto de operação e dados da coluna para linearização e determinação do estado estacionário.	30
Tabela 3.2: Valores do fator FPE para diferentes ordens dos polinômios $A(q)$ e $B(q)$	35
Tabela 3.3: Parâmetros determinados para cada metodologia de perturbação	44
Tabela 4.1: Resultados obtidos para a variação do valor de p	56
Tabela 4.2: Resultados obtidos para comparação entre os métodos Degraus, PRBS e GBN.	59
Tabela 4.3: Evolução do fator w para as perturbações das Figuras 4.17 e 4.18.....	66
Tabela 4.4: Resultados obtidos para comparar os métodos de 2 passos e o método proposto.....	69
Tabela 4.5: Resultados obtidos para avaliação do efeito do tempo de duração dos experimentos de identificação.....	71
Tabela 4.6: Resultados obtidos para avaliação do efeito da amplitude do distúrbio não medido no método proposto.....	72
Tabela 4.7: Resultados obtidos para avaliação do efeito da amplitude do distúrbio não medido no método de 2 passos.....	73

Capítulo 1

Introdução

O aumento da produção associado à redução de custos de processamento é uma realidade cada vez mais presente no cenário industrial. Visando atingir tal diretriz, são necessários investimentos, diferentes ferramentas e metodologias, tais como métodos de controle avançado. Estes métodos normalmente fazem uso de modelos representativos do processo (Hjalmarsson, 2005), porém, a modelagem do processo demanda tempo e mão-de-obra qualificada e pode custar mais de 50% do investimento feito na implementação de controle avançado (Azlan Hussain, 1999).

Os modelos tradicionalmente utilizados para sintonia de controladores PID (Proporcional – Integral – Derivativo) e implementação de métodos de controle avançado, como MPCs (*Model Predictive Control*), são os LTI (*Linear Time Invariant*), pois a maior parte dos controladores ativos nos processos industriais são lineares e a sua sintonia é baseada em modelos lineares do processo. Os modelos LTI obtidos representam bem a dinâmica da planta em determinada faixa de operação e são mais facilmente determinados do que modelos não-lineares. Embora os modelos não-lineares permitam uma melhor representação do processo, a sua complexidade dificulta o cálculo das ações de controle e também a sua identificação (Verhaegen, 1993).

Existem várias formas de se classificar os tipos de modelos. Uma delas agrupa os modelos em três categorias definidas pelo método de determinação. Estes métodos são chamados

modelagem caixa branca, modelagem caixa preta e modelagem caixa cinza, e o modelo determinado leva o nome do método. A modelagem caixa branca é conhecida como modelagem conceitual ou rigorosa. Ela utiliza leis físicas que descrevem o sistema para se obter o modelo, porém este método nem sempre é viável devido ao nível de conhecimento requerido do processo e ao tempo necessário para se desenvolver o modelo. A modelagem caixa preta, também chamada de identificação ou modelagem empírica, é uma alternativa à modelagem caixa branca, pois é necessário pouco ou nenhum conhecimento prévio sobre o processo. Os modelos caixa preta descrevem apenas as relações causa efeito entre as variáveis de entrada e saída e o modelo não apresenta um significado físico. A modelagem caixa branca e caixa preta podem ser interpretadas como os extremos da técnica de modelagem. A modelagem caixa cinza é uma metodologia intermediária, que busca aproveitar as vantagens da modelagem caixa branca e caixa preta. Nesse caso, tanto dados de entrada e saída obtidos no sistema quanto informação auxiliar são usados na identificação (Corrêa e Aguirre, 2004).

Na indústria, a elevada complexidade de alguns processos dificulta a determinação de modelos matemáticos fenomenológicos que os representem. Muitas vezes, algumas informações sobre o sistema não estão disponíveis ou até mesmo as leis físicas e químicas não são capazes de descrever com detalhes algumas etapas do processo, inviabilizando a construção do modelo caixa branca ou gerando um modelo não representativo do processo. A identificação de um modelo caixa preta, por outro lado, pode ser mais rápida e necessita de menos informações sobre o processo, o que justifica seu largo emprego em unidades industriais. No entanto, a identificação é intrusiva, ou seja, é preciso perturbar o processo para se obter os dados necessários. Isso pode tirar o processo do ponto de operação ideal gerando produtos fora de especificação e transtornos à operação (Corrêa e Aguirre, 2004).

O sucesso do processo de identificação depende de muitos fatores, tais como: tipo de sinal utilizado nas perturbações, a sequência destas perturbações, a estratégia de identificação utilizada, a relação sinal de saída/ruído, a presença de distúrbios não medidos, o método de identificação utilizado, o formato do modelo, o tempo despendido com a realização dos testes e o quanto o processo foi removido de seu ponto de operação. Testes de identificação bem projetados reduzem os custos gerados pelos dois últimos fatores citados, por reduzirem o tempo gasto com a obtenção dos dados e retirarem pouco o sistema do ponto de operação, gerando dados ricos em informação do processo, o que é de suma importância para a identificação de um modelo de boa qualidade capaz de representar o sistema (Zhan, Li e

Georgakis, 2006). Perturbações mal projetadas podem não excitar o processo em regiões importantes, gerando dados que trazem pouca informação sobre o processo e produzindo modelos que não representam as reais características do processo. Isso faz com que todo o esforço, tempo e custo para obter estes dados sejam desperdiçados, e novos testes serão necessários para complementar os dados gerados.

Muitos estudos têm sido feitos na área de planejamento de perturbações para processos MIMO (Misra e Nikolaou, 2003; Conner e Seborg, 2004; Bruwer e Macgregor, 2006; Micchi e Pannocchia, 2008). Diversos aspectos da identificação ainda não têm uma metodologia bem definida, por exemplo, a determinação da amplitude mínima da perturbação para que o sinal de saída tem amplitude suficiente para ser diferenciado do ruído e a definição do melhor sinal para perturbar as dinâmicas do processo.

A principal perturbação empregada industrialmente é o teste degrau em malha aberta. Esta metodologia é de simples aplicação, pois consiste em uma mudança abrupta na variável de entrada, assumindo dois possíveis valores distintos, u_{sup} e u_{inf} . Estes valores têm o mesmo valor absoluto, mas são aplicados em sentidos diferentes. Usualmente, pelo menos um degrau em cada sentido é realizado para que as variáveis não operem fora da média e se mantenham dentro dos limites estipulados. Em processos multivariáveis, ou MIMO (*Multiple Inputs Multiple Outputs*), o teste degrau é feito de forma não simultânea, ou seja, as variáveis de entrada não são perturbadas ao mesmo tempo, o que permite visualizar o efeito de cada entrada em cada saída. Por isso pode-se dizer que as perturbações nas variáveis de entrada não são correlacionadas. A duração dos degraus é determinada de forma que o sistema chegue próximo ao estado estacionário, fazendo com que seja obtida informação principalmente da região de baixas frequências. Dependendo da dinâmica do processo, os testes degrau podem elevar muito o tempo de obtenção de dados, elevando também o custo da identificação do modelo (Ljung e Glad, 1994).

Para processos MIMO, existem outras dificuldades na identificação do modelo, pois, diferentemente de processos SISO (*Single Input Single Output*), eles apresentam características que dependem da correlação, ou direção, das perturbações nas suas variáveis de entrada. Essas características são: direções de maior e de menor ganho, que ocorrem em processos mal condicionados, e zeros de transmissão. O teste degrau, ou qualquer outro método de perturbações não correlacionadas, pode acarretar a perda deste tipo de informação,

pois não perturba simultaneamente as variáveis de entrada nas direções adequadas, podendo levar à identificação de modelos não representativos da planta,. Em casos de processos MIMO mal condicionados, mesmo que as perturbações sejam correlacionadas na direção de menor ganho a resposta do sistema poderá ter amplitude muito pequena e será confundida com o ruído do processo. Para evitar este problema, a amplitude da perturbação na direção de menor ganho também tem que ser levada em conta (Hägglom e Böling, 1998).

Apesar da identificação de modelos caixa preta ser amplamente difundida na indústria, não há consenso sobre o método de perturbação (Degrau, PRBS e GBN) adequado para cada característica de processo, tanto para sistemas bem quanto mal condicionados. Além disso, não há na literatura método de planejamento de perturbações que permita a excitação adequada de sistemas mal condicionados, garantindo que as saídas se mantenham dentro de limites especificados pelo engenheiro. A proposição e teste de tal metodologia é o objetivo principal deste trabalho.

O método proposto é comparado com a metodologia de dois passos proposta por Zhu e Stec (2001, 2006) e apresenta melhoria significativa na qualidade dos modelos identificados. Porém, por ser um método iterativo, o método proposto requer um tempo de duração maior que o método de dois passos. Para tornar a comparação mais justa, é feita nova comparação reduzindo o tempo de duração das perturbações em cada iteração até que o tempo total do experimento seja igual ao tempo utilizado nas perturbações de dois passos. Nesta nova comparação a qualidade dos modelos foi mais baixa, porém continuou melhor que os modelos identificados pelo método de dois passos.

O método proposto busca maximizar a amplitude de perturbação até que uma das variáveis atinja o limite máximo imposto, possibilitando que mais informações do processo sejam adquiridas durante o experimento e gerando modelos mais representativos do processo. O procedimento de maximização das amplitudes de perturbação é iterativo e utiliza como critério de parada o número de iterações ou a qualidade do modelo identificado. Para avaliar a qualidade do modelo, foi proposto um fator de confiabilidade, que representa o quão confiável o modelo está para que a nova perturbação possa ser aplicada com amplitude maior.

Para a comparação dos métodos é utilizado o modelo de uma coluna de destilação binária de alta pureza utilizando o refluxo de topo e a vazão de vapor no refeedor como variáveis

manipuladas (Skogestad e Morari, 1987). Essa coluna é um exemplo clássico na literatura de processo mal condicionado. Foram definidas restrições para as variáveis de entrada e saída do modelo e todas as perturbações foram projetadas para que as restrições não fossem violadas.

Além disso, são realizadas comparações entre métodos clássicos da literatura de perturbações não correlacionadas (Degrau, PRBS e GBN). O objetivo dessas comparações é mostrar que a correlação das perturbações é muito importante para a identificação de processos mal condicionados e evidenciar as principais diferenças entre os métodos.

Porém, o principal objetivo do trabalho é desenvolver uma metodologia de projeto de experimento de identificação para a obtenção de modelos multivariáveis de processos mal condicionados com restrições nas variáveis de entrada e saída, causando o mínimo de perturbação no processo.

1.1 Estrutura da Dissertação

Esta dissertação está dividida em cinco capítulos. No Capítulo 2 é feita uma breve descrição dos pontos mais importantes em relação à identificação de modelos lineares. O Capítulo 3 descreve as metodologias aplicadas e a proposta deste trabalho para o projeto de experimentos de identificação levando em conta a direcionalidade do sistema. No Capítulo 4 são apresentados os resultados obtidos na comparação dos modelos identificados utilizando as metodologias de perturbação descritas no Capítulo 3. O Capítulo 5 apresenta as principais conclusões do trabalho e propostas para trabalhos futuros.

Capítulo 2

Revisão Bibliográfica

Neste capítulo é realizada a revisão acerca dos principais conceitos e metodologias envolvidos na identificação de modelos caixa preta de processos. Inicialmente, os principais conceitos serão sumarizados e posteriormente as metodologias de planejamento de perturbações revisadas.

2.1 Identificação de Modelos

Com a evolução computacional das últimas décadas, o número cada vez maior de variáveis disponíveis no processo e a facilidade em se armazenar e tratar estes dados fez com que a identificação de modelos empíricos fosse cada vez mais utilizada industrialmente. Um grande número de estudos foi realizado nas últimas décadas trazendo contribuições valiosas para a identificação de modelos, especialmente na consistência, confiabilidade e eficiência numérica dos algoritmos de identificação (Micchi e Pannocchia, 2008).

O processo de identificação de modelos dinâmicos, segundo alguns autores (Ljung e Söderström, 1983; Conner e Seborg, 2004), é dividido em quatro partes principais: planejamento e realização dos testes de perturbação, seleção da estrutura do modelo, cálculo dos parâmetros do modelo e validação do modelo (Zhu e Butoyi, 2002). Tal procedimento deve ser repetido de forma iterativa, como mostrado na Figura 2.1, até que um modelo

representativo do sistema seja determinado. Se o modelo identificado não é adequado para a utilização, é feita uma revisão dos procedimentos. Começa-se pelo método de cálculo dos parâmetros, em seguida a estrutura do modelo selecionado e por último se necessário os experimentos de identificação são planejados novamente e repetidos para gerarem dados com mais informações sobre o sistema (Cunha, 2004).

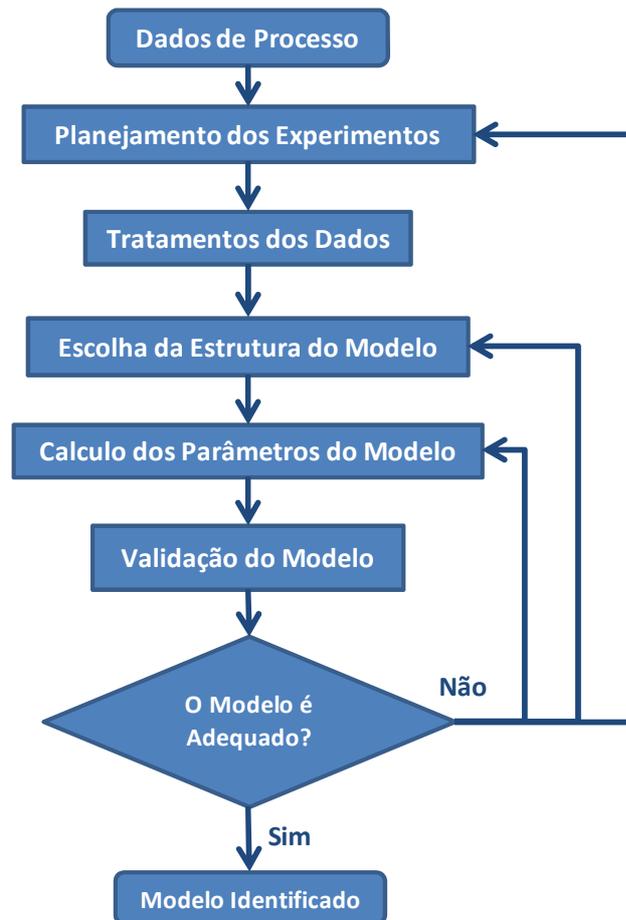


Figura 2.1: Algoritmo do processo de identificação.

Os modelos dinâmicos identificados podem ser classificados seguindo uma série de características,(Ljung, 1999):

- Modelos lineares ou não-lineares;
- Modelos variantes no tempo ou invariantes no tempo;

- Modelos discretos ou contínuos;
- Modelos monovariáveis ou multivariáveis;
- Modelos determinísticos ou estocásticos;
- Modelos paramétricos ou não paramétricos;
- Modelos com parâmetros concentrados ou parâmetros distribuídos;

Os modelos tradicionalmente utilizados para controle de plantas industriais são os LTI, ou seja, modelos lineares invariantes no tempo, pois representam bem a dinâmica da planta e são fáceis de serem identificados. Embora os modelos não-lineares permitam a representação do processo em um intervalo mais amplo, a sua complexidade dificulta o cálculo das ações de controle e também a sua identificação. Muitas vezes, a não linearidade é confundida com distúrbios não medidos, os quais são componentes estocásticos do processo, assim como o ruído de medida (Ljung, 1999).

Os modelos monovariáveis são comumente representados por funções de transferência tanto no domínio discreto quanto no domínio contínuo (Li, Su e Chu, 2006). Os modelos multivariáveis são expressos normalmente em matriz de transferência, onde cada elemento da matriz representa a função de transferência e uma variável de entrada para uma variável de saída.

2.1.1 Identificação para Aplicação em MPC

Nas últimas três décadas, a tecnologia do controle preditivo baseado em modelo (MPC) tem sido amplamente aplicada na indústria de refino e petroquímica, bem como em outras indústrias de processo. O controle preditivo traz grandes benefícios para o processo, melhorando a qualidade de produtos e otimizando a sua produção e seu custo ao levar o sistema para condições operacionais que reduzem o custo de energia e de utilidades em geral (Prett e García, 1988). A ideia central por trás de um MPC é a utilização de um modelo dinâmico representativo do processo que possa indicar pontos de operação ótimos e também a melhor forma de atingir estes pontos de operação. A parte mais difícil e que consome o maior

tempo durante a aplicação do projeto de um MPC é a modelagem e identificação do modelo dinâmico (Qin e Badgwell, 2003).

Na implementação de MPC, são utilizados modelos multivariáveis devido à natureza deste controle. O sucesso da aplicação do controle avançado é dependente da qualidade do modelo identificado, o que pode não ser uma tarefa fácil em se tratando de identificação de modelos multivariáveis. A etapa de identificação do modelo pode consumir até 50% dos recursos reservados para o projeto do MPC. Por ser um processo que demanda muitos recursos, muitos MPCs permanecem muito tempo sem atualização do seu modelo, perdendo a representatividade, representando muitas vezes abandono (Álvarez *et al.*, 2013).

As dificuldades em se identificar processos com mais de uma variável começam pelo fato de que é muito mais simples observar o comportamento de cada par de variáveis entrada/saída separadamente. Porém, um conjunto de identificações SISO somadas não garante um modelo multivariável com bom desempenho para MPC, como é o caso de sistemas mal condicionados e sistemas com zeros de transmissão (Stec e Zhu, 2001). Para garantir a robustez do controle utilizando MPC, o modelo deve conter esse tipo informação. O tempo gasto para realizar identificações SISO em um sistema com muitas variáveis também é um fator limitante para o método.

2.1.2 Condicionamento do sistema

A grande interação entre as variáveis também é um fator que dificulta a identificação de um sistema multivariável através da soma das identificações SISO, pois, quando se realizam identificações isoladas, a informação da resposta do sistema às interações entre as variáveis manipuladas é perdida (Li e Georgakis, 2008). Para um modelo que será utilizado para controle multivariável, esse tipo de informação é crucial para garantir a estabilidade e a robustez do controle. A interação entre as variáveis pode criar sistemas mal condicionados, onde existem combinações de variáveis, ou direções, que geram respostas com ganhos muito distintos (Skogestad e Morari, 1988). Um dos maiores problemas na identificação de sistemas mal condicionados é que as perturbações comumente utilizadas, como o teste degrau, PRBS (*Pseudo Random Binary Sequence*) e GBN (*Generalised Binary Noise*), não perturbam as direções de menor ganho ou, quando perturbam, não o fazem com amplitude suficiente para

que uma variação no sinal de saída seja percebida, e muitas vezes acabam ficando escondidas no ruído do sistema (Stec e Zhu, 2001). Isso faz com que os dados coletados sejam pobres em informação sobre as direções de menor ganho e o modelo gerado não seja capaz de ser utilizado em uma estratégia de controle multivariável (Zhu e Stec, 2006).

Exemplos clássicos de sistemas mal condicionados são colunas de destilação de alta pureza que utilizam a vazão de refluxo e a vazão de vapor do refeedor como variáveis manipuladas (estrutura LV de controle), onde o sistema tem um ganho muito pequeno quando a pureza do produto de topo e de fundo é aumentada ou reduzida simultaneamente e um ganho muito grande quando a pureza é aumentada em um dos produtos e reduzida no outro. No capítulo 3 este processo é explicado em mais detalhes.

Um sistema linear multivariável, com matriz de ganho estacionário G_0 , pode ser fatorado por meio de uma decomposição em valor singular, SVD (*Singular Value Decomposition*):

$$U\Sigma V = SVD(G_0) \quad (2.1)$$

Onde U , Σ e V são matrizes quadradas com as mesmas dimensões da matriz G_0 . A matriz U é a matriz de direções para o *setpoint*. As colunas dessa matriz representam as combinações de mudanças no *setpoint* das variáveis de saída do sistema que apresentam o maior ganho (primeira coluna) até o menor ganho (última coluna). A matriz V é a matriz de direções para as variáveis de entrada. As suas colunas representam as combinações das variáveis de entrada que geram o maior ganho (primeira coluna) até o menor ganho (última coluna). A matriz Σ é a matriz de valores singulares, que representam o valor do ganho de cada direção, tanto para variações no *setpoint* quanto para variações nas variáveis de entrada do sistema. Essa matriz é diagonal, onde o primeiro valor da diagonal representa o maior valor singular (σ_M) e o último valor representa o menor valor singular (σ_m) do sistema (Chiuso e Picci, 2004).

A relação entre o maior valor singular e o menor valor singular presentes na matriz diagonal Σ é conhecido como número de condicionamento (γ). Um sistema é dito bem condicionado quando seu condicionamento é menor que 5. Para um sistema ser considerado mal condicionado, γ deve ser maior que 50 (Trierweiler, 1997), o que sugere que os valores das saídas do sistema dependem fortemente da direção de suas entradas e, conseqüentemente, existem ganhos distintos em suas respostas dependendo da combinação de perturbações

realizadas nas suas variáveis de entrada. Quanto maior o número de condicionamento, mais próxima de ser singular estará a matriz de ganhos estacionários e mais mal condicionado é o sistema (Zhu e Stec, 2006). Porém, para sistemas MIMO com diferentes tipos de entradas e saídas (temperatura, vazão, composição, etc.), a escala das unidades tem efeitos significantes no número de condicionamento. O escalonamento do sistema não afeta as características mas tem efeito nos valores singulares. Um processo com alto grau de interação, ou acoplamento, é sempre mal condicionado, enquanto o contrário nem sempre é verdadeiro, pois um sistema pode ser mal escalonado devido à presença de variáveis distintas.

Para verificar se um sistema é verdadeiramente mal condicionado deve-se determinar o número de condicionamento mínimo do sistema. O condicionamento mínimo do sistema é obtido através de:

$$\gamma^*(G_0) = \min_{L,R} \gamma(LG_0R) \quad (2.2)$$

Onde L e R são matrizes reais, diagonais e não singulares que representam o escalonamento das variáveis de entrada e de saída, respectivamente. Então um sistema é considerado verdadeiramente mal condicionado quando γ^* é maior que 50 e é considerado mal escalonado quando γ é maior que 50 e γ^* menor do que 5 (Trierweiler, 1997).

Outra forma de avaliar a interação entre as variáveis é através da matriz de ganhos relativos, RGA (*Relative Gain Array*), proposta por (Bristol, 1977). A matriz RGA é obtida segundo a relação:

$$RGA = G_0 \cdot *(G_0^{-1})^T = [\lambda_{ij}]_{n \times n} \quad (2.3)$$

Onde $X_1 \cdot *X_2$ denota a multiplicação elemento a elemento das matrizes X_1 e X_2 . λ_{ij} é a razão entre o ganho da variável manipulada j sobre a variável controlada i mantendo todas as outras variáveis manipuladas constantes e em malha aberta dividido pelo ganho da variável manipulada j sobre a variável controlada i mantendo todas as demais malhas fechadas. A vantagem desta abordagem é a independência da escala para determinar a interatividade entre as variáveis, ou seja, $RGA(LG_0R)$ é igual ao $RGA(G_0)$. O cálculo de λ_{ij} é expresso por:

$$\lambda_{ij} = \frac{\left(\frac{\Delta y_i}{\Delta u_j} \right)_{u_{k \neq j} = cte}}{\left(\frac{\Delta y_i}{\Delta u_j} \right)_{y_{k \neq i} = cte}} \quad (2.4)$$

Para um sistema MIMO 2x2, a matriz RGA pode ser representada pela equação 2.5. A equação também mostra que a matriz RGA tem seus vetores unitários e é diagonal-dominante. Isso vale para matrizes RGA de sistemas com mais de duas variáveis de entrada e duas variáveis de saída (Trierweiler, 1997).

$$RGA = \begin{bmatrix} \lambda & 1 - \lambda \\ 1 - \lambda & \lambda \end{bmatrix} \quad (2.5)$$

$$y = \frac{1}{1 - \frac{g_{12}g_{21}}{g_{11}g_{22}}}$$

Onde g_{ij} são os elementos da matriz G_0 . Em um processo com elevada interação, λ é maior que 10 (Zhu e Stec, 2006), o que implica em uma planta com comportamento mal condicionado.

2.2 Planejamento e Realização dos Testes de Identificação

Os dados para a identificação de modelos são usualmente obtidos durante experimentos de identificação especialmente projetados (Ljung, 1999). No entanto, por muitos anos os principais estudos foram feitos visando o desenvolvimento e aperfeiçoamento das técnicas de ajuste dos parâmetros (Zhu, 1998). Já se sabia que, para processos SISO, os testes de identificação deveriam ser projetados de acordo com o objetivo do modelo obtido para que trouxessem informações úteis sobre o processo (Gevers e Ljung, 1986). Em seguida, estudos de perturbações para o desenvolvimento de modelos para a implementação de controle robusto e MPC's foram propostos (Koung e Macgregor, 1993).

O projeto de perturbações inclui escolhas como quais sinais medir e quando os medir, quais sinais utilizar e como os manipular. As perturbações devem ser pequenas o suficiente para minimizar o impacto na planta e a influência de não linearidades do processo; ao mesmo tempo devem ser grandes o suficiente para minimizar os efeitos do ruído e distúrbios. Diferentemente das outras etapas de identificação, que podem ser testadas computacionalmente, os dados gerados através dos experimentos de identificação só podem ser substituídos por dados obtidos de novos experimentos, o que seria custoso e consumiria muito tempo. Por essa razão, é necessário que os experimentos sejam projetados com cuidado, para que gerem dados suficientemente informativos (Zhu, 2001).

Na escolha do tipo de perturbação das entradas se deve levar em conta principalmente o espectro de frequência, que mostra as principais frequências excitadas pela perturbação. O conjunto das principais frequências excitadas deve conter a frequência de operação desejada para o controlador. Para sistema multivariáveis, as formas como as variáveis de entrada são perturbadas também é muito importante. Neste sentido as perturbações podem ser correlacionadas e não correlacionadas. As perturbações não correlacionadas são aplicadas independentemente umas das outras nas variáveis de entrada, ou seja, não apresentam correlação e, portanto, não excitam nenhuma direção do sistema em específico. Já as perturbações correlacionadas são aplicadas igualmente em todas as variáveis, variando apenas a amplitude da perturbação. Este tipo de perturbação excita direções específicas do sistema e por isso apresenta grande vantagem na identificação de sistemas mal condicionados (Stec e Zhu, 2001).

Subsequentemente, será realizada uma descrição mais detalhada sobre os principais tipos de perturbações não correlacionadas e correlacionadas utilizadas neste trabalho.

2.2.1 Perturbação Degrau

Atualmente, testes degrau não simultâneos e em malha aberta são frequentemente utilizados para a obtenção de dados para a identificação. Esta metodologia é de simples aplicação, pois consiste em uma mudança abrupta na variável de entrada, assumindo dois possíveis valores distintos, representados por u_{sup} e u_{inf} . Ambos têm o mesmo valor absoluto, mas são aplicados em sentidos diferentes, assumindo que o valor base da variável manipulada é nulo.

Usualmente, pelo menos um degrau em cada sentido é realizado para que a variabilidade e a média da variável controlada sejam reduzidas para que o processo não se afaste do ponto de operação ideal. No entanto, este tipo de teste não excita o sistema em regiões de alta frequência, pois a sua energia está situada na região de baixas frequências do espectro de frequência e acaba não sendo persistentemente excitante para frequências maiores. Para que a perturbação degrau seja persistentemente excitante em uma banda maior de frequência seria necessário aumentar o número e reduzir o tempo de permanência dos degraus. Existem outros tipos de perturbação que possibilitam a manipulação da banda de frequência excitada, como o PRBS e o GBN (Zhu e Van Den Bosch, 2000).

Em processos multivariáveis, o teste degrau é feito de forma não simultânea, ou seja, as variáveis de entrada não são perturbadas ao mesmo tempo, como ilustra a Figura 2.2, o que permite visualizar o efeito de cada entrada em cada saída (Ljung, 1999). Mesmo que os degraus fossem feitos simultaneamente levando em conta as direções do sistema, a amplitude da perturbação na direção de menor ganho seria muito pequena para que a resposta do sistema tenha uma relação sinal/ruído suficiente. Desta forma, o sinal de saída não seria diferenciado do ruído do sistema e a informação da direção de menor ganho seria perdida.

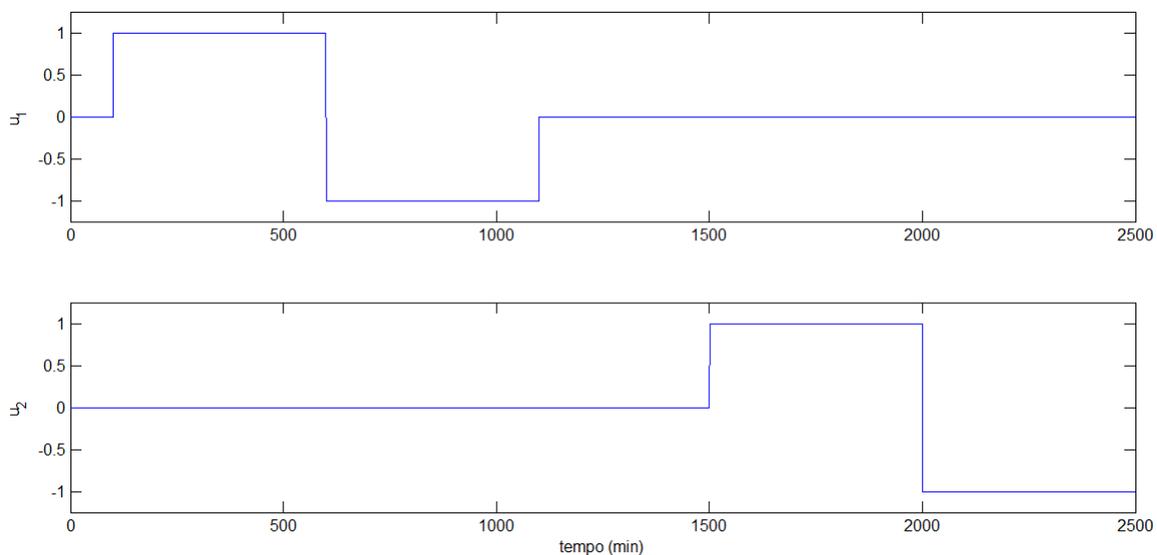


Figura 2.2: Perturbação degrau para um sistema multivariável.

A duração dos degraus é determinada de forma que o sistema se aproxime do estado estacionário nas variáveis de saída, fazendo com que este processo obtenha informação principalmente da região de baixas frequências. Dependendo da dinâmica do processo, o experimento degrau pode elevar muito o tempo de obtenção de dados, elevando também o custo, pois o processo pode ser removido por muito tempo do seu ponto de operação, podendo gerar produtos fora de especificação com pouco ou até mesmo nenhum valor agregado.

2.2.2 Perturbação PRBS

A perturbação PRBS também é utilizada industrialmente. Assim como no teste degrau, o PRBS pode assumir somente dois valores: u_{inf} e u_{sup} . No entanto, permanece por tempos distintos em cada valor, diferentemente do teste degrau, que permanece sempre o mesmo tempo em cada valor. O tempo de permanência é determinado através de uma metodologia que visa perturbar todo o espectro de frequências do sistema. Isso traz ao PRBS a grande vantagem de excitar com intensidade suficiente uma grande faixa de frequências. Uma desvantagem do PRBS é o favorecimento das altas frequências, tirando pouca informação de frequências mais baixas, que trazem informações importantes do estado estacionário do sistema. Para isto, devem ser calculados os períodos de permanência máximo e mínimo em cada valor, dando a característica determinística do sinal. O sinal PRBS é gerado através da seguinte equação:

$$u(t) = \text{rem}(P(q)u(t), 2) = \text{rem}(a_1 u(t-1) + \dots + a_n u(t-n), 2) \quad (2.6)$$

Onde $\text{rem}(x, 2)$ é o resto da divisão de x por 2, que será sempre 0 ou 1. $P(q)$ é um polinômio de deslocamento onde as constantes a_k assumem valores de 0 ou 1 de acordo com a ordem n determinada para a sequência PRBS, como mostra a Tabela 2.1. A variável q é chamada de operador de deslocamento e pode assumir valores de deslocamento positivos e negativos, fazendo os valores do vetor $u(t)$ sejam deslocados gerando o vetor de perturbações passadas. O vetor de perturbações passadas $[q^{-1}u(t) \dots q^{-n}u(t)] = [u(t-1) \dots u(t-n)]$ pode assumir somente 2^n valores, portanto, este vetor deve ser periódico e com período de no máximo 2^n . Porém existe a possibilidade de todos os n valores serem zeros e gerar uma perturbação igualmente igual a zero. Então eliminando esta possibilidade o período máximo de permanência da perturbação em um estado será $M = 2^n - 1$. O real período máximo da perturbação será

determinado por $P(q)$, porém os valores da Tabela 2.1 garantem que o período máximo esteja contido na perturbação.

O intervalo de frequências excitadas pela perturbação PRBS (*Band Width*, BW) pode ser definido por:

$$\omega_L = \frac{1}{\beta\tau_{\max}} \leq BW \leq \frac{\alpha}{\tau_{\min}} = \omega_H \quad (2.7)$$

Onde τ_{\max} e τ_{\min} são a maior e menor constantes de tempo do sistema MIMO, respectivamente; α é especificado para assegurar que esteja disponível conteúdo suficiente de alta frequência no sinal de excitação, medido como quão rápido se espera que a resposta em malha fechada seja em relação à resposta em malha aberta; β é especificado para assegurar que existam frequências baixas no sinal de entrada. Assim o intervalo $BW=[\omega_L ; \omega_H]$ é a faixa de frequências onde se deseja que a energia do sinal de excitação esteja concentrada.

Tabela 2.1: Valores dos a_k parâmetros do polinômio $P(q)$ para cada ordem n da perturbação PRBS.

n	M	$a_k = 1$ para k
2	3	1 e 2
3	7	2 e 3
4	15	1 e 4
5	31	2 e 5
6	63	1 e 6
7	127	3 e 7
8	255	1, 2, 7 e 8
9	511	4 e 9
10	1023	7 e 10
11	2047	9 e 11

A ordem n da perturbação é determinada através da maior frequência que deve ser excitada. Fazendo a multiplicação do tempo escolhido para a perturbação e a frequência máxima que será excitada é determinado o valor de M , e com isso os valores dos parâmetros de $P(q)$ são

determinados. A característica da perturbação depender dos seus valores passados a torna uma perturbação determinística, por isso o nome “pseudo-randômico”, pois existirá somente uma perturbação para cada $P(q)$ (Ljung, 1999).

Diferente do teste degrau, a perturbação PRBS é normalmente empregada simultaneamente nas variáveis de entrada de sistemas multivariável, como ilustrado na Figura 2.3.

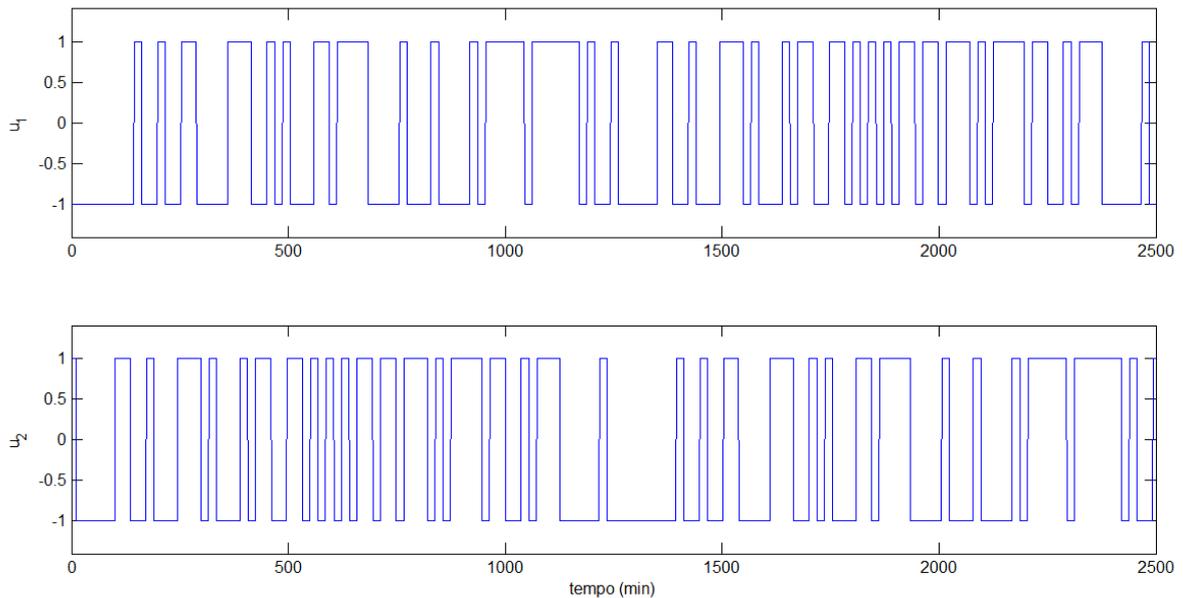


Figura 2.3: Perturbação PRBS para um sistema multivariável.

Para que não exista correlação entre as perturbações é necessário realizar um deslocamento no tempo entre elas, pois, o polinômio $P(q)$ é o mesmo para as duas perturbações e faria com que elas fossem exatamente iguais. Na Figura 2.3 é possível notar que a perturbação em u_1 e u_2 são iguais, porém defasadas em aproximadamente 1250 minutos. Também é possível perceber o favorecimento de frequências mais altas, pois, o maior período de permanência acontece apenas uma vez, em quanto que o menor período de permanência ocorre muitas vezes durante a perturbação. Esta característica do método PRBS faz com que a matriz de ganhos estacionários não seja bem identificado, gerando maiores erros quando métodos de erro de predição (PEM) são utilizados para estimar os parâmetros do modelo.

Da mesma forma que a perturbação degrau, mesmo que as perturbações fossem correlacionadas na direção de menor ganho não teriam energia suficiente para que o sinal de saída fosse diferenciado do ruído do sistema.

2.2.3 Perturbação GBN (Generalised Binary Noise)

Os dois métodos de perturbação mais utilizados na identificação de modelos são o Degrau e o PRBS. O Degrau é persistentemente excitante na zona de baixas frequências, já o PRBS é persistentemente excitante em toda a faixa de frequências, porém acaba favorecendo frequências mais altas.

Para definir melhor as frequências excitadas pela perturbação, foi proposto o GBN, onde é introduzido um parâmetro que determina a probabilidade de não ocorrer troca de sinal (Chen e Yu, 1997). Esse parâmetro torna possível manipular o espectro de frequências excitadas de acordo com a necessidade. O sinal GBN é gerado da mesma forma que um ruído binário, exceto pelo fato de que no ruído binário a probabilidade, p , do sinal se manter no mesmo valor é de $\frac{1}{2}$, enquanto que o GBN pode assumir probabilidades entre 0 e 1. Isso abre um grau de liberdade para o planejamento do experimento de identificação que pode ser otimizado para trazer mais informações para os dados de identificação. Quando p é definido com valores inferiores a $\frac{1}{2}$, a energia da perturbação estará concentrada nas maiores frequências, enquanto que para p maior que $\frac{1}{2}$ a energia da perturbação estará concentrada nas menores frequências (Tulleken, 1990). A Figura 2.4 mostra a influência de p no espectro de frequências de um sinal do tipo GBN, onde T é o menor tempo de permanência possível do sinal.

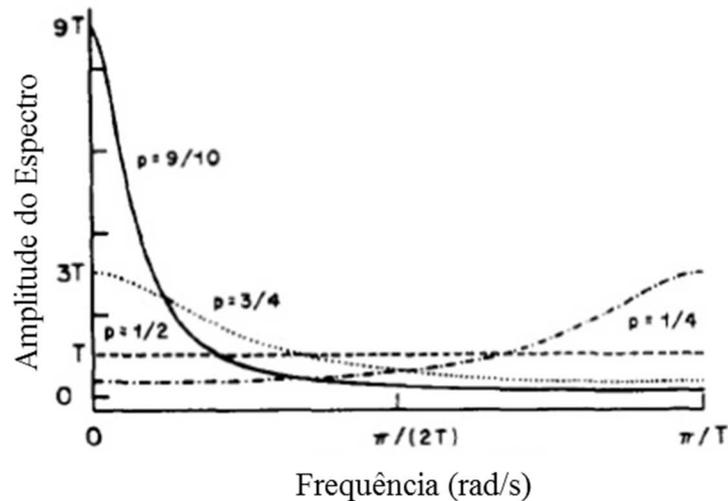


Figura 2.4: Comparação do espectro de frequências de um sinal GBN para diversos valores de p (Tulleken, 1990).

Quanto maior o valor de p , maior será a excitação gerada pela perturbação nas baixas frequências do sistema, ou seja, mais informações sobre o estado estacionário do sistema serão obtidas, pois o tempo de permanência das perturbações tende a ser maior. Quando p é igual ou menor que $1/2$ a excitação gerada pela perturbação tende a se distribuir nas regiões de alta frequência do sistema, isso faz com que sejam perdidas informações do estado estacionário e também traz informações de frequências mais altas que a frequência de operação do controlador. Este tipo de informação não é útil, pois o sistema nunca atingirá esta região de frequência.

Para a perturbação GBN também é preciso definir o intervalo de frequências onde o sinal estará contido, assim como no PRBS. Desta forma os tempos de permanência da perturbação serão sempre maiores que $2\pi/\omega_H$ e nunca maiores que $2\pi/\omega_L$. A Figura 2.5 mostra a comparação de três perturbações realizadas com diferentes valores de p e com o mesmo intervalo de frequência (Tulleken, 1990).

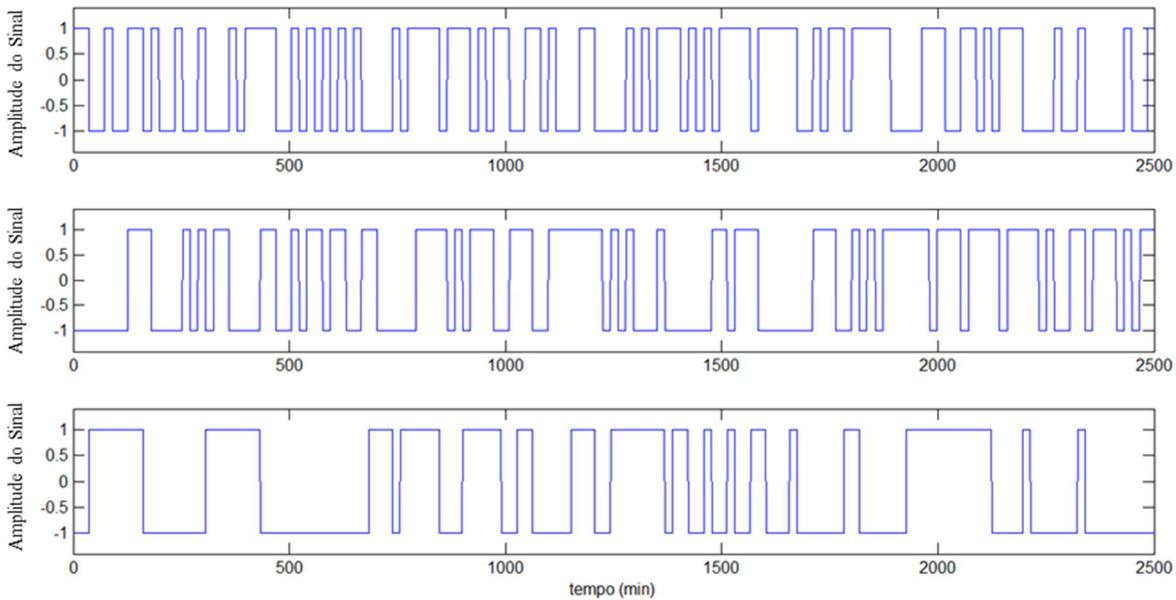


Figura 2.5: Comparação da perturbação GBN para p igual a $1/4$, $1/2$ e $3/4$, respectivamente, em um mesmo intervalo de frequência.

Como pode ser visto na Figura 2.5, a perturbação GBN com maior valor de p tem períodos maiores entre trocas de nível. Isso traz mais informações das frequências mais baixas. Diferentemente do PRBS que se propõe em excitar todas as frequências, o GBN favorece as frequências menores. Isso traz um ganho significativo na identificação da matriz de ganhos estacionários e na qualidade do modelo como um todo. O GBN com p igual a $1/2$ gera perturbações muito próximas às perturbações PRBS, como pode ser visto quando se comparam as Figuras 2.5 e 2.3. Isso mostra que perturbações GBN com p maior que $1/2$ geram dados com mais informações de frequências baixas do sistema do que as perturbações geradas com PRBS, gerando modelos com menor erro na matriz de ganhos estacionário (Tulleken, 1990). No Capítulo 3 é feita uma comparação entre os métodos para mostrar as vantagens das perturbações GBN frente às perturbações PRBS.

2.2.4 Planejamento de Perturbações Propostas por Zhu (2001 e 2006)

Processos mal condicionados são difíceis de serem controlados quando as dinâmicas dos canais são muito próximas. Nestes casos controladores descentralizados são pouco indicados

devido à grande interação entre as variáveis, e MPCs podem sofrer problemas de robustez (Skogestad e Morari, 1988). Além disso, processos mal condicionados são difíceis de serem identificados, porque tradicionais testes de identificação como o teste degrau em malha aberta e PRBS tendem a excitar o sistema majoritariamente na direção de maior ganho (Jacobsen e Skogestad, 1994). Dependendo da direção das entradas as magnitudes das respostas podem variar consideravelmente entre as direções de maior ganho e menor ganho. Esta variação faz com que a informação sobre a direção de maior ganho se sobreponha à informação de menor ganho, causando a perda desta informação e gerando modelos que não são apropriados ao propósito de controle (Koung e Macgregor, 1994).

Para resolver o problema da identificação da direção de menor ganho em processos mal condicionados foram feitas algumas propostas, nas quais se utiliza sinais correlacionados das variáveis de entrada que sejam capazes de excitar tanto a direção de maior ganho quanto a direção de menor ganho (Koung e Macgregor, 1993; Conner e Seborg, 2004). Porém, a determinação destas direções não é uma tarefa simples. Visando resolver este problema foram propostos dois novos métodos de teste de identificação: o método de dois passos com sinais concatenados e o método de dois passos com sinais somados (Stec e Zhu, 2001; Zhu e Stec, 2006).

Para os dois métodos, o primeiro passo consiste em realizar uma identificação preliminar utilizando um sinal GBN. Como visto anteriormente na Figura 2.5, o sinal GBN não traz informações da direção de menor ganho, pois não utiliza perturbações correlacionadas, porém ela traz informações do vetor de maior ganho. Com as informações obtidas no modelo preliminar e sabendo que os vetores das direções de menor e maior ganho são ortogonais entre si, pode-se determinar uma aproximação da direção e da amplitude necessárias para perturbar esta direção.

Método de Dois Passos com Sinais Concatenados

No segundo passo do método de dois passos com sinais concatenados, um novo teste de identificação é realizado utilizando dois tipos de sinais: o primeiro utilizando sinais não correlacionados com pequena amplitude para obter informação da direção de maior ganho. Para gerar estes sinais é utilizada a metodologia GBN. O segundo sinal utiliza um sinal GBN correlacionado de alta amplitude para a obtenção dos dados da direção de menor ganho. A

determinação da amplitude do sinal correlacionado não é uma tarefa simples, pois normalmente não se conhece o menor ganho do processo (Stec e Zhu, 2001).

Essa determinação é feita testando possíveis amplitudes, até que a razão entre a amplitude do sinal das variáveis de saída e a amplitude do ruído de medida seja de aproximadamente dez. É indicado utilizar inicialmente uma amplitude de dez vezes a amplitude utilizada para a etapa dos experimentos não correlacionados, pois para um processo ser considerado mal condicionado a razão entre o ganho da direção de maior ganho e o ganho da direção de menor ganho deve ser maior que dez. Esse é um dos pontos negativos dessa metodologia, que é o tempo de execução dos experimentos, pois esta amplitude deverá ser testada durante os experimentos fazendo com que seu tempo de duração aumente consideravelmente. Esta segunda etapa do experimento de identificação está ilustrada na Figura 2.6 (Zhan, Li e Georgakis, 2006).

Método de Dois Passos com Sinais Somados

No segundo passo do método de dois passos com sinais somados, um novo teste de identificação é realizado utilizando a soma das perturbações determinadas da mesma forma que no método anterior, porém com as amplitudes multiplicadas por um fator, conforme equação 2.8. O experimento de identificação é ilustrado na Figura 2.7.

$$u(t) = \frac{1}{\sqrt{2}} [u_{hi}(t) + u_{low}(t)] \quad (2.8)$$

Onde $u_{hi}(t)$ é a perturbação determinada para elevada amplitude e $u_{low}(t)$ é a perturbação determinada para a menor amplitude. Esse fator garante que a amplitude das variáveis de saída será igual ao método anterior.

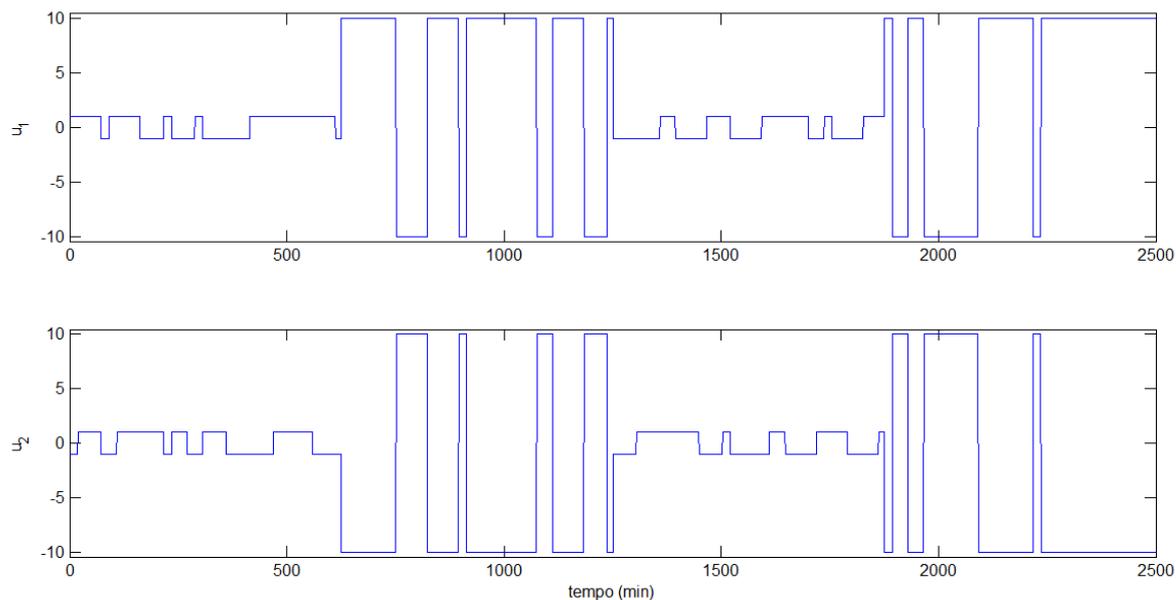


Figura 2.6: Perturbação do segundo passo do método de dois passos com sinais concatenados.

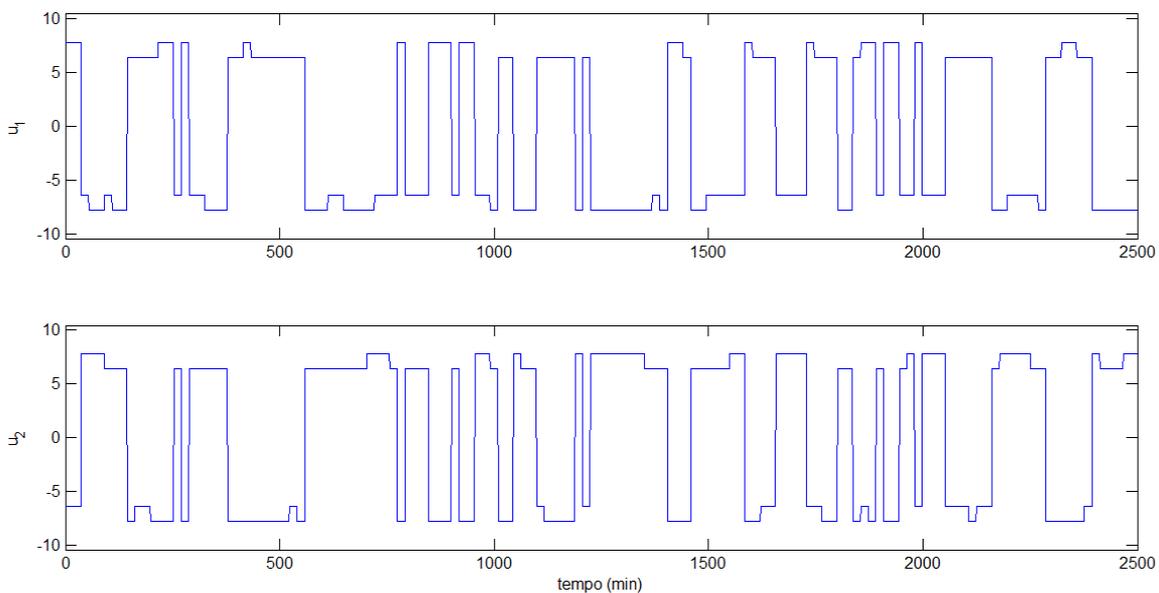


Figura 2.7: Perturbação do segundo passo do método de dois passos com sinais concatenados.

2.3 Método de Identificação - PEM (*Prediction Error Method*)

A identificação de modelos é comumente realizada pelo método do erro de predição (PEM). PEM utiliza como premissa que o modelo que melhor se ajusta aos dados é aquele que gera o menor erro de predição, onde esse erro é a diferença entre o valor real e o valor estimado pelo modelo da variável de saída (ou das variáveis de saída em caso de um sistema multivariável) (Forssell e Ljung, 1999). A representação genérica dos modelos identificados com o critério PEM segue a estrutura:

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}e(k) \quad (2.9)$$

Onde $y(k)$ é uma matriz cujas suas colunas são as variáveis de saída, $u(k)$ é uma matriz cujas colunas são as variáveis de entrada do sistema, $e(k)$ é a matriz de erros das variáveis de saída, e as linhas destas matrizes são as N amostragens das variáveis. $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são polinômios de deslocamento (q), que seguem as equações 2.10, 2.11, 2.12, 2.13 e 2.14 respectivamente.

$$A(q) = 1 - a_1q^{-1} - \dots - a_{na}q^{-na} \quad (2.10)$$

$$B(q) = b_0 + b_1q^{-1} + \dots + b_{nb}q^{-nb} \quad (2.11)$$

$$C(q) = 1 + c_1q^{-1} + \dots + c_{nc}q^{-nc} \quad (2.12)$$

$$D(q) = 1 + d_1q^{-1} + \dots + d_{nd}q^{-nd} \quad (2.13)$$

$$F(q) = 1 + f_1q^{-1} + \dots + f_{nf}q^{-nf} \quad (2.14)$$

Onde na , nb , nc , nd e nf são as ordens dos polinômios $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$, respectivamente e a_1, \dots, a_{na} , b_0, \dots, b_{nb} , c_1, \dots, c_{nc} , d_1, \dots, d_{nd} e f_1, \dots, f_{nf} são os coeficientes que serão calculados pelo método para a obtenção do modelo.

A predição dos valores, $\hat{y}(k/k-1, \theta)$, é dada por:

$$\hat{y}(k | k-1, \theta) = \left[I - \frac{A(q)D(q)}{C(q)} \right] y(k) + \left[\frac{B(q)D(q)}{C(q)F(q)} \right] u(k) \quad (2.15)$$

O vetor θ contém todos os coeficientes dos polinômios da equação 2.15. Através de um problema de otimização, obtêm-se os coeficientes dos polinômios que minimizam o erro de predição, como mostra a função objetivo a seguir.

$$\hat{\theta} = \arg \min_{\theta} \sum_{k=1}^N \|y(k) - \hat{y}(k | k-1, \theta)\|^2 \quad (2.16)$$

Onde N é o número de amostragens realizadas durante a identificação, $\hat{\theta}$ é o vetor de parâmetros do modelo que minimiza a soma da norma quadrada dos erros de predição.

Como visto na equação 2.9, o número de polinômios e o número de coeficientes que serão determinados dependem da estrutura do modelo. A escolha de tal estrutura leva em consideração alguns aspectos como o número de parâmetros necessários, a complexidade numérica da estimação dos parâmetros (não-linearidade) e a consistência obtida com esta estrutura.

Dependendo da estrutura do modelo, o problema de otimização pode se tornar linear ou não linear, e em alguns casos podem apresentar mínimos locais. As possíveis estruturas utilizadas estão apresentadas na Tabela 2.2.

Tabela 2.2: Estruturas de identificação discreta.

Polinômios usados na equação (2.3)	Estrutura do Modelo
B	FIR
A, B	ARX
A, B, C	ARMAX
A, C	ARMA
A, B, D	ARARX
A, B, C, D	ARARNAX
B, F	OE (output error)
B, F, C, D	BJ (Box-Jenkins)

2.4 Métodos de Validação

A etapa de validação dos modelos, conforme visto na seção 2.1, é a quarta etapa do processo de identificação de sistemas. Essa etapa visa indicar qual dos modelos identificados é o mais adequado para representar o sistema utilizando critérios determinados. Em quase todos os procedimentos e algoritmos de identificação, o problema de otimização para determinação dos parâmetros é formulado como a minimização do critério do erro quadrático, tal como mostra a equação 2.17.

$$J(\theta^\wedge) = \min[e(k, \theta^\wedge)^2] \quad (2.17)$$

Onde, $J(\theta)$ é o valor da função objetivo e $e(k, \theta^\wedge)$ é a diferença entre a variável medida, $y(k)$, e a predição da saída $y^\wedge(k, \theta^\wedge)$, isto é, $e(k, \theta^\wedge) = y(k) - y^\wedge(k, \theta^\wedge)$. Quanto menor for o módulo desta diferença melhor é considerado este modelo. No entanto nem sempre os parâmetros que tornam os erros de predição mínimos são os parâmetros que melhor representam o processo (Cunha, 2004). Em alguns casos pode ocorrer o *overfitting*, ou super-ajuste onde o número de parâmetros é tão elevado que o erro de predição acaba sendo baixo, porém o modelo não apresenta consistência com o sistema real. Existem alguns critérios de validação que penalizam o número de parâmetros do modelo, evitando este tipo de erro.

Os critérios mais conhecidos para validação dos modelos são: o critério AIC (*Akaike's Information Criterion*) e o critério MDL (*Minimum Description Length*), apresentados nas equações 2.18 e 2.19.

$$J_{AIC}(\theta^\wedge, Z^N) = \left(1 + \frac{2 \dim(\theta^\wedge)}{N}\right) \frac{1}{N} \sum_{k=1}^N e^T(k, \theta^\wedge) e(k, \theta^\wedge) \quad (2.18)$$

$$J_{MDL}(\theta^\wedge, Z^N) = \left(1 + \frac{2 \log(N \dim(\theta^\wedge))}{N}\right) \frac{1}{N} \sum_{k=1}^N e^T(k, \theta^\wedge) e(k, \theta^\wedge) \quad (2.19)$$

Onde Z é o conjunto de dados, o qual contém N pontos, enquanto que $\dim(\theta)$ é o tamanho do vetor de parâmetros do modelo identificado. Ambos penalizam a função objetivo de determinação dos parâmetros do modelo, de modo que o modelo identificado represente bem o sistema com o menor número de parâmetros possível, para evitar erros de *overfit* do modelo. Pouca diferença há entre o critério AIC e o critério MDL, sendo a única diferença entre eles é

que o MDL aumenta a penalização sobre o número de parâmetros do modelo (Ljung e Glad, 1994; Ljung, 1999).

A Validação Cruzada é outra forma de avaliação dos modelos identificados. O modelo identificado baseado em um conjunto determinado de dados é utilizado para estimar os valores de um novo conjunto de dados. Caso os erros entre o valor real da variável de saída no segundo conjunto e a predição do modelo identificado com os dados do primeiro conjunto sejam pequenos, o modelo é considerado adequado (Ljung, 1999).

Capítulo 3

Metodologia

3.1 Estudo de Caso

3.1.1 Descrição do Sistema

Exemplos clássicos de sistemas mal condicionados são colunas de destilação de alta pureza, que utilizam a vazão de refluxo e de vapor no refeedor como variáveis manipuladas para o controle da composição dos produtos. Esses tipos de colunas são utilizados em separação de produtos com pontos de ebulição muito próximos e com graus de pureza muito elevados, tanto no produto de topo quanto no produto de fundo. Para exemplificar um sistema mal condicionado, será utilizada uma coluna de destilação de alta pureza que foi modelada por Skogestad e Morari em 1987. Essa coluna tem duas variáveis manipuladas e duas variáveis controladas. A estrutura de controle desta coluna é do tipo LV, ou seja, o controle é feito através da vazão de refluxo de topo (L) e da vazão de vapor no refeedor (V). As variáveis controladas são a composição do componente mais volátil no topo (y_D) e no fundo (x_B), como ilustrado na Figura 3.1.

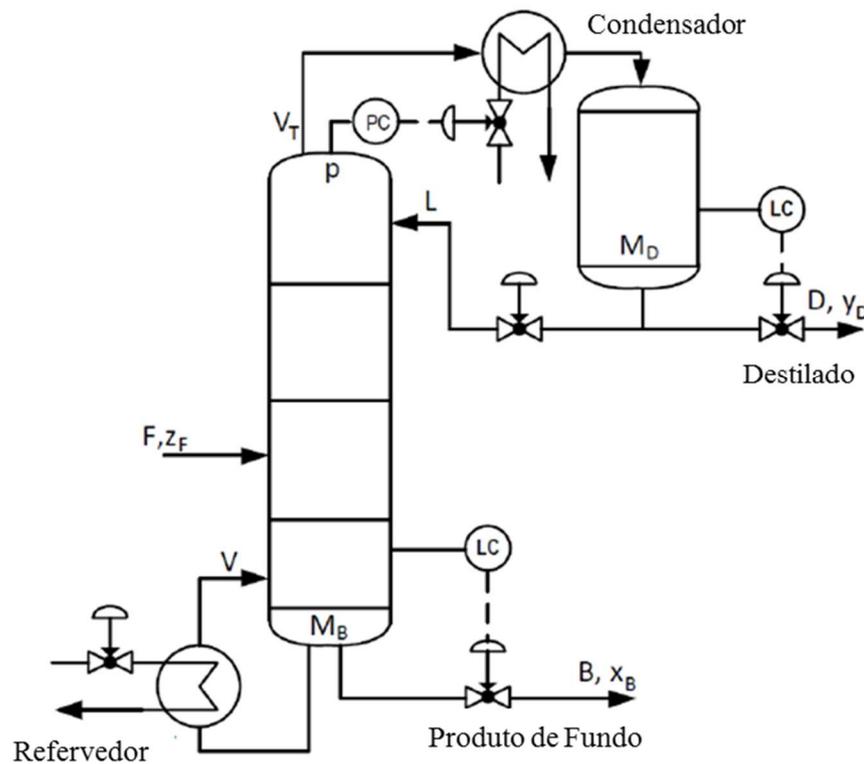


Figura 3.1: Coluna de destilação de alta pureza na configuração de controle LV (Skogestad, 1997).

Este tipo de controle não é o mais recomendado para este tipo de coluna de destilação, uma vez que gera um sistema mal condicionado. Para fugir da condição de mau condicionamento basta adotar uma estratégia de controle do tipo DV, ou seja, a composição do produto de topo controlada pela vazão de retirada de produto de topo (D) e a composição do produto de fundo controlada pela vazão de vapor do reboiler (V). No entanto, este exemplo será utilizado na estrutura LV para possibilitar a análise da identificação de sistemas mal condicionados. A diferença de condicionamento entre as duas formas de controle é um exemplo de processo mal condicionado e processo mal escalonado. A estrutura LV tem número de condicionamento 141,73 e número de condicionamento mínimo de 138,26, portanto, é verdadeiramente mal condicionada. Já a estrutura DV apresenta número de condicionamento 70,76 e número de condicionamento mínimo de 1, caracterizando um processo mal escalonado.

Para a modelagem deste sistema, o autor não considerou os efeitos de hidrodinâmica e fez as seguintes considerações: separação binária, volatilidade relativa constante, fluxo molar

constante e controle de nível perfeito no condensador e no fundo da torre. Os dados da estrutura da coluna de destilação assim como o ponto de operação para a linearização do sistema e a determinação do estado estacionário estão apresentados na Tabela 3.1.

Tabela 3.1: Ponto de operação e dados da coluna para linearização e determinação do estado estacionário.

Dados da Coluna	
Volatilidade Relativa (α)	1,5
Número de Pratos Teóricos	40
Prato de Alimentação (refervedor = 1)	21
Composição a Carga	0,5
Ponto de Operação	
y_D	0,990
x_B	0,010
D/F	0,500
L/F	2,706

Como o objetivo deste trabalho é apresentar uma metodologia de identificação para processos mal condicionados com restrições nas variáveis, foram adicionadas restrições em L/F , V/F , y_D e x_B . As composições podem ter variações de 0,005 (0,5% na composição dos produtos) para mais ou para menos, de forma que não sejam gerados produtos fora de especificação. Para as variáveis manipuladas, L/F e V/F , podem ter variações de 0,05.

A equação 3.1 apresenta o modelo linear do processo $G(s)$, para as variáveis manipuladas L e V , respectivamente, e para as variáveis controladas y_D e x_B .

$$G(s) = \begin{bmatrix} \frac{0,878}{1 + \tau_1 s} & \left(\frac{-0,878}{1 + \tau_1 s} + \frac{0,014}{1 + \tau_2 s} \right) \\ \frac{1,082}{1 + \tau_1 s} & \left(\frac{-1,082}{1 + \tau_1 s} - \frac{0,014}{1 + \tau_2 s} \right) \end{bmatrix} \quad (3.1)$$

Onde τ_1 e τ_2 são constantes de tempo com valores de 194 min e 15 min, respectivamente. τ_1 corresponde à dinâmica para variações do fluxo externo da coluna, enquanto τ_2 corresponde à dinâmica para variações do fluxo interno da coluna, ou seja, variações nas vazões de L e V mantendo as retiradas D e B constantes.

O número de condicionamento da matriz de ganhos estacionário, G_0 , define se o sistema é mal condicionado. Quando maior o número de condicionamento, mais próxima de ser singular estará a matriz de ganhos estacionários e mais mal condicionado é o sistema, como visto anteriormente (Zhu e Stec, 2006). A equação 3.2 mostra o resultado da decomposição em valores singulares do exemplo em questão.

$$U\Sigma V = SVD(G_0) = \begin{bmatrix} -0,625 & -0,781 \\ -0,781 & 0,625 \end{bmatrix} \begin{bmatrix} 197,21 & 0 \\ 0 & 1,39 \end{bmatrix} \begin{bmatrix} -0,707 & -0,708 \\ 0,708 & -0,707 \end{bmatrix} \quad (3.2)$$

O condicionamento do sistema é determinado pela razão entre o maior valor e o menor valor da matriz Σ , que para este sistema é 141,73. Isso quer dizer que uma perturbação feita na direção de maior ganho, terá um ganho estacionário 141,73 vezes maior que uma perturbação feita, com a mesma amplitude, na direção de menor ganho, atestando que este sistema é mal condicionado. Além de determinar o condicionamento do sistema, a decomposição em valores singulares traz também informações das direções de maior e menor ganho, assim como o ganho estacionário que estas perturbações proporcionam. Os vetores da matriz U representam as direções de variações no *setpoint* das variáveis controladas que proporcionam a maior e a menor ação de controle. Já os vetores da matriz V representam as direções de variações nas variáveis manipuladas que geram o maior e o menor ganho nas variáveis controladas. Tanto na matriz U quanto na matriz V , os vetores são ortogonais entre si, o que traz como vantagem a possibilidade de determinar a direção de menor ganho através das direções com ganhos maiores. Em um sistema 2x2, por exemplo, se a direção de maior ganho é conhecida a direção de menor ganho será a direção perpendicular a essa. Esta característica é utilizada na metodologia proposta por Zhu e Stec (2006).

Como mencionado no capítulo anterior, outra forma de determinar se o sistema tem acoplamento forte entre as variáveis é através da matriz de ganhos relativos (RGA), com a vantagem desta ser independente do escalonamento do sistema. O RGA para o estudo de caso

é representado pela equação 3.3, a qual confirma o mau condicionamento do sistema, pois os valores da diagonal da matriz são muito diferentes da unidade.

$$RGA = \begin{bmatrix} 35,07 & -34,07 \\ -34,07 & 35,07 \end{bmatrix} \quad (3.3)$$

Para ilustrar o efeito da direcionalidade e do mau condicionamento do sistema, foram realizadas duas perturbações, que estão apresentadas nas Figuras 3.2 e 3.3. A Figura 3.2 mostra a resposta do sistema a uma perturbação realizada nas direções de maior e menor ganho com a mesma amplitude.

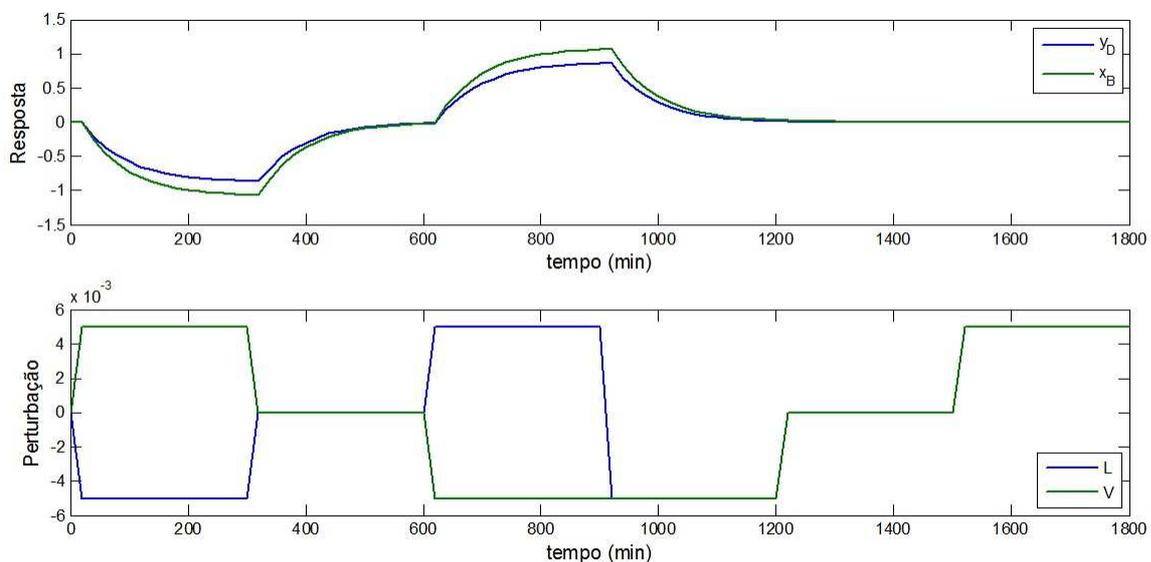


Figura 3.2: Perturbação com a mesma amplitude nas direções de maior e menor ganho.

Como pode ser visto na Figura 3.2, para uma perturbação de mesma amplitude nas direções de maior e menor ganho as respostas do sistema têm magnitudes muito distintas, o que mostra que perturbações simples como Degraus, PRBS e GBN não conseguem excitar a direção de menor ganho com intensidade suficiente para que a resposta não seja camuflada pelo ruído do sistema. A Figura 3.3 mostra a resposta do sistema a uma perturbação feita nas direções de maior e menor ganho, porém com a amplitude da direção de menor ganho 140 vezes maior que a amplitude da direção de maior ganho. Tal figura ilustra que para gerar uma resposta de mesma magnitude, a direção de menor ganho deve ser perturbada com amplitude igual ao

número de condicionamento vezes a amplitude utilizada para perturbar a direção de maior ganho.

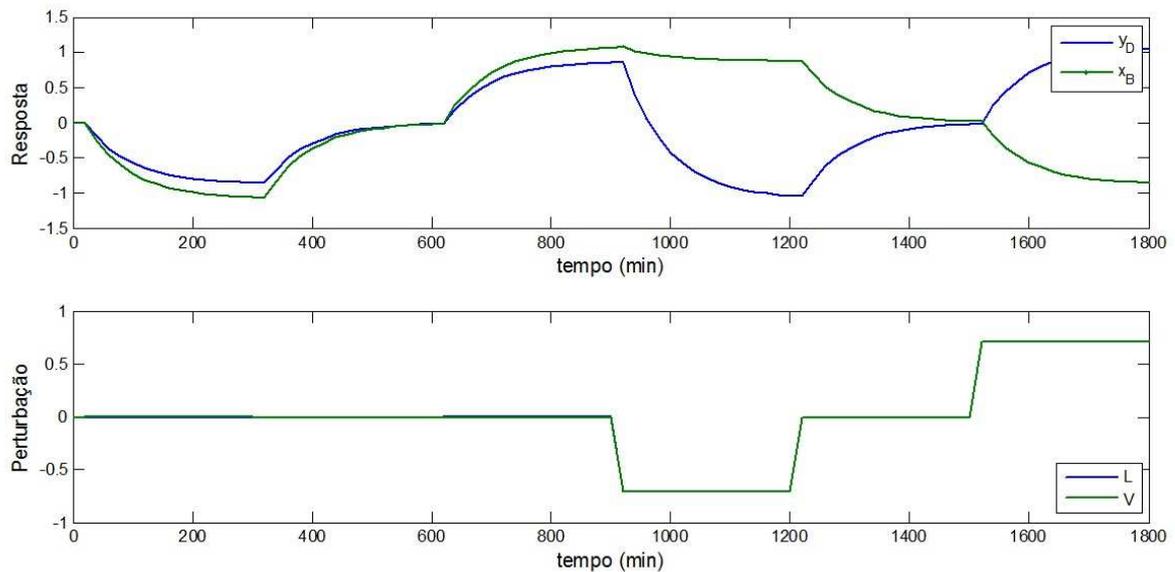


Figura 3.3: Perturbação com amplitudes diferentes nas direções de maior e menor ganho.

3.1.2 Simulação do Sistema em MATLAB®

Para realizar as identificações foi criada uma simulação em MATLAB - Simulink® utilizando o modelo proposto como estudo de caso. Simulink® é uma ferramenta para modelagem, simulação e análise de sistemas dinâmicos que utiliza diagrama de blocos como interface. A Figura 3.4 mostra a simulação representada em diagrama de blocos. Para aproximar o estudo de caso de um processo real, foi introduzido ruído branco de medição nas variáveis de saída do sistema com amplitude de 0,0001 (0,01% de variação na composição dos produtos). Também foram adicionados distúrbios não medidos nas variáveis de saída com amplitude de 0,0005 (0,05% de variação na composição dos produtos). O distúrbio não medido foi introduzido de forma que seja diferente a cada nova simulação. Para que isso aconteça é gerado um sinal do tipo GBN para cada variável de saída, que passam por funções de transferência para adicionar dinâmica ao distúrbio não medido. As funções de transferência para os distúrbios estão representadas na equação 3.4.

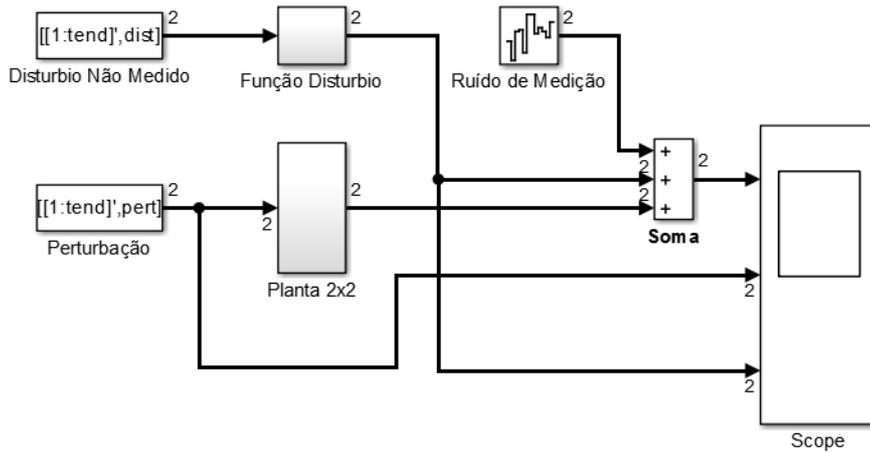


Figura 3.4: Simulação do estudo de caso em MATLAB - Simulink®

$$G_d = \begin{bmatrix} \frac{K_{d1}}{500s^2 + 50s + 1} \\ \frac{K_{d2}}{350s^2 + 25s + 1} \end{bmatrix} \quad (3.4)$$

Onde K_{d1} é o ganho da função distúrbio na variável y_D e K_{d2} é o ganho da função distúrbio na variável x_B . Com os valores de K_{d1} e K_{d2} é possível variar a intensidade do distúrbio não medido. Um exemplo do distúrbio não medido aplicado a uma simulação é apresentado na Figura 3.5.

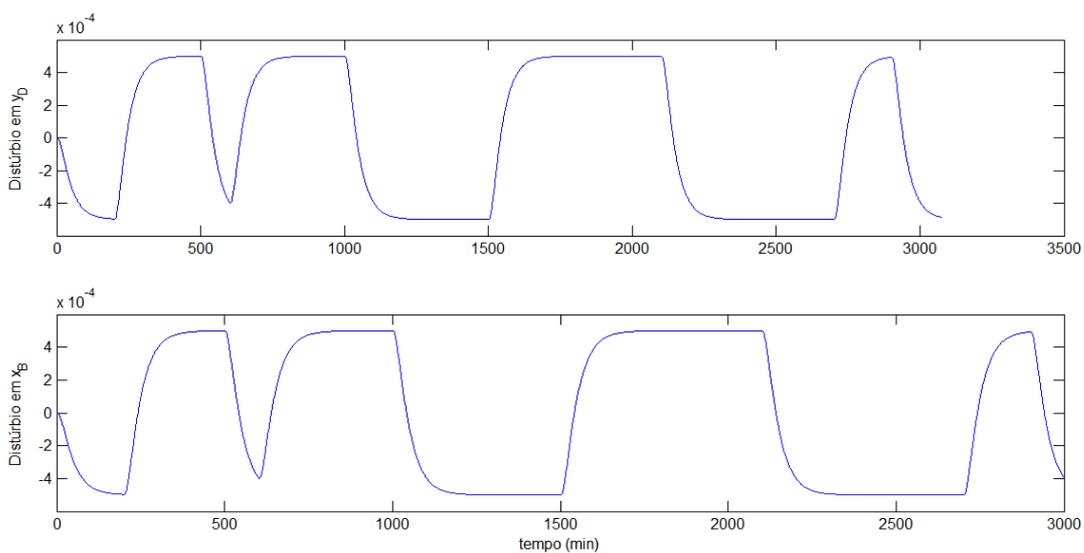


Figura 3.5: Exemplo de distúrbio não medido aplicado nas variáveis de saída do sistema.

3.1.3 Definições para Identificação Utilizando a Simulação

A estrutura escolhida para os modelos identificados é ARX e para determinar as ordens dos polinômios foi utilizado o fator FPE (*Akaike's Final Prediction Error*), que é computado pelo MATLAB® a cada identificação. Este fator é uma derivação do método de validação AIC. Segundo a teoria de Akaike quanto menor o valor de FPE melhor é o modelo (Ljung, 1999). A equação que define o fator FPE é representada por:

$$FPE = \det \left(\frac{1}{N} \sum_{k=1}^N e^T(k, \theta^{\wedge}) e(k, \theta^{\wedge}) \right) \left(\frac{1 + \dim(\theta^{\wedge})/N}{1 - \dim(\theta^{\wedge})/N} \right) \quad (3.5)$$

Onde $\det(X)$ é o determinante da matriz X . Foram realizadas diversas combinações para as ordens dos polinômios $A(q)$ e $B(q)$ e verificado o valor de FPE. Como mostra a Tabela 3.2 a melhor combinação de ordens foi 4 para o polinômio $A(q)$ e 4 para o polinômio $B(q)$. O tempo morto foi definido como 1.

Tabela 3.2: Valores do fator FPE para diferentes ordens dos polinômios $A(q)$ e $B(q)$

		Ordem de $B(q)$				
		2	3	4	5	6
Ordem de $A(q)$	2	0,1313	0,0390	0,0391	0,0393	0,0394
	3	0,0774	0,0382	0,0382	0,0382	0,0384
	4	0,0589	0,0383	0,0381	0,0383	0,0385
	5	0,0539	0,0385	0,0384	0,0385	0,0386
	6	0,0527	0,0387	0,0386	0,0386	0,0388

Após a determinar das ordens do modelo, foi realizada uma identificação sem ruído de medido e distúrbios não medidos. Este modelo ARX de ordens 4:4:1 é utilizado como parâmetro de comparação entre os modelos identificados com as diferentes perturbações estudadas. Para um modelo com esta ordem são necessários estimar 32 parâmetros. Os parâmetros deste modelo são representados por:

Modelo para y_D : $A_{11}(z) y_D(t) = -A_{12}(z) x_B(t) + B_{11}(z)L/F(t) + B_{12}(z)V/F(t) + e_1(t)$

Modelo para x_B : $A_{22}(z) x_B(t) = -A_{21}(z) y_D(t) + B_{21}(z)L/F(t) + B_{22}(z)V/F(t) + e_2(t)$

$$\begin{aligned}
 A_{11}(z) &= 1 - 0.9981 z^{-1} + 0.07047 z^{-2} - 0.02606 z^{-3} - 0.005565 z^{-4} \\
 A_{12}(z) &= 0.005728 z^{-1} - 0.06187 z^{-2} + 0.02408 z^{-3} + 0.003716 z^{-4} \\
 A_{22}(z) &= 1 - 0.9953 z^{-1} + 0.04233 z^{-2} - 0.01297 z^{-3} - 0.00363 z^{-4} \\
 A_{21}(z) &= -0.001588 z^{-1} - 0.0447 z^{-2} + 0.01136 z^{-3} + 0.004543 z^{-4} \\
 B_{11}(z) &= 2.174e-05 z^{-1} + 0.009034 z^{-2} - 0.004481 z^{-3} + 7.158e-05 z^{-4} \\
 B_{12}(z) &= -1.717e-05 z^{-1} - 0.007236 z^{-2} + 0.003462 z^{-3} + 0.0001013 z^{-4} \\
 B_{21}(z) &= 4.492e-05 z^{-1} + 0.01112 z^{-2} - 0.005587 z^{-3} + 0.0001654 z^{-4} \\
 B_{22}(z) &= -4.12e-05 z^{-1} - 0.01291 z^{-2} + 0.006587 z^{-3} - 0.0002195 z^{-4}
 \end{aligned} \tag{3.6}$$

Onde e_1 e e_2 são os erros do modelo nas variáveis y_D e x_B respectivamente. Para a comparação entre as perturbações foram realizadas 50 identificações para cada uma delas. Os distúrbios não medidos e os ruídos introduzidos no sistema são diferentes a cada nova identificação. Com isso a comparação é feita através de parâmetros médios para cada tipo de perturbação.

O tempo de amostragem foi determinado da mesma forma que as ordens da estrutura ARX. Foram testados tempos de amostragem de 1 a 20 minutos e o valor mais indicado foi 8 minutos, como mostra a Figura 3.6.

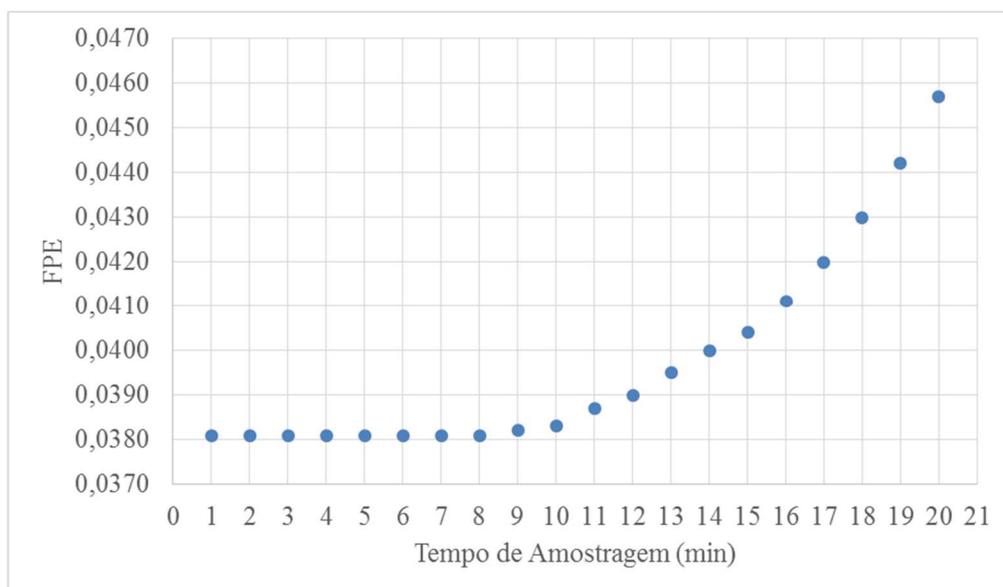


Figura 3.6: Escolha do tempo de amostragem através do fator FPE.

3.2 Determinação dos Parâmetros para as Perturbações

3.2.1 Perturbação Degrau

Como visto no capítulo anterior, a metodologia de geração de sinais tipo degrau é simples e por isso é uma das mais utilizadas na identificação de modelos. Nesta metodologia são necessários dois parâmetros para cada uma das variáveis manipuladas: a amplitude e o tempo de permanência da perturbação.

A amplitude da perturbação deve ser a maior possível para que a relação sinal/ruído seja suficiente para minimizar os efeitos do ruído de processo nos sinais das variáveis controladas. Porém, uma amplitude muito elevada pode fazer com que o processo se afaste muito do ponto de operação ideal, aumentando os custos da identificação do modelo. As existências de não-linearidades no sistema também impõem limites para a amplitude de perturbação, pois os modelos identificados são normalmente lineares e as informações para a sua identificação devem ser extraídas de uma região linear do sistema. A determinação da amplitude normalmente é feita empiricamente, baseada na experiência de operação e com dados históricos de processo. Neste trabalho, como o modelo é conhecido, a amplitude foi determinada através de uma otimização linear, onde os limites impostos para as variáveis do modelo foram utilizados como restrições do problema de otimização. O problema de otimização é expresso pela equação 3.7.

$$\begin{aligned}
 \max z &= Amp \\
 y &= y_0 \pm G_0 V Amp \\
 u &= u_0 \pm V Amp \\
 y^- &\leq y \leq y^+ \\
 u^- &\leq u \leq u^+
 \end{aligned} \tag{3.7}$$

Onde Amp é o vetor com as amplitudes aplicadas a cada direção do sistema, V é a matriz que contém em suas colunas os vetores das direções de entrada do sistema, y é o vetor das variáveis de saída e y_0 é o vetor dos seus valores iniciais, u é o vetor das variáveis de entrada e u_0 é o vetor dos seus valores iniciais. As restrições das variáveis de saída e de entrada são dadas pelos vetores y^- , y^+ , u^- e u^+ , respectivamente.

O tempo de permanência da perturbação é determinado para que o sistema alcance, ou chegue muito próximo, do estado estacionário para a nova condição da variável manipulada. Alguns autores, como Ljung (1999) e Zhu (2006), dizem que o tempo de perturbação deve estar entre 4 e 2π vezes a constante de tempo dominante do sistema, que para o caso estudado é 198 minutos. Porém, o modelo do processo normalmente não está disponível em uma identificação real de processo, então este valor também pode ser determinado por dados históricos e pela experiência de operação.

Considerando que serão realizados dois degraus em cada variável manipulada, um positivo e outro negativo, com a mesma amplitude e que as variáveis manipuladas serão perturbadas não simultaneamente, o tempo do experimento de identificação para o estudo de caso será aproximadamente 3100 minutos, para um tempo de permanência de 4 vezes a constante de tempo dominante. A implementação em MATLAB[®] para construção destas perturbações está apresentada no Apêndice 3 deste trabalho.

3.2.2 Perturbação PRBS

Sinais de perturbação do tipo PRBS também são comuns em identificação de modelos. Para esta metodologia é necessário determinar a amplitude da perturbação, a banda de frequências e o tempo de duração do experimento de identificação.

Para determinar a amplitude da perturbação foi utilizada a mesma metodologia da perturbação Degrau. Como as perturbações Degrau e PRBS não têm sinais correlacionados e a otimização da amplitude não leva em conta a dinâmica do processo, o valor obtido para as amplitudes máximas de perturbação serão iguais. Para que a comparação entre as perturbações fosse justa o tempo de duração do experimento foi mantido o mesmo que o utilizado para a perturbação Degrau. Assim sendo o tempo de duração para o PRBS é de aproximadamente 3100 min.

A determinação da banda de frequências foi feita através da equação 2.7, utilizando valores de 198 minutos para o τ_{max} e 15 minutos para o τ_{min} , e considerando $\alpha = 5$ e $\beta = 1$. Com isso define-se $BW=[0,0050 \text{ rad/min}; 0,3333 \text{ rad/min}]$. Com a frequência máxima e o tempo de duração do experimento, é possível determinar M , e através da Tabela 2.1, determinar a ordem da perturbação PRBS e os valores das constantes do polinômio $P(q)$.

Para a criação das perturbações PRBS foi utilizada a função “`idinput`” do MATLAB[®], que utiliza as variáveis descritas seguindo a seguinte estrutura:

$$u = idinput([td, n], "prbs", BW, Amp) \quad (3.8)$$

Onde td é o tempo de duração da perturbação, n é o número de variáveis de entrada. Primeiramente o método determina a menor tempo de permanência possível como sendo o inverso da maior frequência. Em seguida é determinado o número de possíveis trocas de sinal, M , fazendo a divisão do tempo de duração pelo menor tempo de permanência. Com o valor de M é determinado os valores dos coeficientes de $P(q)$.

3.2.3 Perturbação GBN

A perturbação GBN é gerada de forma mais simples que a perturbação PRBS, pois a mudança do sentido da perturbação é probabilística e não é necessário definir a ordem para o polinômio como o PRBS. Os parâmetros necessários para a construção desta perturbação são os mesmos utilizados para o PRBS, porém na perturbação GBN existe o parâmetro p , que é a probabilidade da perturbação se manter no patamar em que está. Para determinar o valor ideal de p para o caso de estudo, foram realizadas identificações utilizando perturbações do tipo GBN variando o valor de p . Os modelos identificados foram comparados utilizando os mesmos critérios que serão descritos neste capítulo.

O tempo de duração da perturbação foi considerado igual ao tempo utilizado para a perturbação PRBS, para tornar justa a comparação entre as perturbações. A banda de frequências contidas na perturbação é definida da mesma forma para a perturbação PRBS, e por tanto também são iguais. Assim como a amplitude que também é definida da mesma forma para as perturbações Degrau, PRBS e GBN. A implementação em MATLAB[®] para construção destas perturbações está apresentada no Apêndice 4 deste trabalho.

3.2.4 Perturbações Propostas por Zhu (2001 e 2006)

Como visto anteriormente, nas perturbações propostas por Zhu e Stec (2001, 2006) são realizadas duas identificações consecutivas utilizando sinais do tipo GBN. O primeiro passo

consiste em uma perturbação GBN convencional, em que os parâmetros são definidos da mesma forma. Apenas o tempo de duração da perturbação que foi reduzido para 4 vezes a maior constante de tempo, pois esse primeiro passo visa apenas obter uma aproximação das direções de maior e menor ganho para serem utilizadas no planejamento do segundo passo do método.

O segundo passo consiste na aplicação de dois sinais. Um sinal com os mesmos parâmetros utilizados no sinal do primeiro passo para obter mais dados da direção de maior ganho. O outro sinal é produzido através de um sinal GBN, com amplitude maior, aplicado na direção de menor ganho identificada na aproximação inicial do primeiro passo. Os demais parâmetros do segundo sinal são definidos da mesma forma que os anteriores. A amplitude utilizada para o segundo sinal é dez vezes a amplitude determinada para o primeiro sinal.

Foram propostos pelo autor dois métodos para aplicação do segundo passo, o método de sinais concatenados e o método de sinais somados. A construção da perturbação do segundo passo para estes métodos foi descrita no capítulo anterior como método de dois passos com sinais concatenados e método de dois passos com sinais somados. A implementação em MATLAB® para construção destas perturbações está apresentada no Apêndice 5 deste trabalho.

3.3 Método Proposto para Projeto de Perturbação

O método proposto é baseado nas perturbações de dois passos propostas por Zhu e Stec (2001 e 2006) para gerar as perturbações. Porém, diferente do método original, este método é iterativo e atualiza a estimativa da direção de menor ganho e otimiza a amplitude utilizada para perturbar essa direção a cada iteração, sem que os limites das variáveis de controle sejam ultrapassados. Após cada iteração do segundo passo um novo modelo é obtido e uma nova direção de menor ganho é estimada, e com estas informações a nova amplitude da perturbação é otimizada para que gere o máximo de informações sem que o sistema ultrapasse os limites estipulados para suas variáveis de entrada e saída.

O primeiro passo continua utilizando uma perturbação do tipo GBN para obter um modelo prévio com informações da direção de maior ganho e, conseqüentemente, informações da

direção de menor ganho, já que os vetores são ortogonais. Porém esta primeira aproximação do modelo pode ser obtida de outras formas sem a necessidade de realizar um procedimento de identificação. Em casos onde a identificação estiver sendo realizada para atualizar o modelo de um MPC já implementado, o modelo desatualizado pode ser utilizado como uma primeira aproximação. No trabalho de (Cunha, 2004), é proposta uma metodologia de identificação de modelos prévios utilizando dados históricos, onde estes dados são selecionados seguindo critérios de variabilidade.

Após a obtenção do modelo prévio, é iniciada a etapa iterativa do método, onde é feita uma otimização linear para determinar a maior amplitude que pode ser aplicada na direção de menor ganho sem que o processo ultrapasse os limites de controle das variáveis de saída e entrada. No entanto, o valor obtido da otimização não pode ser utilizado integralmente na próxima perturbação da direção de menor ganho, pois os modelos identificados geralmente apresentam erros na matriz de ganho estacionário e também apresentam uma defasagem nas direções em relação ao processo real. Como mostra a Figura 3.7, se uma perturbação for aplicada na direção de menor ganho do modelo identificado parte desta perturbação será projetada na direção de maior ganho do processo real e se a amplitude desta perturbação for muito grande essa projeção fará com que a resposta das variáveis de saída ultrapasse os limites definidos.

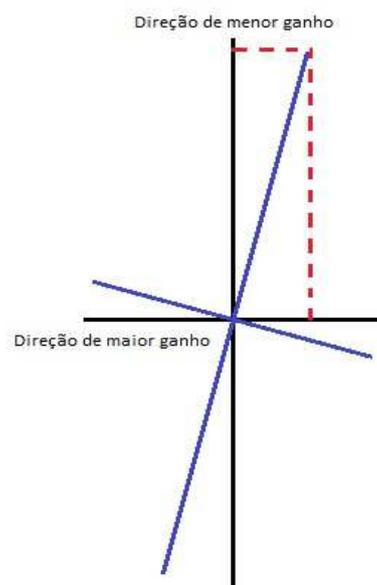


Figura 3.7: Defasagem entre as direções do processo (linha preta) e do modelo identificado (linha azul).

Então para construir as perturbações do segundo passo foi proposto um fator de confiabilidade, w . Este fator representa a fração da amplitude obtida pela otimização que será aplicada na próxima perturbação. O primeiro valor de w deve ser escolhido baseado na qualidade do modelo prévio. Após a primeira iteração o fator w é atualizado a cada iteração, para garantir que as variáveis de entrada e saída da próxima iteração cheguem o mais próximo possível das suas restrições. Assim, com a evolução do valor de w é possível verificar a melhoria da qualidade do modelo. Para o estudo de caso proposto, w foi considerado inicialmente igual a 0,3, ou seja, 30% da amplitude será utilizada na primeira iteração do segundo passo.

Assim como a metodologia de dois passos o método proposto utiliza o mesmo intervalo de frequências BW e o parâmetro p do método GBN. O tempo de duração do segundo passo foi considerado a metade do valor utilizado para o segundo passo dos métodos de Zhu (2001 e 2006), pois, como o processo é iterativo se o tempo de duração da perturbação for muito elevado o tempo total o processo de identificação pode ser muito extenso.

Com as informações obtidas do modelo prévio, a definição do fator w inicial e a determinação dos parâmetros de intervalo de frequência e tempo de duração uma nova perturbação é construída para a identificação de um novo modelo. Essa identificação é feita utilizando o método dos sinais concatenados ou o método dos sinais somados. Neste trabalho os dois métodos foram utilizados para comparação.

Após a primeira iteração, um novo modelo é obtido e novas informações das direções de maior e menor ganho são computadas. Com os valores obtidos das variáveis controladas um novo fator w é calculado através da equação 3.9. Esta atualização determina o valor que o fator w pode assumir para que as novas perturbações façam com que as variáveis atinjam as suas restrições, gerando a maior perturbação possível na direção de menor ganho estimada pelo modelo identificado.

$$w_{n+1} = w_n \min \left(\frac{\Delta \lim y_k}{\Delta \max |y_k|}, \frac{\Delta \lim y_{k-1}}{\Delta \max |y_{k-1}|} \dots \frac{\Delta \lim y_1}{\Delta \max |y_1|} \right) \quad (3.9)$$

Onde y_k são as k variáveis controladas do sistema, para o estudo de caso deste trabalho k é igual a dois; $\Delta \lim y_k$ são os limites de variação das variáveis controladas e $\Delta \max |y_k|$ são as

máximas variações obtidas pelas variáveis y_k durante a identificação. A Figura 3.8 ilustra como as variáveis da equação 3.9 são obtidas.

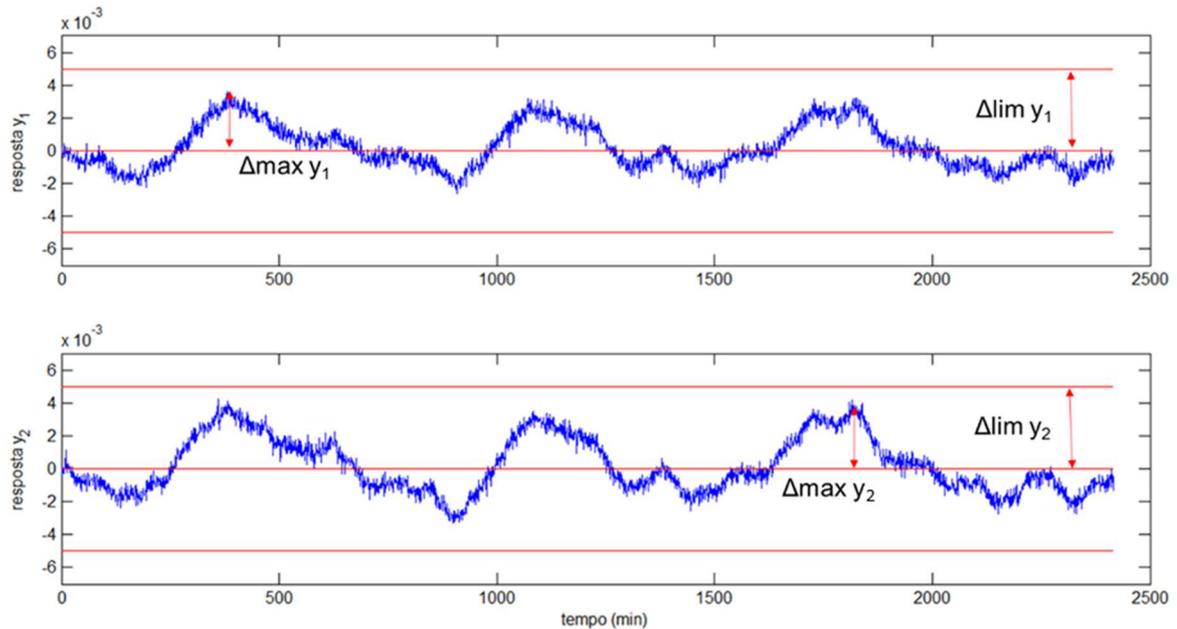


Figura 3.8: Determinação das variáveis da equação 3.9 para atualização do fator w .

O valor de w atualizado será utilizado para o projeto das perturbações da iteração seguinte e é atualizado a cada nova iteração. Conforme as iterações acontecem e a qualidade do modelo melhora, o fator de confiabilidade w tende a aumentar de valor. Desta forma, a evolução do fator w durante o processo de identificação é um indicativo de que o modelo está mais representativo a cada iteração. A interrupção do processo iterativo de identificação pode ser determinada pelo valor de w e/ou pelo tempo máximo de perturbação determinado. Neste trabalho cinco iterações foi o limite imposto para a duração total do método ou quando o valor de w for maior que 0,8. A implementação em MATLAB[®] para construção destas perturbações está apresentada no Apêndice 5 deste trabalho.

A Tabela 3.3 resume os parâmetros definidos para as perturbações estudadas e para a perturbação proposta.

Tabela 3.3: Parâmetros determinados para cada metodologia de perturbação

		Tempo de Duração (minutos)	Tempo de Permanência		Amplitudes da Perturbação		BW (rad/min)
			Máximo	Mínimo	Não Corr.	Menor Ganho	
	Degrau	3076	768		0,0036		-
	PRBS	3076	192	19	0,0036		[0,0052; 0,3333]
	GBN	3076	192	19	0,0036		[0,0052; 0,3333]
Método de 2 Passos	Concatenados	768 para 1º Passo 2307 para 2º Passo	192	19	0,0036	0,036	[0,0052; 0,3333]
	Somados	Total 3076 minutos			0,0025	0,025	
Método Proposto ***	Concatenados	768 para 1º Passo 768 por Iteração	192	19	0,0036	0,05 *	[0,0052; 0,3333]
	Somados	Máximo 4608 minutos			0,0025	0,047 **	

* A amplitude para a direção de menor ganho tende ao limite estipulado para as variáveis manipuladas do sistema.

** A amplitude para a direção de menor ganho mais a amplitude para as perturbações não correlacionadas tende ao limite estipulado para as variáveis manipuladas do sistema.

*** Para o método proposto w inicial é 0,3 e os critérios de parada são 5 iterações ou quando valor de w for maior que 0,8.

3.4 Critérios de Qualidade para Comparação dos Métodos

3.4.1 Validação Cruzada

A validação cruzada é a verificação da qualidade de predição do modelo. Para quantificá-la, um conjunto de dados que não foi utilizado na identificação é separado para posterior verificação do modelo. Essa verificação é feita aplicando as mesmas perturbações aplicadas nos dados de validação ao modelo identificado e calculando o erro de predição para determinar o grau de ajuste do modelo ao processo. O grau de ajuste (FIT) do modelo expresso em porcentagem é dado por:

$$FIT = 100 * \left(1 - \frac{\sqrt{(y - y_p)^2}}{\sqrt{(y - y_M)^2}} \right) \quad (3.10)$$

Onde y são os valores das variáveis controladas do conjunto de dados de validação, y_M é a média dos valores de cada y e y_p é o valor predito para cada y .

Como este trabalho visa a identificação de modelos de sistemas mal condicionados, os dados de validação foram escolhidos de forma a verificar a eficácia da identificação da direção de menor ganho. Para isso, a validação foi separada em duas partes. A primeira metade dos dados de validação são perturbações do tipo GBN aplicadas na direção de menor ganho com amplitude máxima das variáveis manipuladas. A segunda metade são perturbações do tipo GBN não correlacionadas com amplitude igual à utilizada nas perturbações GBN da fase de identificação. Os dados gerados para a validação são mostrados na Figura 3.9.

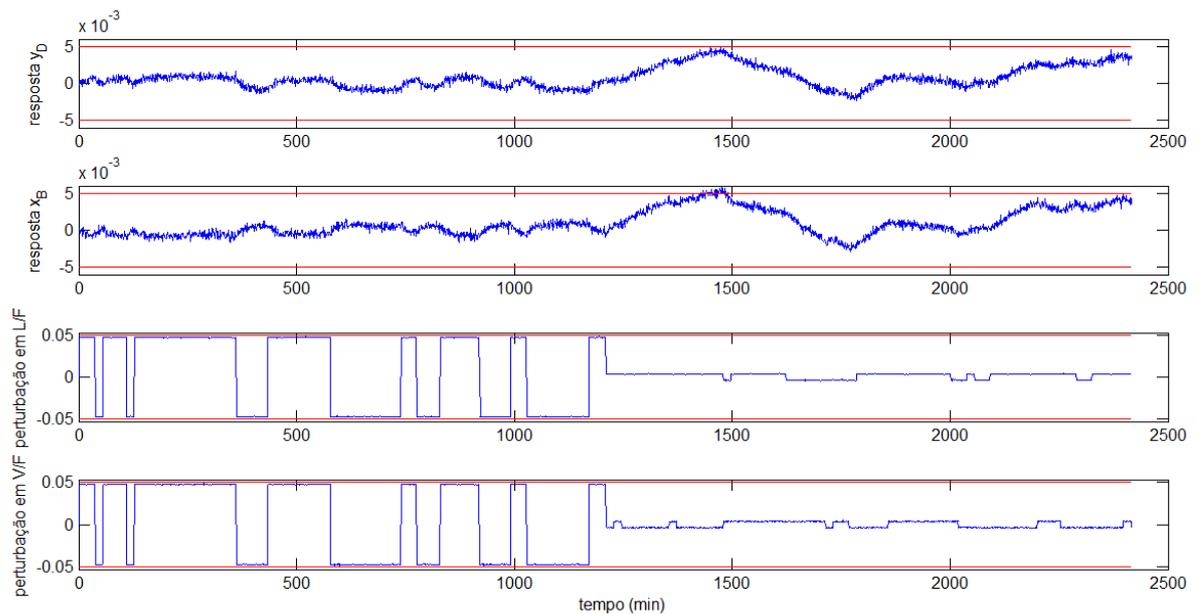


Figura 3.9: Dados selecionados para validação cruzada dos modelos identificados.

O grau de ajuste dos modelos será calculado separadamente para as duas partes dos dados de validação, e serão apresentados como a média dos valores obtidos para as cinquenta identificações de cada método com a seguinte nomenclatura: *FIT1* para o grau de ajuste aos dados da primeira parte da validação cruzada, e *FIT2* para o grau de ajuste aos dados da segunda parte da validação cruzada

3.4.2 Erro da Estimativa dos Parâmetros

Para determinação da qualidade dos parâmetros dos modelos identificados, foi proposto o cálculo do erro da estimativa dos parâmetros das matrizes *A* e *B*. Este erro é calculado

utilizando o modelo obtido para o sistema em uma identificação sem ruídos de medida e sem distúrbios não medido. A nomenclatura utilizada foi *erroA* e *erroB* e sua forma de cálculo está apresentada na equação 3.11.

$$\begin{aligned} erroA &= \sum_1^{n\theta a} \sqrt{(\theta_A - \hat{\theta}_A)^2} \\ erroB &= \sum_1^{n\theta b} \sqrt{(\theta_B - \hat{\theta}_B)^2} \end{aligned} \quad (3.11)$$

Onde $n\theta a$ e $n\theta b$ são o número de parâmetros existentes nas matrizes A e B do modelo; θ_A e θ_B são os parâmetros do modelo padrão; $\hat{\theta}_A$ e $\hat{\theta}_B$ são os parâmetros estimados pela identificação.

3.4.3 Inversão do Sinal do Ganho Multivariável

O sinal do ganho multivariável é muito importante para a robustez do modelo. A inversão de seu sinal pode causar instabilidade no controlador. Portanto, modelos com erro no sinal do ganho multivariável são considerados inadequados para a utilização em MPC. O sinal do ganho multivariável é definido por:

$$K = \det(G_0) \quad (3.12)$$

Onde K é a ganho multivariável. Para comparar os métodos foram determinados quantos dos cinquenta modelos identificados para cada método tiveram o sinal do ganho multivariável invertido. Esse valor é apresentado em percentual e será chamado de *erroK*.

3.4.4 Erros dos Valores Singulares - Estacionário e Dinâmico

Os valores singulares representam os ganhos que perturbações realizadas nas direções de maior e menor ganho proporcionam ao sistema. Portanto, são parâmetros que podem ser utilizados para determinar a eficiência dos métodos em identificar estas direções. Os valores singulares podem ser avaliados de duas formas, no estado estacionário e no transiente.

Para avaliar os valores singulares em uma condição dinâmica é preciso utilizar a equação 2.1 avaliada em uma faixa de frequências, ω . A verificação dos valores singulares nesta condição foi realizada apenas por método gráfico, verificando a aderência dos valores singulares identificados aos valores singulares do modelo do estudo de caso. Os valores singulares do estudo de caso avaliados para uma faixa de frequências são ilustrados na Figura 3.10.

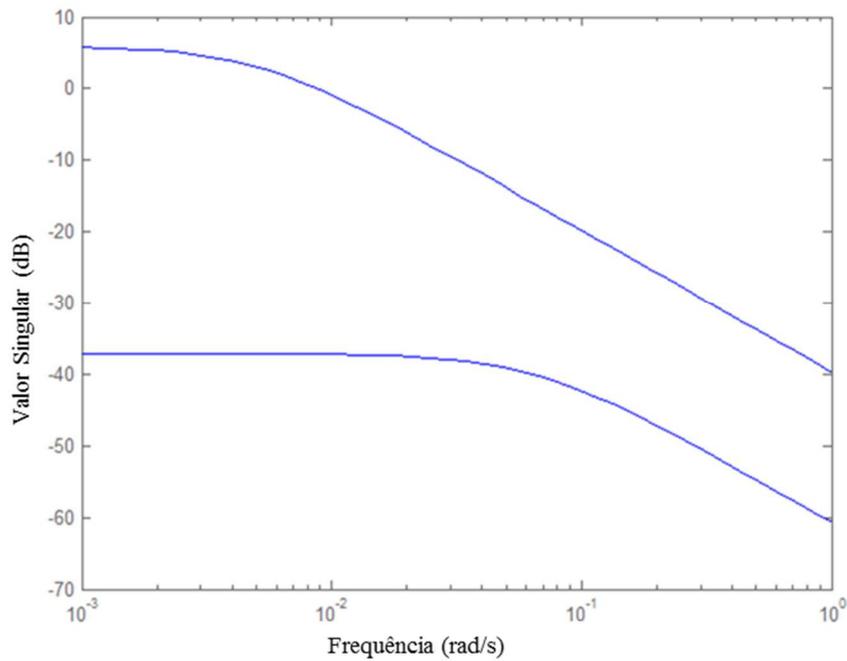


Figura 3.10: Valores singulares do estudo de caso avaliados para uma faixa de frequências.

A avaliação estacionária utiliza simplesmente a equação 2.1 avaliada para G_0 , gerando as matrizes U , Σ e V . A matriz Σ é uma matriz diagonal composta pelos valores singulares das direções existentes no sistema. Como o estudo de caso é um sistema 2x2 existem apenas duas direções e, portanto, apenas dois valores singulares, o máximo (σ_M) e o mínimo (σ_m). O erro de cada valor singular é calculado através de.

$$erro \sigma = 100 * \left(\frac{|\sigma_{Mi} - \sigma_M|}{\sigma_M}, \frac{|\sigma_{mi} - \sigma_m|}{\sigma_m} \right) \quad (3.13)$$

Onde σ_{Mi} e σ_{mi} são o maior e o menor valor singular, respectivamente, do modelo identificado. O *erro σ* será apresentado como a média dos valores obtidos nos cinquenta modelos para cada um dos valores singulares seguindo a nomenclatura *erro σ_M* e *erro σ_m* .

3.4.5 Erro no RGA

O RGA, além de estabelecer uma estimativa do condicionamento mínimo do sistema, também determina o melhor emparelhamento entre as variáveis manipuladas e controladas para implementação de controle descentralizados. O melhor emparelhamento de um sistema é o emparelhamento onde os valores da diagonal são próximos de 1. Para um sistema 2x2, como o caso em questão, a equação 2.5 mostra que só existem dois valores na matriz RGA que são positivos.

Erro no emparelhamento do modelo identificado em relação ao modelo real leva à instabilidade em malha fechada, portanto são modelos impróprios para a utilização na implementação de MPC. Como mostra a equação 3.3, o emparelhamento adequado para o modelo real é L com y_D e V com x_B . Para determinar o erro de emparelhamento dos modelos identificados foi verificado o sinal do valor encontrado para o emparelhamento L com y_D , ou seja, o sinal do elemento 1,1 da matriz de RGA. Quando existe inversão do sinal em relação ao modelo real este modelo é considerado inadequado. Os modelos inadequados são contados e este valor é apresentado em porcentagem com a nomenclatura *erroPAR*.

3.4.6 Estabilidade em Malha Fechada

Para um sistema estável em malha aberta, existe um controlador linear com ação integral que estabiliza o sistema em malha fechada se, e somente se, a equação 3.14 for satisfeita (Garcia e Morari, 1985).

$$\operatorname{Re}(\delta_j(G_0 G i_0^{-1})) > 0 \quad (3.14)$$

Onde $\delta_j(X)$ são os j autovalores da matriz X , $\operatorname{Re}(X)$ é a parte real do número imaginário X , G_0 é a matriz de ganhos estacionários do modelo real e $G i_0$ é a matriz de ganhos estacionários do

modelo identificado. Para que o sistema seja estável em malha fechada a parte real dos autovalores da matriz $G_0G_0^{-1}$ devem ser positivos. Esta condição é comumente chamada de “controlabilidade integral” e fornece uma condição de estado estacionário para estabilidade robusta (Koung e Macgregor, 1994).

Para comparação dos métodos foram determinados quantos dos cinquenta modelos identificados para cada método são instáveis em malha fechada. Este valor é apresentado em percentual e com a nomenclatura *IMF* (Instabilidade em Malha Fechada).

Capítulo 4

Resultados

4.1 Comparação Entre os Métodos de Identificação Não Correlacionados

Primeiramente foi realizada a comparação das perturbações clássicas com sinais não correlacionados: Degrau, PRBS e GBN. Para estas perturbações, foi utilizada a mesma amplitude dos sinais de entrada visando um comparativo justo. Para a perturbação degrau, o tempo de permanência em cada nível foi definido como 2π vezes o valor da constante de tempo dominante do sistema, que neste caso é 198 min. Para os sinais PRBS e GBN a largura de banda (*band width, BW*) foi determinada pela equação 2.7 considerando $\alpha = 5$, $\beta = 1$, $\tau_{\max} = \tau_1 = 198$ min e $\tau_{\min} = \tau_2 = 15$ min e obtendo $BW = \{0,0050 \text{ rad/min}; 0,3333 \text{ rad/min}\}$. Para a perturbação GBN a probabilidade de não trocar de patamar, p , foi determinada através de uma série de experimentos de identificação utilizando diferentes valores para o fator.

Para avaliar a variabilidade dos métodos foram realizadas cinquenta identificações para cada um dos métodos.

4.1.1 Perturbação Degrau

A Figura 4.1 ilustra um dos procedimentos de identificação realizados com a perturbação Degrau aplicado ao estudo de caso.

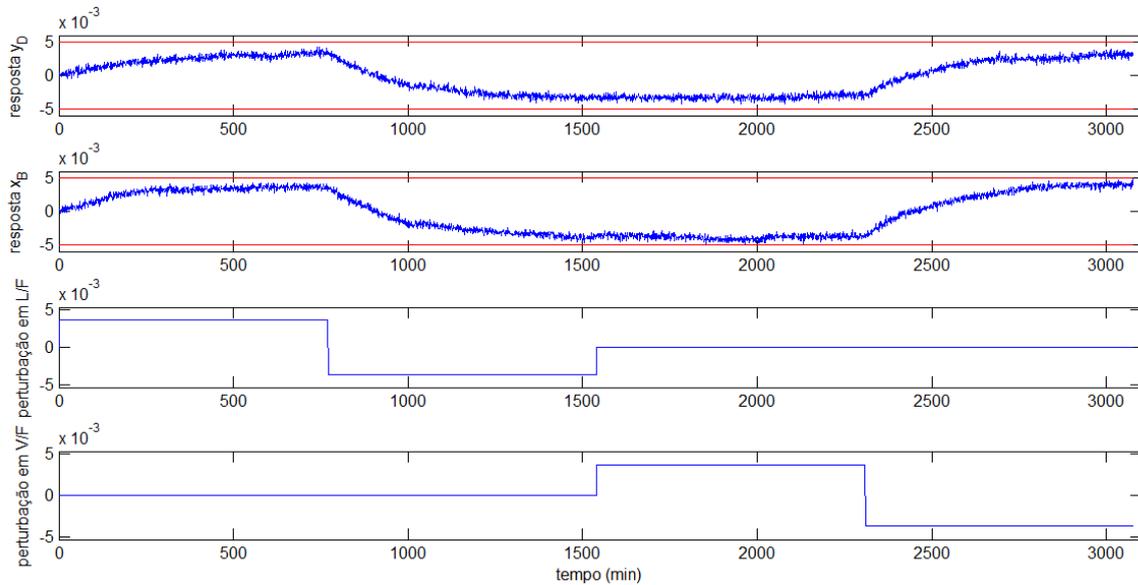


Figura 4.1: Perturbação Degrau aplicada ao estudo de caso em um procedimento de identificação.

Como pode ser visto na Figura 4.1, as variáveis controladas não foram perturbadas além dos limites especificados para este sistema, que foram variações de 0,005 em torno de zero. A amplitude da perturbação também garantiu que as variáveis manipuladas não ultrapassem os limites de variação de 0,05 em torno de zero.

Nos capítulos anteriores, foi mencionada a baixa eficiência do método de perturbação Degrau para a identificação de sistemas mal condicionados. Na Figura 4.2 isso pode ser comprovado através da análise dos valores singulares dos modelos identificados comparados com os valores singulares do modelo real que representa o processo.

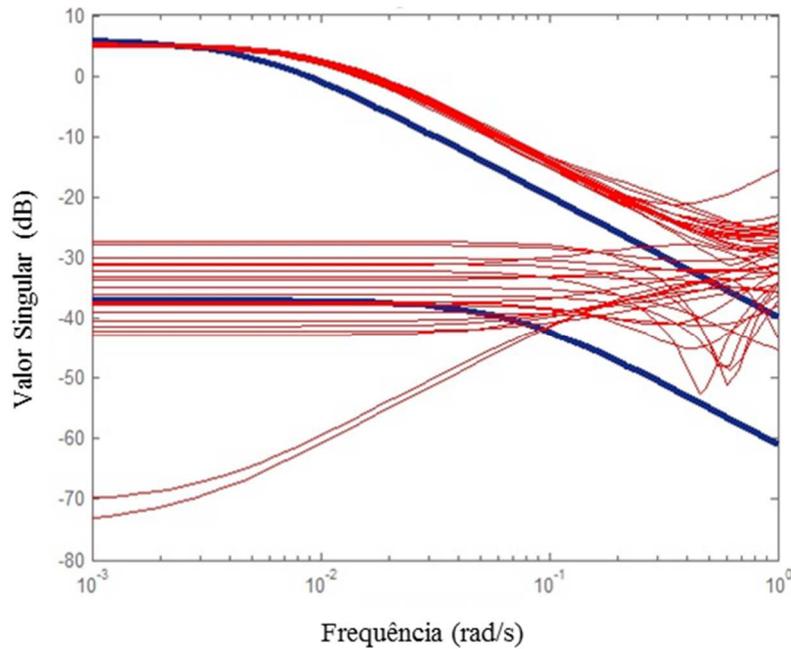


Figura 4.2: Comparação dos valores singulares dos cinquenta modelos identificados com a perturbação Degrau (linhas vermelhas) com os valores singulares do processo real (linha azul).

Como pode ser visto na Figura 4.2 o maior valor singular é bem identificado somente para a região de baixa frequência, pois este método perturba muito pouco o sistema em frequências maiores. Para um modelo que será utilizado para implementação em MPC, que pode realizar ajustes no sistema em frequências mais altas, esta característica não é desejada.

No estudo de caso, a direção de menor ganho é um aumento ou redução simultânea das duas variáveis manipuladas, L e V . Caso haja um aumento das variáveis manipuladas, os produtos de topo e fundo têm um acréscimo em sua pureza, aumentando o valor de y_D e reduzindo o valor de x_B . Em caso de redução simultânea das variáveis manipuladas a pureza dos produtos será diminuída fazendo o valor de y_D diminuir e o valor de x_B aumentar. A Figura 4.3 corrobora que os valores das variáveis controladas obtidos para a identificação nunca são perturbadas na direção de menor ganho, visto que os dados estão direcionados em apenas uma direção, com pouca variação na sua direção perpendicular, que é a direção de menor ganho.

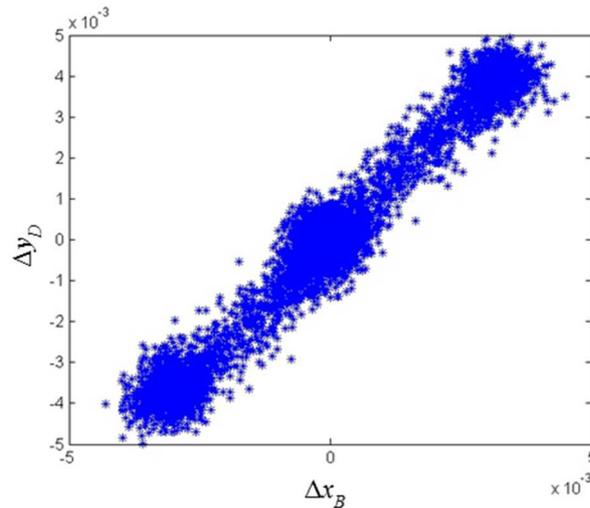


Figura 4.3: Dispersão típica dos dados para uma identificação utilizando perturbação Degrau.

4.1.2 Perturbação PRBS

A Figura 4.4 ilustra um dos procedimentos de identificação realizados com a perturbação PRBS aplicado ao estudo de caso. Como a amplitude de perturbação foi considerada a mesma utilizada nas perturbações Degrau, as variáveis controladas não se aproximam dos seus limites, pois o tempo de permanência das perturbações são muito menores que o tempo necessário para que o estado estacionário seja alcançado.

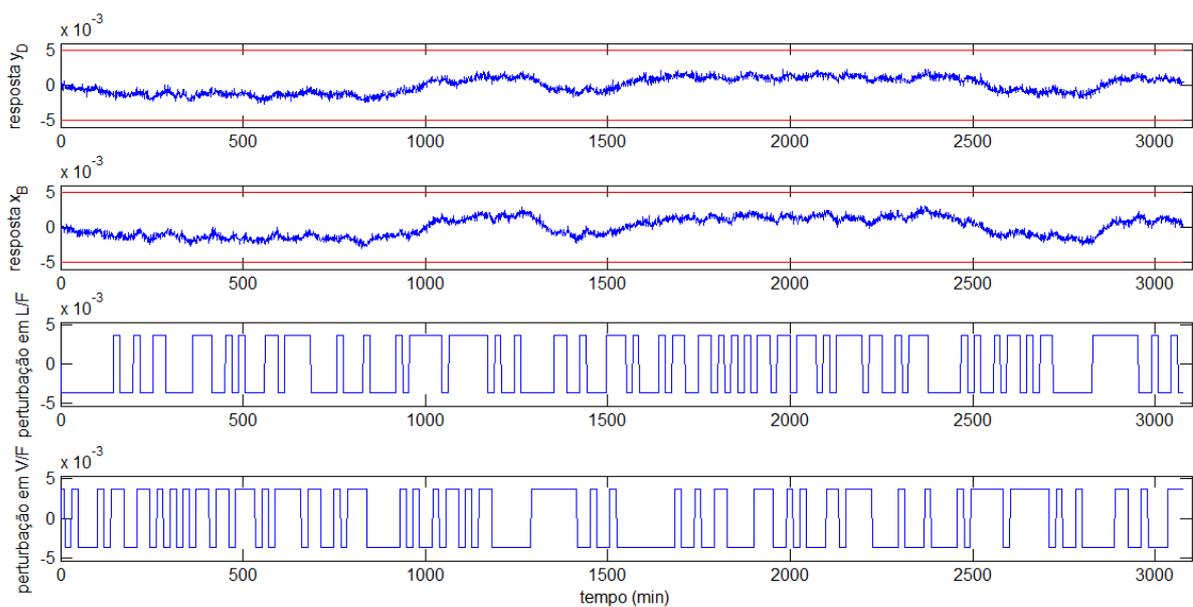


Figura 4.4: Perturbação PRBS aplicada ao estudo de caso em um procedimento de identificação.

Diferentemente da perturbação Degrau, a perturbação PRBS utiliza perturbações com frequências maiores, retirando pouca informação do sistema para frequências mais baixas. Isso é confirmado na Figura 4.5 onde é feita a comparação entre os modelos identificados e o modelo real. O maior valor singular foi bem identificado dentro da banda de frequência determinada para a perturbação, e mal identificado na região de baixa frequência.

Já o menor valor singular, assim como na perturbação Degrau, não foi bem identificado em nenhum dos modelos identificados, pelos mesmos motivos descritos anteriormente. Modelos que não representam a direção de menor ganho podem trazer perda de eficiência do controle e também problemas de robustez.

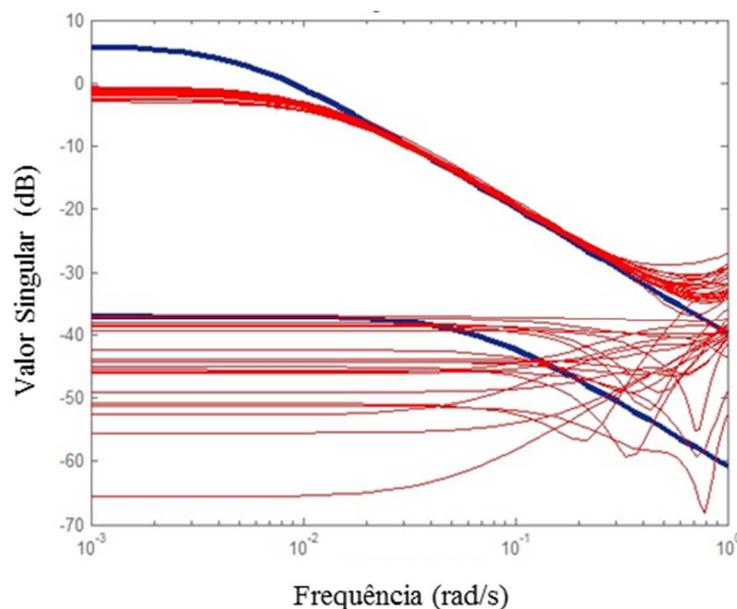


Figura 4.5: Comparação dos valores singulares dos cinquenta modelos identificados com a perturbação PRBS (linhas vermelhas) com os valores singulares do processo real (linha azul).

Novamente, a ausência de dados na direção de menor ganho ocasiona os erros de identificação mencionados. A Figura 4.6 mostra a dispersão dos dados nas variáveis

controladas gerados pela perturbação PRBS. Como a perturbação PRBS não atinge o estado estacionário, os dados são mais concentrados na faixa central do gráfico, pois as variáveis não são perturbadas até os seus limites.

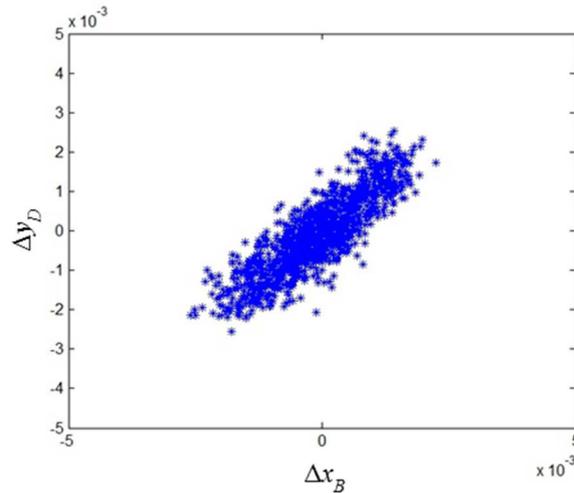


Figura 4.6: Dispersão típica dos dados gerados para uma identificação utilizando perturbação PRBS.

4.1.3 Perturbação GBN

A perturbação GBN traz características das perturbações Degrau e PRBS, pois excita tanto a região de baixa frequência quanto a região de alta frequência. Para otimizar a perturbação GBN é necessário escolher um valor adequado para p , pois ele define a quantidade de energia da perturbação que será aplicada nas frequências baixas, que trazem informações do estado estacionário do sistema. Para otimizar este valor foram realizadas identificações do estudo de caso para diversos valores de p . Os resultados são apresentados na Tabela 4.1 e mostram que o valor de 0,8 é o que apresenta os melhores resultados para os parâmetros de qualidade dos modelos identificados. Este valor será utilizado para a comparação das perturbações GBN com as demais perturbações. Para valores próximos de $\frac{1}{2}$ as baixas frequências não são excitadas e acabam gerando muitos erros na matriz de ganhos estacionários. Para valores maiores de p a qualidade dos modelos identificados reduz, pois, as maiores frequências deixam de ser excitadas.

Tabela 4.1: Resultados obtidos para a variação do valor de p .

	$p = 0,5$	$p = 0,6$	$p = 0,7$	$p = 0,8$	$p = 0,9$
<i>FIT1</i>	39,3%	41,0%	43,8%	45,8%	44,5%
<i>FIT2</i>	58,6%	61,1%	65,3%	68,3%	66,4%
<i>erroA</i>	0,158	0,155	0,152	0,149	0,151
<i>erroB</i>	0,154	0,151	0,148	0,145	0,147
<i>erroK</i>	63,9%	61,9%	58,4%	56,0%	57,6%
<i>erroσ_M</i>	26,0%	25,2%	23,8%	22,8%	23,4%
<i>erroσ_m</i>	72,4%	70,0%	66,2%	63,4%	65,2%
<i>erroPAR</i>	63,9%	61,9%	58,4%	56,0%	57,6%
<i>IMF</i>	63,9%	61,9%	58,4%	56,0%	57,6%

A Figura 4.7 ilustra a perturbação GBN para p igual a 0,8 e mostra a característica de perturbar tanto frequências elevadas quanto frequências baixas.

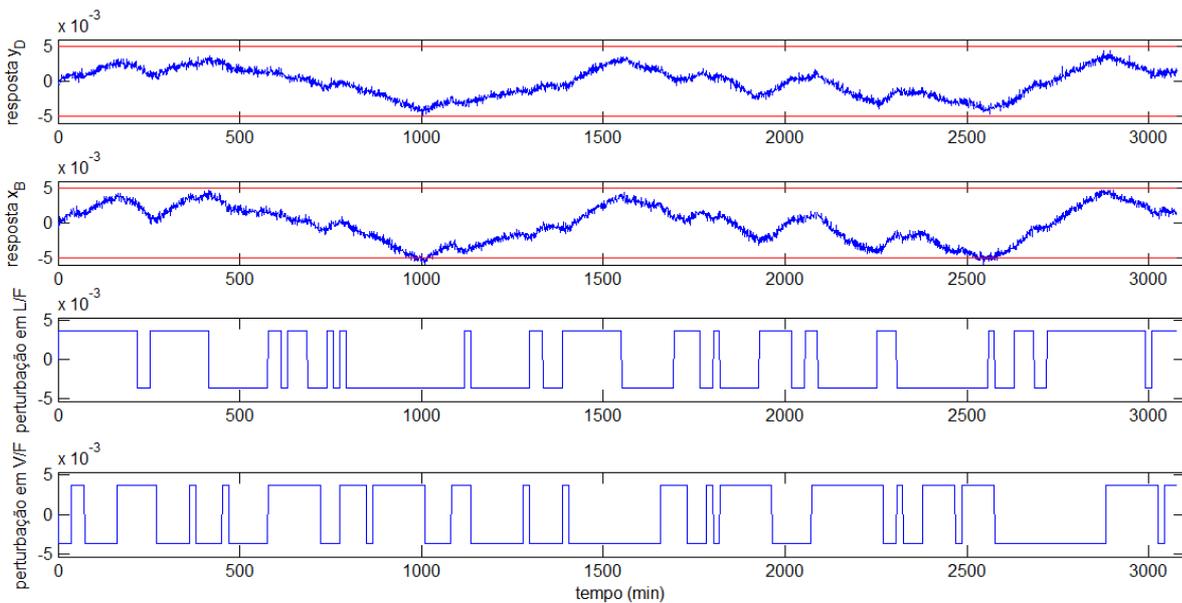


Figura 4.7: Perturbação GBN aplicada ao estudo de caso em um procedimento de identificação com p igual a 0,8.

Por ter a possibilidade de chegar próximo ao estado estacionário e utilizar a mesma amplitude utilizada nas perturbações Degrau e PRBS, a perturbação GBN chega próximo dos limites impostos para as variáveis controladas, diferentemente da perturbação PRBS.

A característica de perturbar um espectro mais amplo de frequência faz com que o sinal GBN identifique o maior valor singular com qualidade em todas as regiões, como pode ser visto na Figura 4.8. Porém, da mesma forma que as perturbações anteriores, ele não consegue identificar o menor valor singular, pois os dados de identificação não têm informações sobre a direção de menor ganho, como pode ser visto na Figura 4.9.

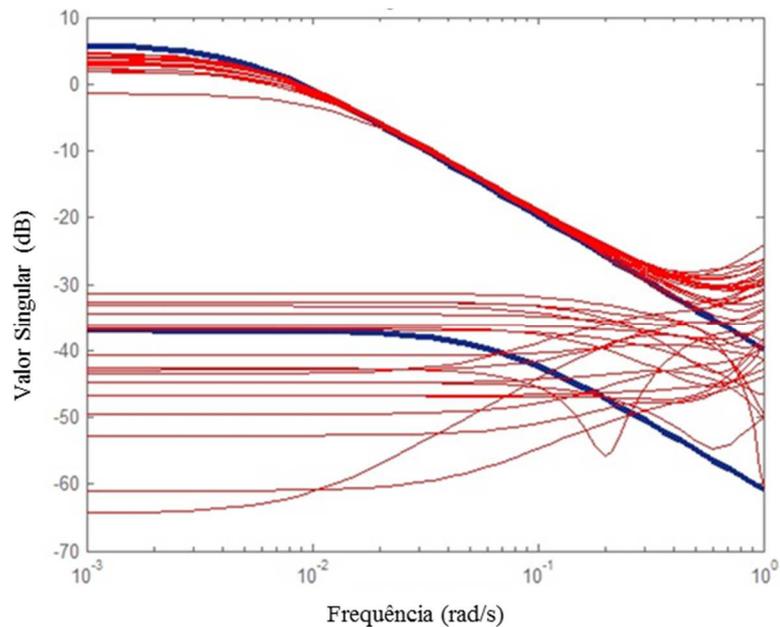


Figura 4.8: Comparação dos valores singulares dos cinquenta modelos identificados com a perturbação GBN (linhas vermelhas) com os valores singulares do processo real (linha azul).

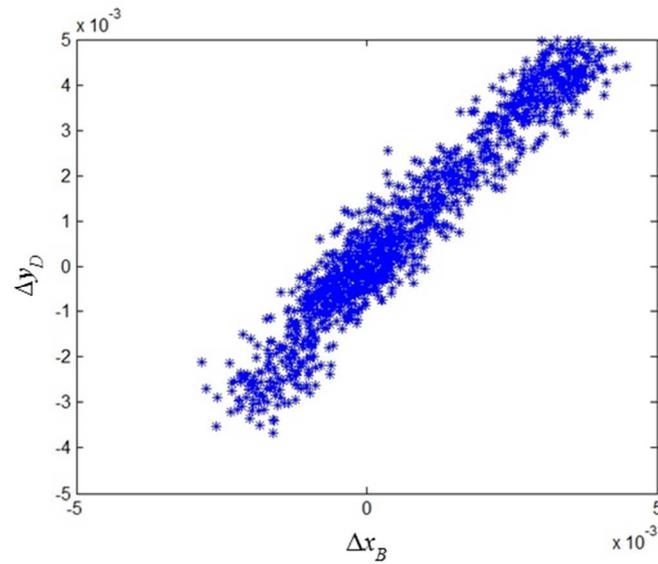


Figura 4.9: Dispersão típica dos dados gerados para uma identificação utilizando perturbação GBN.

4.1.4 Resumo da Comparação

A Tabela 4.2 resume os resultados obtidos nesta primeira etapa, onde foram utilizados os critérios descritos no capítulo anterior para comparar a eficácia de cada método.

Tabela 4.2: Resultados obtidos para comparação entre os métodos Degrau, PRBS e GBN.

	Degrau	PRBS	GBN
<i>FIT1</i>	42,2%	40,5%	45,8%
<i>FIT2</i>	62,0%	63,7%	68,3%
<i>erroA</i>	0,152	0,162	0,149
<i>erroB</i>	0,163	0,153	0,145
<i>erroK</i>	60,0%	62,0%	56,0%
<i>erroσ_M</i>	23,5%	24,2%	22,8%
<i>erroσ_m</i>	65,5%	62,3%	63,4%
<i>erroPAR</i>	60,0%	62,0%	56,0%
<i>IMF</i>	60,0%	62,0%	56,0%

A Tabela 4.2 mostra que nenhum dos métodos se mostrou eficaz na identificação de sistemas mal condicionados. Todos os três métodos apresentaram erro do sinal multivariável e no emparelhamento das variáveis em mais de 50% dos modelos identificados. O mesmo vale para a estabilidade em malha fechada.

Os modelos apresentaram pequeno erro na identificação do maior valor singular, porém apresentaram grande erro na identificação no menor valor singular, que representa a direção de menor ganho. No entanto, o método GBN apresentou melhor identificação do maior valor singular para uma faixa maior de frequências e também apresentou resultados melhores que os demais métodos nos critérios de comparação. Isso também pode ser visto pela validação cruzada, apresentada na Figura 4.10 para os modelos com os melhores graus de ajuste de cada método.

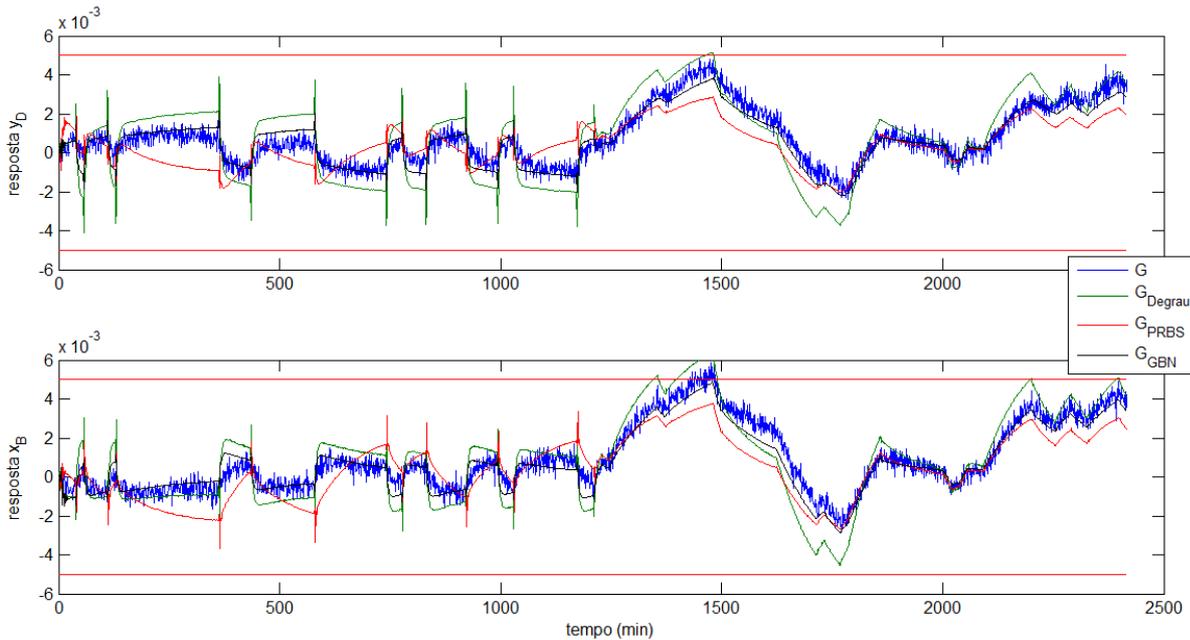


Figura 4.10: Validação cruzada para os melhores modelos identificados com os métodos Degrau, PRBS e GBN.

O método GBN apresentou melhor grau ajuste tanto para o primeiro conjunto de dados quanto para o segundo. Pelos resultados da comparação entre os três métodos, foi decidido utilizar a metodologia GBN para perturbação base para as perturbações da metodologia proposta.

4.2 Avaliação do método de dois passos e aplicação da metodologia para maximizar a amplitude das perturbações

4.2.1 Método de Dois Passos

Para a comparação dos métodos de dois passos, foi realizado o mesmo procedimento utilizado na seção de comparação das perturbações clássicas. Todos os métodos desta seção utilizam perturbações do tipo GBN como base e todos os parâmetros utilizados são iguais aos definidos na seção anterior.

Para os métodos de dois passos, a amplitude utilizada nos sinais não correlacionados foi a

mesma da utilizada nas perturbações da seção anterior. Já a amplitude utilizada nos sinais correlacionados, foi dez vezes a amplitude utilizada nos sinais não correlacionados, como sugere o autor do método. As Figuras 4.11 e 4.12 mostram uma sequência de identificação para cada variação do método, para sinais concatenados e somados, respectivamente.

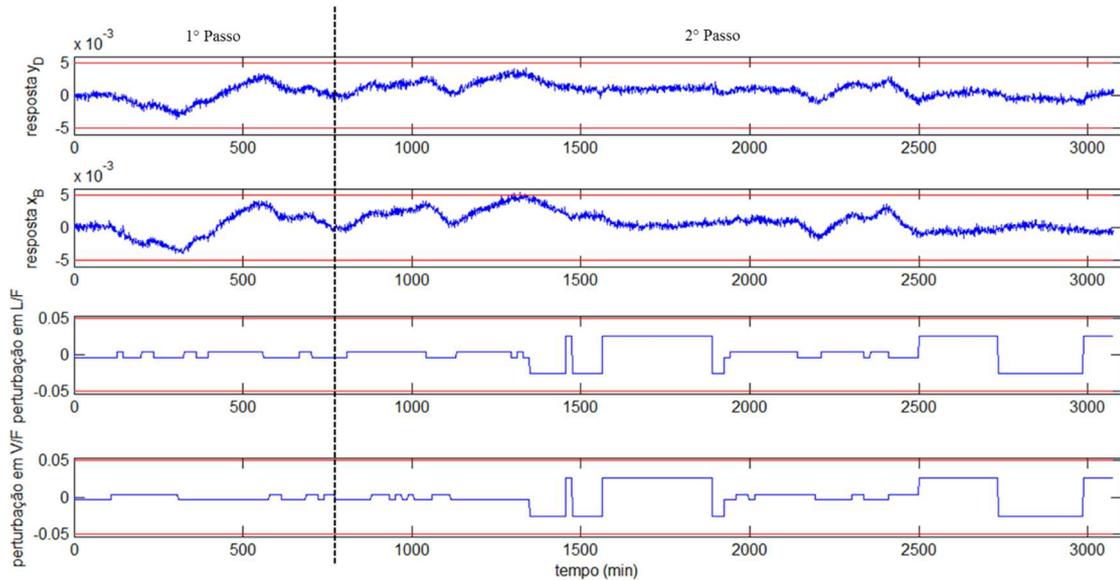


Figura 4.11: Perturbação de dois passos com sinais concatenados aplicada ao estudo de caso em um procedimento de identificação.

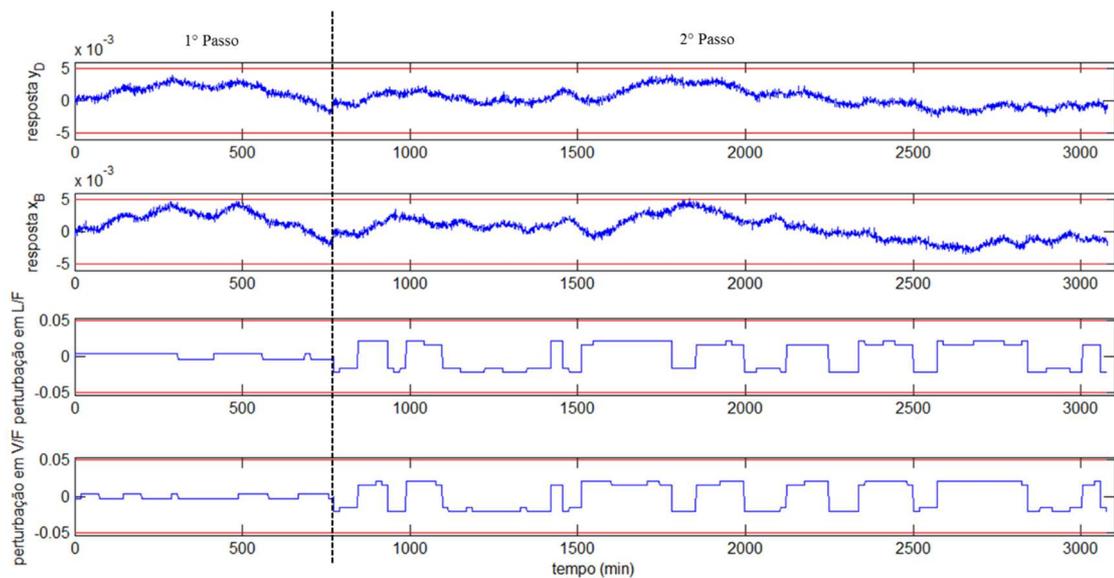


Figura 4.12: Perturbação de dois passos com sinais somados aplicada ao estudo de caso em um procedimento de identificação.

Os limites determinados para as variáveis controladas e manipuladas não foram ultrapassados em ambos os casos, mesmo utilizando uma amplitude dez vezes maior para a direção de menor ganho. A dispersão dos dados de saída do conjunto de dados de identificação muda sua característica e apresenta um pouco de informações da direção de menor ganho, como pode ser visto na Figura 4.13.

Para o método de dois passos com sinais concatenados, os dados aparecem numa forma de cruz, justamente por que os sinais são concatenados e as direções não são perturbadas simultaneamente. Já o método de dois passos com sinais somados parece deslocar o perfil de dados da direção de maior ganho sobre a direção de menor ganho, formando uma espécie de retângulo. Essa dispersão maior nos dados de identificação, em um primeiro momento, pode levar a conclusão errônea de que os modelos identificados com o segundo método teriam uma qualidade maior, porém isso não acontece. Na comparação realizada na Tabela 4.4, não foi possível verificar uma diferença significativa na qualidade dos modelos identificados. A Figura 4.14 mostra a análise dos valores singulares feita para os dois métodos.

Contudo, é importante enfatizar que os métodos foram capazes de representar a direção de menor ganho com mais precisão que os métodos tradicionais. A Figura 4.15 mostra a validação cruzada de um modelo obtido com cada método, sendo possível observar a melhora na identificação da direção de menor ganho.

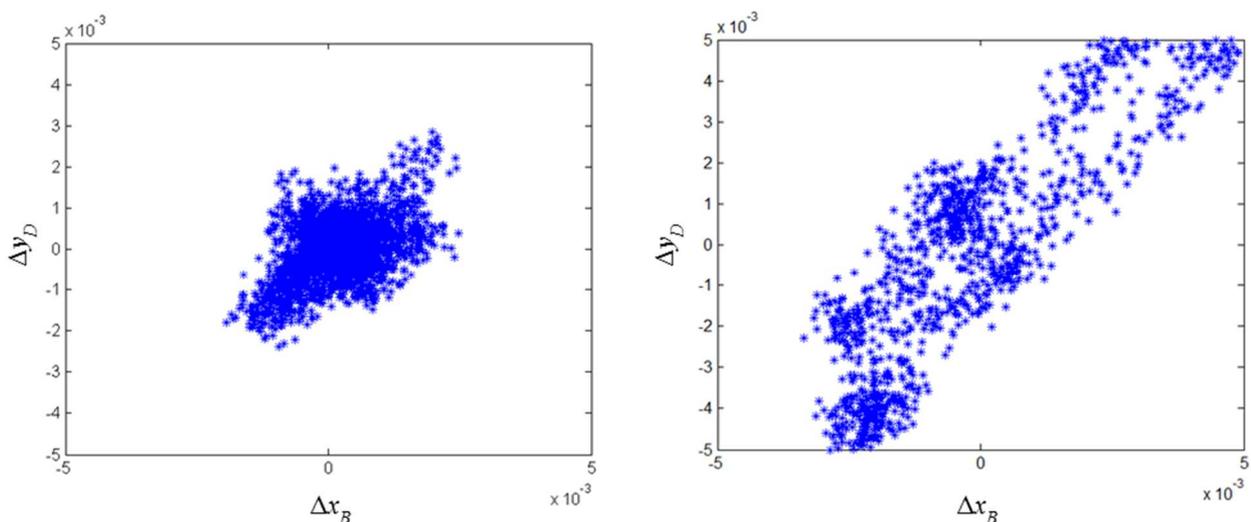


Figura 4.13: Dispersão típica dos dados gerados para uma identificação utilizando perturbação de dois passos com sinais concatenados (esquerda) e perturbação de dois passos com sinais somados (direita).

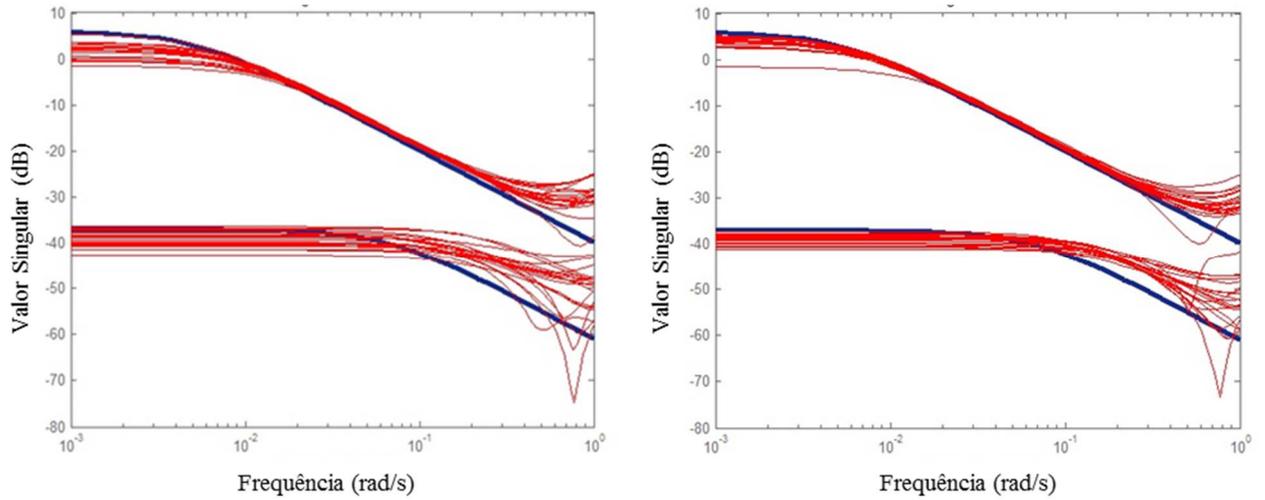


Figura 4.14: Comparação dos valores singulares dos cinquenta modelos obtidos com a perturbação de dois passos com sinais concatenados (esquerda) e com a perturbação de dois passos com sinais somados (direita).

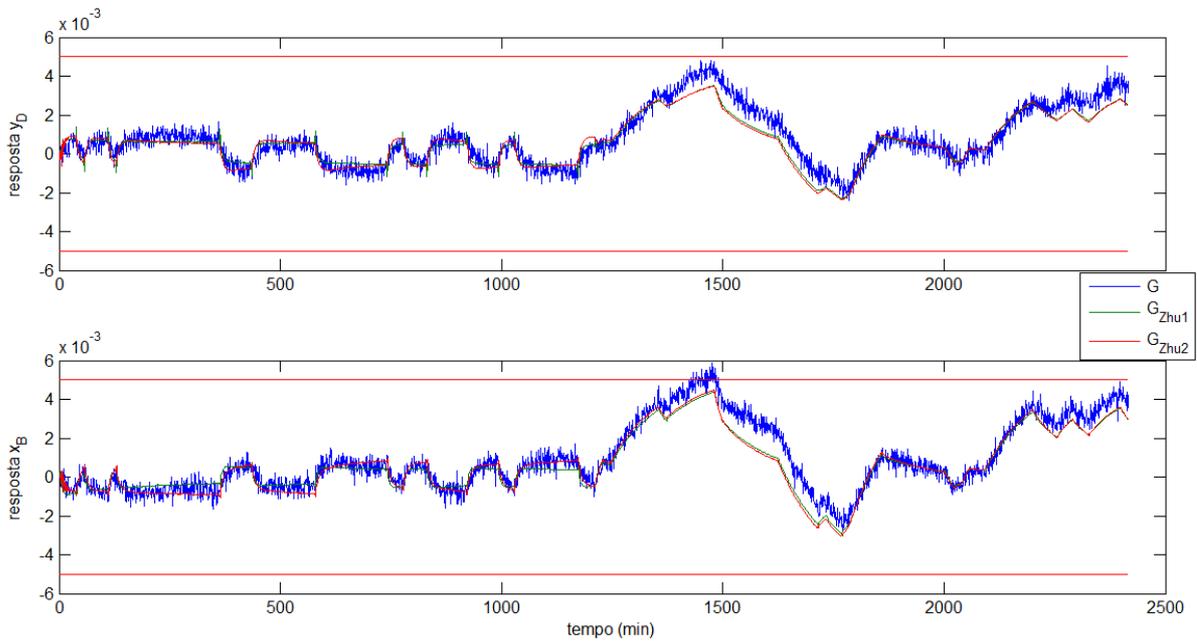


Figura 4.15: Validação cruzada para os melhores modelos identificados com os métodos de dois passos.

4.2.2 Aplicação da metodologia proposta de maximização da amplitude

Em sistemas mal condicionados a qualidade dos dados depende muito das perturbações na direção de menor ganho do sistema, como mencionado anteriormente. Para obter dados com qualidade da direção de menor ganho é indispensável perturbar esta direção com amplitude suficiente para que a resposta do sistema não seja confundida com o ruído e com distúrbios não medidos do processo. Portanto, encontrar uma aproximação suficientemente boa da direção de menor ganho e maximizar a amplitude da perturbação nesta direção é muito importante. O método proposto visa exatamente isso, através de um processo iterativo onde a aproximação da direção de menor ganho é melhorada a cada iteração e a amplitude da perturbação é maximizada, evitando que os limites impostos pelo processo nas variáveis de entrada e saída sejam ultrapassados.

Como pode ser visto nas Figuras 4.11 e 4.12, a amplitude da perturbação na direção de menor ganho poderia ser maior sem que as variáveis controladas atingissem os limites determinados e se a direção de menor ganho tivesse uma aproximação melhor, esta amplitude poderia ser ainda maior.

O método proposto para maximizar a amplitude da direção de menor ganho faz uma atualização dessa direção a cada iteração, como ilustra a Figura 4.16, possibilitando o aumento da amplitude da perturbação a cada nova iteração. Com isso é possível maximizar a amplitude de perturbação da direção de menor ganho, como mostram as Figuras 4.17 e 4.18, onde são apresentados exemplos de procedimentos de identificação utilizando a metodologia proposta com sinais concatenados e com sinais somados.

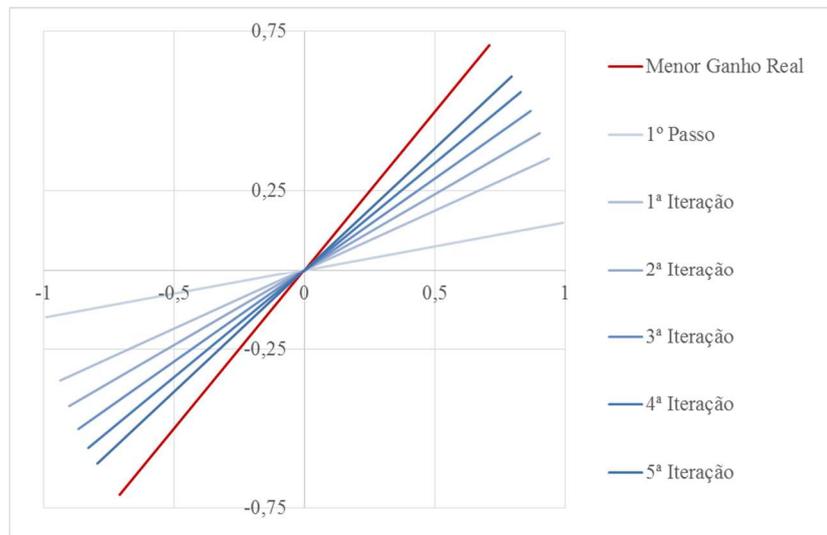


Figura 4.16: Atualização da direção de menor ganho em uma identificação utilizando a metodologia proposta.

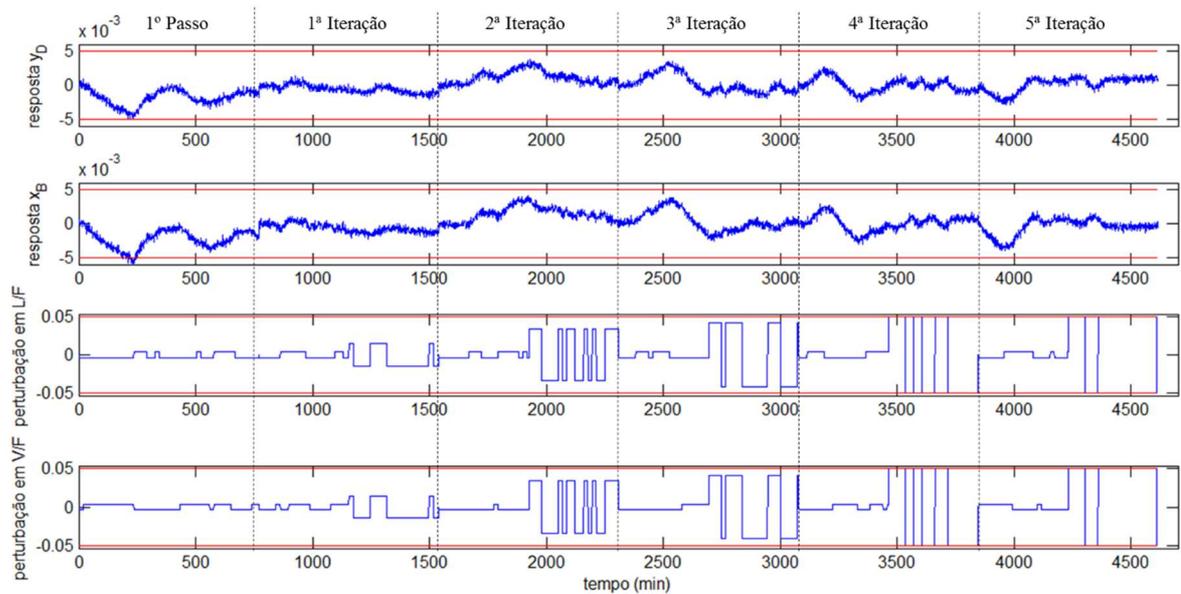


Figura 4.17: Perturbação proposta com sinais concatenados aplicada ao estudo de caso em um procedimento de identificação.

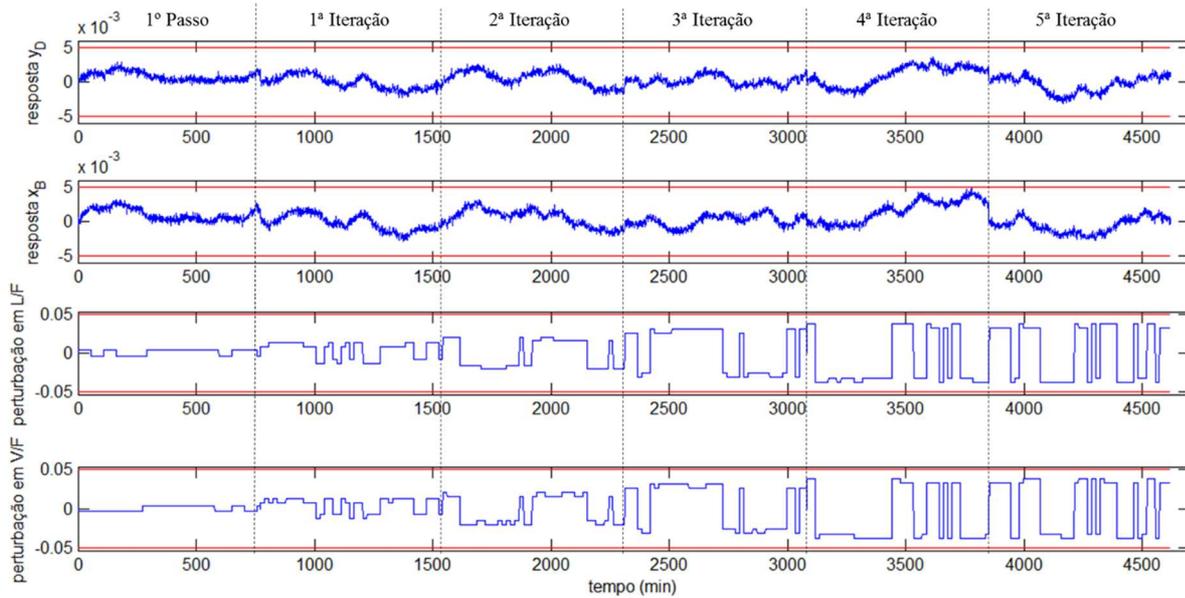


Figura 4.18: Perturbação proposta com sinais somados aplicada ao estudo de caso em um procedimento de identificação.

No primeiro passo do método, a direção de menor ganho tem uma aproximação muito pobre, pois no primeiro passo nenhuma perturbação é projetada nesta direção. Com o avanço das iterações essa aproximação melhora e é possível aumentar a amplitude das perturbações seguintes. A melhoria da aproximação também pode ser representada pela evolução do parâmetro w . Conforme a confiança no modelo aumenta, o fator w aumenta e a aproximação da direção de menor ganho melhora. A evolução do fator w para as perturbações das Figuras 4.17 e 4.18 está apresentado na Tabela 4.3.

Tabela 4.3: Evolução do fator w para as perturbações das Figuras 4.17 e 4.18

	w para sinais concatenados	w para sinais somados
1° Passo	-	-
1ª Iteração	0,300	0,300
2ª Iteração	0,424	0,380
3ª Iteração	0,610	0,528
4ª Iteração	0,799	0,730
5ª Iteração	1,000	0,917

Em ambos os casos a perturbação foi aumentando a sua amplitude na direção de menor ganho sem que as variáveis controladas atingissem os seus limites. Na Figura 4.19 é possível verificar que o conjunto de dados de identificação tem uma maior concentração de dados da direção de menor ganho em relação aos dados obtidos com a metodologia de 2 passos sem a maximização da amplitude do sinal. Este ganho de informação da direção de menor ganho melhora a qualidade dos modelos identificados, como pode ser visto na Figura 4.20, onde são mostrados os valores singulares dos modelos obtidos com a maximização da amplitude da direção de menor ganho. É possível verificar uma melhoria significativa no menor valor singular. A Figura 4.21 apresenta a validação cruzada dos modelos obtidos com o método proposto.

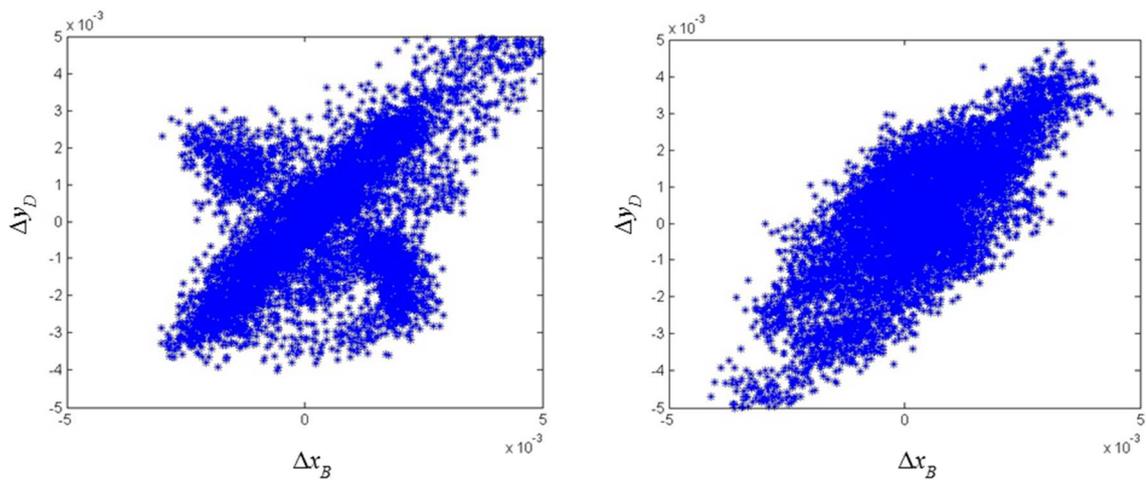


Figura 4.19: Dispersão típica dos dados gerados para identificação utilizando a metodologia proposta com sinais concatenados (esquerda) e com sinais somados (direita).

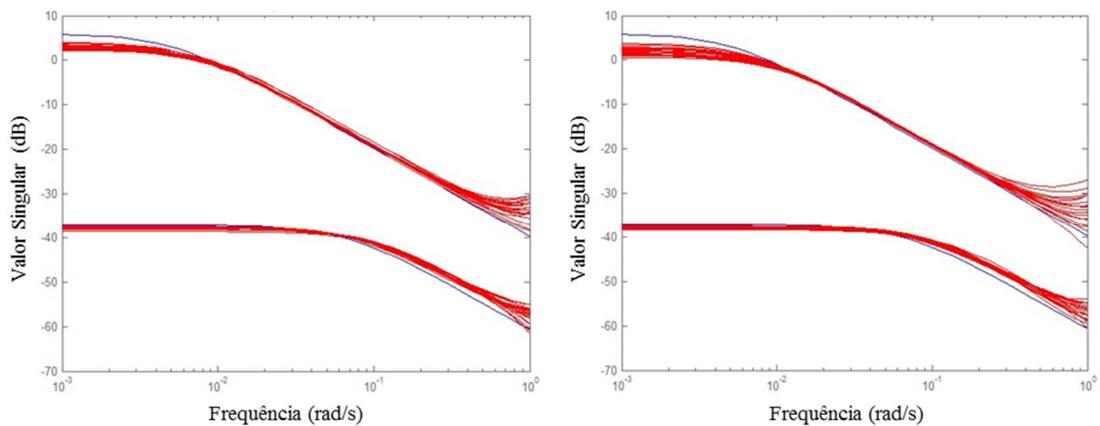


Figura 4.20: Comparação dos valores singulares modelos obtidos com a metodologia proposta e com sinais concatenados (esquerda) e com sinais somados (direita).

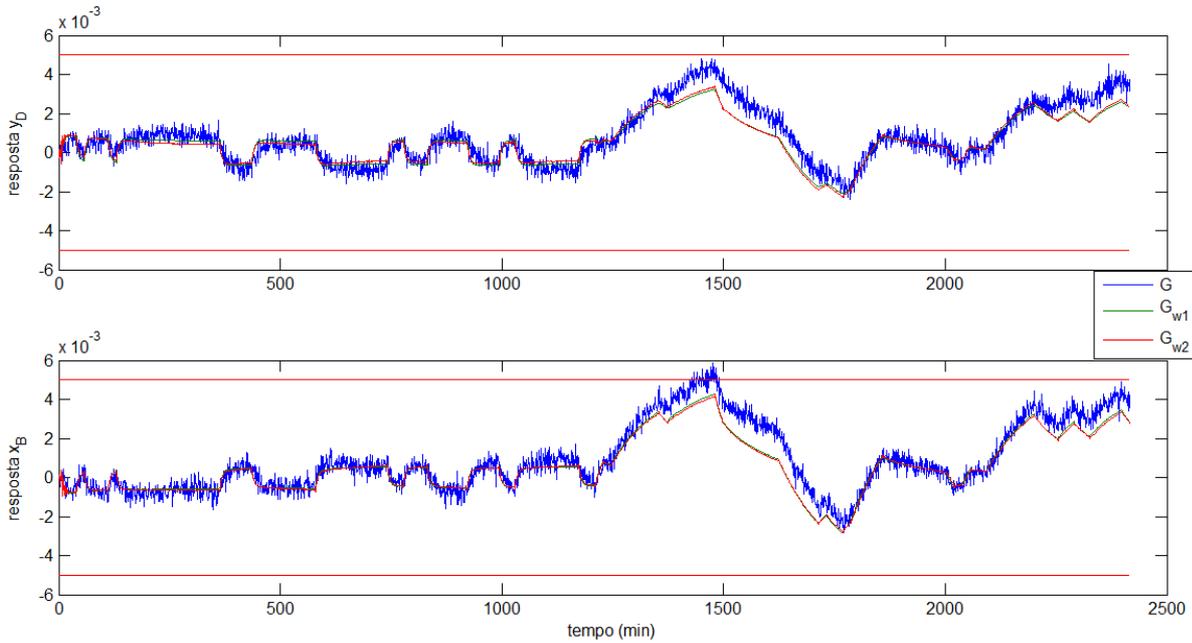


Figura 4.21: Validação cruzada para os melhores modelos identificados com a metodologia proposta.

4.2.3 Resumo da Comparação

A Tabela 4.4 mostra os resultados obtidos para comparação da metodologia proposta com os métodos de dois passos, onde se pode verificar que a metodologia proposta apresenta melhores resultados em todos os parâmetros de comparação. O fator w mostra claramente a evolução da qualidade da identificação da direção de menor ganho, podendo ser utilizado como critério de parada das iterações. Porém, a metodologia proposta pode aumentar o tempo de duração do experimento de identificação, pois se trata de um processo iterativo e a qualidade do modelo dependerá do número de iterações.

Tabela 4.4: Resultados obtidos para comparar os métodos de 2 passos e o método proposto.

	Método de 2 Passos		Método Proposto	
	Concatenados	Somados	Concatenados	Somados
<i>FIT1</i>	75,2%	74,3%	85,1%	86,2%
<i>FIT2</i>	84,9%	83,7%	91,2%	89,3%
<i>erroA</i>	0,085	0,087	0,046	0,048
<i>erroB</i>	0,081	0,083	0,041	0,043
<i>erroK</i>	16,0%	20,0%	8,0%	6,0%
<i>erroσ_M</i>	12,0%	11,1%	8,2%	7,3%
<i>erroσ_m</i>	27,5%	24,2%	12,2%	11,7%
<i>erroPAR</i>	16,0%	20,0%	8,0%	6,0%
<i>IMF</i>	16,0%	20,0%	8,0%	6,0%

4.2.4 Avaliação do Efeito do Tempo de Duração da Perturbações

Para verificar a eficiência do método para tempos menores de duração total do experimento, foram feitas novas identificações com dois novos tempos de duração do experimento. O primeiro tempo é 3076 minutos, ou seja, o mesmo tempo de duração do método de dois passos. O segundo tempo é 2500 minutos para verificar se a metodologia consegue ser mais eficaz mesmo com tempo menor de duração do experimento. Para cada um dos novos tempos foram realizadas cinquenta identificações, da mesma forma que as comparações anteriores.

Para mostrar a influência do tempo de duração do experimento, foi avaliada primeiramente a evolução do fator w durante as cinco iterações, tanto para o caso utilizando sinais concatenados, mostrado na Figura 4.22, quanto para o caso utilizando sinais somados, mostrado na Figura 4.23. Para a comparação foi calculado o fator w médio das cinquenta identificações para cada iteração.

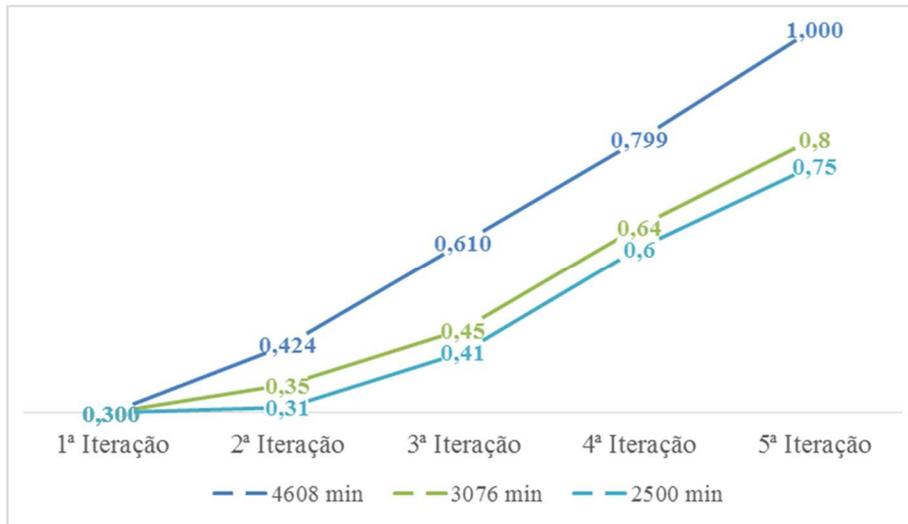


Figura 4.22: Evolução do fator w para as identificações utilizando a metodologia proposta com sinais concatenados.

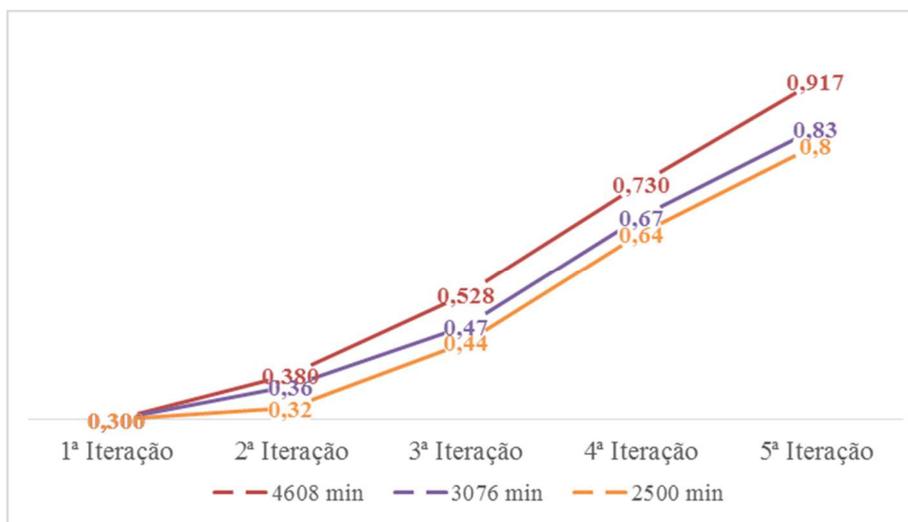


Figura 4.23: Evolução do fator w para as identificações utilizando a metodologia proposta com sinais somados.

Como pode ser visto em ambos os casos, a evolução do fator w teve uma redução conforme o tempo de duração do experimento foi reduzido. Porém, para as identificações utilizando sinais somados esta redução na evolução do fator w foi menor. Isso pode ser explicado pela característica dos sinais: no método utilizando sinais concatenados as direções são perturbadas separadamente, quando o tempo de duração do experimento é reduzido a quantidade de

informação obtida da direção de menor ganho é muito pequeno. Já no método de sinais somados, como as direções são perturbadas simultaneamente, a quantidade de dados obtidos da direção de menor ganho é suficiente para uma melhor identificação.

A Tabela 4.5 comprova a melhor eficácia do método de sinais somados quando o tempo de perturbação é reduzido. Com o tempo de duração igual ao utilizado na metodologia de dois passos, a metodologia proposta obteve modelos melhores em relação ao método de dois passos. Já com o tempo de duração menor a metodologia proposta utilizando sinais concatenados obteve resultados equivalentes com os obtidos para o método de dois passos, e a metodologia proposta com sinais somados manteve uma qualidade superior nos modelos identificados. Isso mostra que a metodologia proposta com sinais somados é menos influenciada pela redução do tempo de duração do teste de identificação.

Tabela 4.5: Resultados obtidos para avaliação do efeito do tempo de duração dos experimentos de identificação.

	Metodologia Proposta						Método de 2 Passos	
	4608 min		3076 min		2500 min		3076 min	
	Concatenados	Somados	Concatenados	Somados	Concatenados	Somados	Concatenados	Somados
<i>FIT1</i>	85,1%	86,2%	80,2%	81,7%	77,3%	80,1%	75,2%	74,3%
<i>FIT2</i>	91,2%	89,3%	88,5%	90,3%	85,4%	89,2%	84,9%	83,7%
<i>erroA</i>	0,046	0,048	0,051	0,053	0,055	0,057	0,085	0,087
<i>erroB</i>	0,041	0,043	0,046	0,048	0,050	0,052	0,081	0,083
<i>erroK</i>	8,0%	6,0%	11,0%	10,0%	17,0%	12,0%	16,0%	20,0%
<i>erroσ_M</i>	8,2%	7,3%	10,5%	9,8%	12,5%	10,3%	12,0%	11,1%
<i>erroσ_m</i>	12,2%	11,7%	18,3%	17,7%	24,8%	18,8%	27,5%	24,2%
<i>erroPAR</i>	8,0%	6,0%	11,0%	10,0%	17,0%	12,0%	16,0%	20,0%
<i>IMF</i>	8,0%	6,0%	11,0%	10,0%	17,0%	12,0%	16,0%	20,0%

4.2.5 Avaliação do Efeito da Amplitude do Distúrbio Não Medido

Um dos maiores problemas na identificação de modelos é a presença de distúrbios não medidos nas variáveis de processo. Esses distúrbios fazem com que as variáveis de saída variem independentemente da perturbação aplicada no experimento de identificação e muitas

vezes acabam sendo confundidas como algo dependente da perturbação. Essa falsa dependência das variações causadas pelo distúrbio não medido com a perturbação causam erros nas estimativas dos parâmetros do modelo, gerando modelo que não representa bem o processo.

Para avaliar o efeito da amplitude do distúrbio não medido foram feitas identificações variando a amplitude destes distúrbios. Os métodos de dois passos e os métodos propostos foram comparados nas Tabela 4,6 e 4,7 utilizando o mesmo tempo de duração das perturbações (3076 minutos).

Tabela 4.6: Resultados obtidos para avaliação do efeito da amplitude do distúrbio não medido no método proposto.

	Metodologia Proposta (3076 min)					
	0,0005		0,001		0,002	
	Concatenados	Somados	Concatenados	Somados	Concatenados	Somados
<i>FIT1</i>	80,2%	81,7%	76,7%	78,2%	69,5%	71,0%
<i>FIT2</i>	88,5%	90,3%	85,0%	86,8%	77,8%	79,6%
<i>erroA</i>	0,051	0,053	0,056	0,058	0,071	0,073
<i>erroB</i>	0,046	0,048	0,051	0,053	0,066	0,068
<i>erroK</i>	11,0%	10,0%	12,3%	11,3%	15,7%	14,7%
<i>erroσ_M</i>	10,5%	9,8%	11,8%	11,1%	15,2%	14,5%
<i>erroσ_m</i>	18,3%	17,7%	19,6%	19,0%	23,0%	22,4%
<i>erroPAR</i>	11,0%	10,0%	12,3%	11,3%	15,7%	14,7%
<i>IMF</i>	11,0%	10,0%	12,3%	11,3%	15,7%	14,7%

Tabela 4.7: Resultados obtidos para avaliação do efeito da amplitude do distúrbio não medido no método de 2 passos.

	Método de 2 Passos (3076 min)					
	0,0005		0,001		0,002	
	Concatenados	Somados	Concatenados	Somados	Concatenados	Somados
<i>FIT1</i>	75,2%	74,3%	71,7%	70,8%	64,5%	63,6%
<i>FIT2</i>	84,9%	83,7%	81,4%	80,2%	74,2%	73,0%
<i>erroA</i>	0,085	0,087	0,090	0,092	0,105	0,107
<i>erroB</i>	0,081	0,083	0,086	0,088	0,101	0,103
<i>erroK</i>	16,0%	20,0%	17,3%	21,3%	20,7%	24,7%
<i>erroσ_M</i>	12,0%	11,1%	13,3%	12,4%	16,7%	15,8%
<i>erroσ_m</i>	27,5%	24,2%	28,8%	25,5%	32,2%	28,9%
<i>erroPAR</i>	16,0%	20,0%	17,3%	21,3%	20,7%	24,7%
<i>IMF</i>	16,0%	20,0%	17,3%	21,3%	20,7%	24,7%

É possível notar pelos resultados que a medida que o distúrbio não medido aumenta a qualidade dos modelos identificados piora. Porém o método proposto apresenta melhores resultados. Como o método proposto faz a otimização da amplitude de perturbação acaba fazendo com que as variáveis de saída apresentem respostas maiores, chegando próximo aos seus limites. Essa amplitude maior de resposta das variáveis de saída faz com que o distúrbio não medido seja menos significativo e por tanto a identificação apresente melhores resultados.

Capítulo 5

Conclusão e Sugestões para Trabalhos Futuros

Neste trabalho, primeiramente foi feita uma comparação entre os métodos de construção de perturbações não correlacionadas (Degrau, PRBS e GBN) em um sistema mal condicionado para identificação de modelos dinâmicos para aplicação em MPC. Na comparação, nenhum dos métodos foi capaz de identificar com confiabilidade a direção de menor ganho do sistema, porém para a direção de maior ganho algumas diferenças entre os métodos foram levantadas. A metodologia GBN conseguiu identificar melhor a direção de maior ganho para uma faixa maior de frequências. As outras metodologias identificaram bem somente em baixas frequências, no caso das perturbações Degrau, e em altas frequências, no caso das perturbações PRBS. Por este motivo a perturbação GBN foi utilizada como base para a metodologia proposta.

Também foi desenvolvida uma metodologia de construção de perturbações correlacionadas, utilizando as perturbações GBN como base, que visa a maximização da amplitude de perturbação nas direções de menor ganho, evitando que as variáveis de entrada e saída do sistema ultrapassem suas restrições. Essa maximização da amplitude é feita iterativamente através de um problema de otimização que utiliza o modelo identificado na iteração anterior para projetar as perturbações da nova iteração. Também foi proposto um fator de confiabilidade, w , que permite verificar o grau de evolução da qualidade do modelo ao longo das iterações. Este fator se mostrou útil como critério de parada do processo iterativo.

A método proposto foi comparado com perturbações correlacionadas conhecidas na literatura e que apresentam bons resultados na identificação de processos mal condicionados. A metodologia proposta apresentou uma melhora significativa na identificação da direção de menor ganho. Em nenhum momento as variáveis do processo ultrapassaram suas restrições, trazendo mais confiabilidade ao processo de identificação.

5.1 Sugestões para Trabalhos Futuros

Para dar continuidade a este trabalho é necessário aplicar a metodologia em processos com mais variáveis. No estudo de caso utilizado o problema tinha duas variáveis de entrada e duas variáveis de saída. Isso torna a estimativa da direção de menor ganho mais fácil, pois os vetores das direções dos ganhos são ortogonais e em um sistema 2×2 só existem dois vetores. Para um sistema maior o número de vetores aumenta, e com isso a estimativa da direção de menor ganho fica mais difícil.

Para sistemas maiores também podem ser estudadas as formas de perturbar as direções do sistema, por exemplo, poria ser perturbada somente a direção de menor ganho a cada iteração, ou então poderiam ser perturbadas todas as direções nas suas devidas direções com as suas devidas amplitudes. Para isso seria interessante fazer uma generalização do fator w gerar um fator para cada direção, e conforme essa direção atingisse um valor determinado para w ela deixaria de ser perturbada.

Outro ponto deve ser estudado é a reidentificação do modelo do MPC com o controle em malha fechada. Quando o modelo do MPC é considerado inadequado para o controle a reidentificação iniciaria automaticamente obedecendo as restrições do processo. Utilizando como modelo inicial o próprio modelo do MPC. Com este modelo antigo seriam obtidas as primeiras estimativas das direções e das amplitudes a serem utilizadas.

Apêndice

Este apêndice mostra as implementações feitas em MATLAB utilizadas para o desenvolvimento do trabalho.

A.1 Implementação da Rotina de Simulação

```

%% Simula o sistema aplicando as perturbações, ruídos e distúrbios
não medidos determinados.
sim('MA_2x2')
y = dados.signals(1).values; % resposta da planta à perturbação
u = dados.signals(2).values; % perturbações aplicada
d = dados.signals(3).values; % distúrbios não medido aplicado
z = iddata(y,u,TS); % formação do conjunto de dados para
identificação
th = arx(z,NN); % identificação do modelo discreto
com estrutura ARX

```

A.2 Implementação da Maximização de Amplitude

```

%% Maximização das Amplitudes de Perturbação
%% Rafael Ramos Wagner - 30/09/2012

% G é a matriz de transferência.
% UB é o vetor com os limites superiores das variáveis de entrada e
saída.
% LB é o vetor com os limites inferiores das variáveis de entrada e
saída.
% muy é o vetor com os valores iniciais das variáveis de saída.
% muu é o vetor com os valores iniciais das variáveis de entrada.
% Amp é o vetor com as amplitudes máximas das perturbações nas
direções V.

function [Amp]=ampl(G,UB,LB,muy,muu)

G0=dcgain(G); % matriz de ganhos estacionários
[U S V]=svd(G0); % decomposição em valores singulares de G0.

for i=1:size(V,1)
    z=[zeros(1,4*size(G,1)), -1];
    a=[eye(4*size(G)), [G0*V(:,i);V(:,i);-G0*V(:,i);-V(:,i)]];
    b=[muy;muu;muy;muu];
    c=[eye(4*size(G)), zeros(4*size(G,1),1);-eye(4*size(G,1)+1)];
    d=[UB;UB;-LB;-LB;0];
    X=linprog(z,c,d,a,b);
    Amp(i)=X(end);
end

```

A.3 Implementação da Perturbação Degrau

```

%% Gerador de Perturbações Degrau Unitário
%% Rafael Ramos Wagner - 26/09/2012

% pertu = matriz com perturbações degrau nas variáveis de entrada
% n = número de trocas de sinal
% tp = tempo de permanência
% k = 1 , o sistema volta para o zero antes do novo degrau
% k = 0 , o sistema não volta para o zero antes do novo degrau
% u = número de variáveis de entradas

function pertu=DEGRAUS(tp, n, u, k)

if (nargin<4),
    k=0;
end

if (nargin<3),
    u=1;
end

pertu=zeros(tp*n*u,u);
for j=1:u
    pert=ones(tp,1);
    for i=1:n-1
        if k==0
            pert1=[(-1)^(i)*ones(tp,1)];
            pert=[pert;pert1];
        else
            e=(-1)^(i);
            if e==-1
                pert1=zeros(tp,1);
            else
                pert1=[(-1)^(i/2)*ones(tp,1)];
            end
            pert=[pert;pert1];
        end
    end
    pert=[zeros(tp*n*(j-1),1);pert;zeros(tp*n*(u-j),1)];
    pertu(:,j)=pert;
end
end

```

A.4 Implementação da Perturbação GBN

```

%% Gera perturbações do tipo GNB (Generalized Binary Noise)
%% Rafael Ramos Wagner - 15/10/2012

% td é o tempo de duração da perturbação
% P é a probabilidade de não haver troca de sinal

```

```

% band são as bandas de menor e maior frequências que o sinal deve
conter
    % band = [Lfr, Hfr]
% levels são os valores máximo e mínimo do sinal
    % levels = [Ll, Hl]

function pert = GBN(td,P,band,levels)

mult=-1;
status=1;
cont=0;
clockP=floor(1/band(2));
possP=ceil(td/clockP);
% Determinação do conjunto de números randômicos com
% probabilidade de serem positivos = P
V=3.29*10^15*exp(-((P-1.286)/0.048)^2)+20.9*exp(-((P-2.01)/0.67)^2);
pert=zeros(possP*clockP,1);

for t=1:clockP:clockP*possP;
    nstatus=sign(randn(1)+V);
    if nstatus~=status
        cont=cont+1;
        mult=(-1)^(1+cont);
    end
    pert(t:t+clockP-1,1)=ones(clockP,1)*mult;
end
pert=(levels(2)-levels(1))*(pert(1:td,1)+1)/2+levels(1);

end

```

A.5 Implementação da Perturbação pelo Método de Dois Passos

```

%% Gerador de perturbações pelo método de 2 passos
%% Rafael Ramos Wagner - 30/10/2012

% td = tempo de duração da perturbação
% u = número de variáveis de entrada
% Amp = amplitude da perturbação nas direções
% vd = vetor com a direção de menor ganho
% band são as bandas de menor e maior frequências que o sinal deve
conter
    % band = [Lfr, Hfr]
% P é a probabilidade de não haver troca de sinal
% k = 1, método de 2 passos concatenados
% k = 2, método de 2 passos somados

function pert=ZHU(td, u, Amp, vd, band,P,k)

if (nargin<6),
    P=0.8;
    k=1;
end

```

```

if (nargin<7),
    k=1;
end

if k==1
    for i=1:u
        pert(:,i)=Amp(1)*GBN(td/u,P,band,[-1 1]);
    end
    pert1=Amp(end)*GBN(td/u,P,band,[-1 1])*vd';
    pert=[pert;pert1];
elseif k==2
    for i=1:u
        pert(:,i)=Amp(1)*GBN(td,P,band,[-1 1]);
    end
    pert1=Amp(end)*GBN(td,P,band,[-1 1])*vd';
    pert=pert+pert1;
end

```

A.6 Implementação da Perturbação Proposta

```

%% Método proposto no trabalho
%% Rafael Ramos Wagner 25/11/2012

% Carregando dados do estudo de caso
modelo_LV
ti=t;          % tempo de estabilização das variáveis
t=t/2;        % tempo de duração do experimento de identificação do
modelo prévio
Ident_GBN     % Identificação do modelo prévio - GBN não
correlacionada

w=0.3;        % fator de confiabilidade inicial
wh=w;
t=ti;         % tempo de duração do experimento para cada iteração

for i=1:5     % número de iterações (1º critério de parada)
    Ai=ampl(th,UB,LB,muy,muu); % Maximização da amplitude de
    perturbação utilizando o modelo da última iteração
    [~,S,V]=svd(dcgain(th));   % Obtenção das direções do sistema
    Aw=[A,Ai(end)*w];         % Aplicação do fator de confiabilidade à
    amplitude de menor ganho
    if Aw(end)<A               % Amplitude da direção de menor ganho
        igual ou maior que a amplitude inicial
        Aw(end)=A;
    end
    tipo=1;                    %determina o tipo da perturbação do
    método de dois passos
    pert=ZHU(t,2,Aw/sqrt(tipo),V(:,end),[freqmin,
    freqmax/(2*pi)],p,tipo); % Perturbações
    tend=size(pert,1);
    dist=[GBN(tend,0.5,[0,fd],[-rd rd]),GBN(tend,0.5,[0,fd],[-rd rd])];
    % distúrbio não medido

% Realizando Identificação

```

```
% Identifica
Identifica_acumulada % aplica perturbações à simulação, coleta os
dados e identifica o modelo

    if w>0.8           % verificação do último valor do fator de
confiabilidade
        break         % (2º critério de parada)
    end

% calculo do novo valor do fator de confiabilidade
deltamax=max(abs(yi));
wi=min(UB(1:2)*w./deltamax');
if wi>w               % o fator de confiabilidade deve ser maior que o
anterior
    if wi>1           % e menor do que 1
        w=1;
    else
        w=wi;
    end
end
wh=[wh;w];           % grava histórico da evolução do fator de
confiabilidade
end
```

Referências Bibliográficas

AZLAN HUSSAIN, M. Review of the applications of neural networks in chemical process control — simulation and online implementation. **Artificial Intelligence in Engineering**, v. 13, n. 1, p. 55-68, 1// 1999. ISSN 0954-1810. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0954181098000119> >.

BRISTOL, E. H. RGA 1977: DYNAMIC EFFECTS OF INTERACTION. **Proceedings of the IEEE Conference on Decision and Control**, p. 1096-1100, 1977. Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-0017705658&partnerID=40&md5=037995eab06c4893e5405ff4c88f775b> >.

BRUWER, M.-J.; MACGREGOR, J. F. Robust multi-variable identification: Optimal experimental design with constraints. **Journal of Process Control**, v. 16, n. 6, p. 581-600, 7// 2006. ISSN 0959-1524. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0959152405001393> >.

CHEN, J.-K.; YU, C.-C. Optimal input design using generalized binary sequence. **Automatica**, v. 33, n. 11, p. 2081-2084, 11// 1997. ISSN 0005-1098. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0005109897001222> >.

CHIUSO, A.; PICCI, G. On the ill-conditioning of subspace identification with inputs. **Automatica**, v. 40, n. 4, p. 575-589, 4// 2004. ISSN 0005-1098. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0005109803003674> >.

CONNER, J. S.; SEBORG, D. E. An evaluation of MIMO input designs for process identification. **Industrial and Engineering Chemistry Research**, v. 43, n. 14, p. 3847-3854, // 2004. ISSN 08885885 (ISSN). Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-3042824528&partnerID=40&md5=1e96f5bbe8ac1d69d765359f1f464169> >.

CORRÊA, M. V.; AGUIRRE, L. A. Identificação não-linear caixa-cinza: uma revisão e novos resultados. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 15, p. 109-126, 2004. ISSN 0103-1759. Disponível em: < http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592004000200001&nrm=iso >.

FORSSELL, U.; LJUNG, L. Closed-loop identification revisited. **Automatica**, v. 35, n. 7, p. 1215-1241, 1999. ISSN 00051098 (ISSN). Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-0033165045&partnerID=40&md5=09f9c23442fe26bd430dfb3984c4d4c4> >.

GARCIA, C. E.; MORARI, M. INTERNAL MODEL CONTROL. 2. DESIGN PROCEDURE FOR MULTIVARIABLE SYSTEMS. **Industrial & Engineering Chemistry, Process Design and Development**, v. 24, n. 2, p. 472-484, 1985. Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-0022045775&partnerID=40&md5=d483dd3b14b84f64b07592978d1c9093> >.

- GEVERS, M.; LJUNG, L. Optimal experiment designs with respect to the intended model application. **Automatica**, v. 22, n. 5, p. 543-554, 9// 1986. ISSN 0005-1098. Disponível em: < <http://www.sciencedirect.com/science/article/pii/0005109886900646> >.
- HJALMARSSON, H. From experiment design to closed-loop control. **Automatica**, v. 41, n. 3, p. 393-438, 3// 2005. ISSN 0005-1098. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0005109804003346> >.
- HÄGGBLÖM, K. E.; BÖLING, J. M. Multimodel identification for control of an ill-conditioned distillation column. **Journal of Process Control**, v. 8, n. 3, p. 209-218, // 1998. ISSN 09591524 (ISSN). Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-0032098901&partnerID=40&md5=25eaa82d123d97b95c8bfcfb4f170e32> >.
- JACOBSEN, E. W.; SKOGESTAD, S. Inconsistencies in dynamic models for ill-conditioned plants: Application to low-order models of distillation columns. **Industrial & Engineering Chemistry Research**, v. 33, n. 3, p. 631-640, // 1994. ISSN 08885885 (ISSN). Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-0028389093&partnerID=40&md5=7ab8ba164f962ad1da69d6349820bb73> >.
- KOUNG, C.-W.; MACGREGOR, J. F. Identification for robust multivariable control: The design of experiments. **Automatica**, v. 30, n. 10, p. 1541-1554, 10// 1994. ISSN 0005-1098. Disponível em: < <http://www.sciencedirect.com/science/article/pii/0005109894900949> >.
- KOUNG, C. W.; MACGREGOR, J. F. Design of identification experiments for robust control. A geometric approach for bivariate processes. **Industrial and Engineering Chemistry Research**, v. 32, n. 8, p. 1658-1666, // 1993. ISSN 08885885 (ISSN). Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-0027641955&partnerID=40&md5=40debbcb01f6e09c57801eac0b93e889> >.
- LI, T.; GEORGAKIS, C. Dynamic input signal design for the identification of constrained systems. **Journal of Process Control**, v. 18, n. 3-4, p. 332-346, 3// 2008. ISSN 0959-1524. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0959152407001266> >.
- LI, Y.; SU, H.; CHU, J. Overview on subspace model identification methods. **Huagong Xuebao/Journal of Chemical Industry and Engineering (China)**, v. 57, n. 3, p. 473-479, 2006. ISSN 04381157 (ISSN). Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-33744776960&partnerID=40&md5=153055d18ee670c0fb7a04dfdc88addb> >.
- LJUNG, L. **System identification : theory for the user**. 2nd. Upper Saddle River, N.J.: Prentice Hall, 1999. xxii, 609 p. ISBN 0136566952 (cloth).
- LJUNG, L.; GLAD, T. **Modeling of dynamic systems**. Englewood Cliffs, N.J.: PTR Prentice Hall, 1994. 361 p. ISBN 0135970970.
- LJUNG, L.; SÖDERSTRÖM, T. **Theory and practice of recursive identification**. Cambridge, Mass.: MIT Press, 1983. xix, 529 p. ISBN 026212095X.
- MICCHI, A.; PANNOCCHIA, G. Comparison of input signals in subspace identification of multivariable ill-conditioned systems. **Journal of Process Control**, v. 18, n. 6, p. 582-593,

2008. ISSN 09591524 (ISSN). Disponível em: <

<http://www.scopus.com/inward/record.url?eid=2-s2.0-43149105987&partnerID=40&md5=a3daa18baf6c863e36145059ba49408e> >.

MISRA, P.; NIKOLAOU, M. Input design for model order determination in subspace identification. **AIChE Journal**, v. 49, n. 8, p. 2124-2132, // 2003. ISSN 00011541 (ISSN).

Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-0041324678&partnerID=40&md5=78b99dfde0a1a9906afcb02bc82cacc3> >.

PRETT, D. M.; GARCÍA, C. E. Chapter 6 - Linear Model Predictive Control. In: PRETT, D. M. e GARCÍA, C. E. (Ed.). **Fundamental Process Control**: Butterworth-Heinemann, 1988. p.107-121. ISBN 978-0-409-90082-8.

QIN, S. J.; BADGWELL, T. A. A survey of industrial model predictive control technology. **Control Engineering Practice**, v. 11, n. 7, p. 733-764, // 2003. ISSN 0967-0661.

Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0967066102001867> >.

SKOGESTAD, S. Dynamics and Control of Distillation Columns: A Tutorial Introduction. **Chemical Engineering Research and Design**, v. 75, n. 6, p. 539-562, // 1997. ISSN 0263-8762. Disponível em: <

<http://www.sciencedirect.com/science/article/pii/S0263876297715739> >.

SKOGESTAD, S.; MORARI, M. The dominant time constant for distillation columns.

Computers & Chemical Engineering, v. 11, n. 6, p. 607-617, // 1987. ISSN 0098-1354.

Disponível em: < <http://www.sciencedirect.com/science/article/pii/0098135487870060> >.

SKOGESTAD, S.; LV-Control of a high-purity distillation column. **Chemical Engineering Science**, v. 43, n. 1, p. 33-48, // 1988. ISSN 0009-2509. Disponível em: <

<http://www.sciencedirect.com/science/article/pii/0009250988871240> >.

STEC, P.; ZHU, Y. Some study on identification of ill-conditioned processes for control. 2001, Arlington, VA. p.1202-1207.

TRIERWEILER, J. O. **A Systematic Approach to Control Structure Design**. Shaker, 1997. ISBN 9783826530319. Disponível em: <

<https://books.google.com.br/books?id=4ct8AgAACAAJ> >.

TULLEKEN, H. J. A. F. Generalized binary noise test-signal concept for improved identification-experiment design. **Automatica**, v. 26, n. 1, p. 37-49, // 1990. ISSN 0005-1098. Disponível em: <

<http://www.sciencedirect.com/science/article/pii/000510989090156C> >.

VERHAEGEN, M. Application of a subspace model identification technique to identify LTI systems operating in closed-loop. **Automatica**, v. 29, n. 4, p. 1027-1040, 1993/07/01 1993. ISSN 0005-1098. Disponível em: <

<http://www.sciencedirect.com/science/article/pii/0005109893901042> >.

CUNHA, V. M. **Planejamento de perturbações para a identificação de modelos dinâmicos**. 2004.

ZHAN, Q.; LI, T.; GEORGAKIS, C. Steady state optimal test signal design for multivariable model based control. **Industrial and Engineering Chemistry Research**, v. 45, n. 25, p. 8514-8527, // 2006. ISSN 08885885 (ISSN). Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-33846045616&partnerID=40&md5=e388447d32df5796493d166055e3fea5> >.

ZHU, Y. Multivariable process identification for MPC: The asymptotic method and its applications. **Journal of Process Control**, v. 8, n. 2, p. 101-115, 1998. ISSN 09591524 (ISSN). Disponível em: < <http://www.scopus.com/inward/record.url?eid=2-s2.0-0032045942&partnerID=40&md5=ac0687652e33cdffc0bc700c15c2c8b0> >.

ZHU, Y.; Chapter 3 - Identification Test Design and Data Pretreatment. In: ZHU, Y. (Ed.). **Multivariable System Identification For Process Control**. Oxford: Pergamon, 2001. p.31-63. ISBN 978-0-08-043985-3.

ZHU, Y.; BUTOYI, F. Case studies on closed-loop identification for MPC. **Control Engineering Practice**, v. 10, n. 4, p. 403-417, 4// 2002. ISSN 0967-0661. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0967066102000072> >.

ZHU, Y.; STEC, P. Simple control-relevant identification test methods for a class of ill-conditioned processes. **Journal of Process Control**, v. 16, n. 10, p. 1113-1120, 12// 2006. ISSN 0959-1524. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0959152406000849> >.

ZHU, Y.; VAN DEN BOSCH, P. P. J. Optimal closed-loop identification test design for internal model control. **Automatica**, v. 36, n. 8, p. 1237-1241, 8// 2000. ISSN 0005-1098. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0005109800000340> >.

ÁLVAREZ, J. D. et al. Perspectives on control-relevant identification through the use of interactive tools. **Control Engineering Practice**, v. 21, n. 2, p. 171-183, 2// 2013. ISSN 0967-0661. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S096706611200202X> >.