

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**


**"IMPLEMENTAÇÃO DE UM
CONTROLADOR GPC ADAPTATIVO
APLICADO A PROCESSOS INDUSTRIAIS"**

**DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE FEDERAL DE SANTA
CATARINA PARA OBTENÇÃO DE GRAU DE MESTRE EM
ENGENHARIA**

MARCOS ANDRÉ SILVEIRA MENEZES

FLORIANÓPOLIS, SETEMBRO DE 1993

**IMPLEMENTAÇÃO DE UM CONTROLADOR ADAPTATIVO
APLICADO A PROCESSOS INDUSTRIAIS**

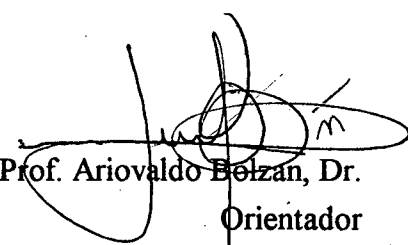


MARCOS ANDRÉ SILVEIRA MENEZES

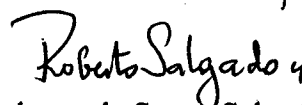
ESTA DISSERTAÇÃO FOI JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE

MESTRE EM ENGENHARIA

ESPECIALIDADE ENGENHARIA ELÉTRICA, ÁREA DE CONCENTRAÇÃO SISTEMAS DE CONTROLE E AUTOMAÇÃO INDUSTRIAL, E APROVADA NA SUA FORMA FINAL PELO PROGRAMA DE PÓS-GRADUAÇÃO.



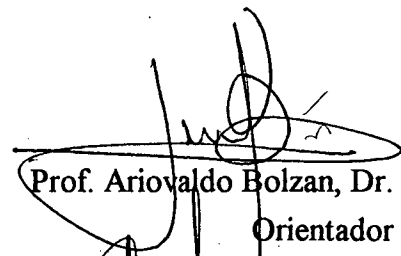
Prof. Ariovaldo Bolzan, Dr.
Orientador




Prof. Roberto de Souza Salgado, Ph.D.

Coordenador do Curso de Pós-graduação em Engenharia Elétrica

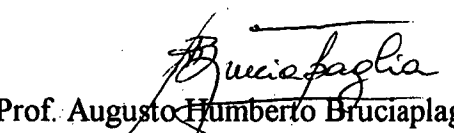
BANCA EXAMINADORA:



Prof. Ariovaldo Bolzan, Dr.
Orientador



Prof. Daniel Juan Pagano, Msc.
Co-orientador



Prof. Augusto Humberto Bruciaplaga, DR. Ing.



Prof. Wagner Carado do Amaral, Dr.

A Almira, minha vó querida.

AGRADECIMENTOS

Ao amigo e Prof. M.Sc. Daniel Juan Pagano pela amizade, dedicação, boa vontade e orientação.

Ao prestativo Prof. Dr. Ariovaldo Bolzan pela orientação.

Ao colega e amigo Márcio Heidi Suguieda, pela solução de problemas computacionais e pela sua extrema boa vontade em ajudar.

Ao colega e amigo Maurício Rocha Maia pelo companheirismo e pelas discussões proveitosas.

A Thereza Christina Teixeira Rocha pelo carinho, apoio e colaboração na edição desta dissertação.

Aos demais colegas: Elieser, Aldebaro, Jáder, Cícero, Márcio Có, Sérgio, Falcondes, Eduardo, Ziller, Marcus Marinho, Iberê, Assis, Vinícius, Arão, Tristão, Romeu, Bazanella, Zorzo, Gisele, Denise, Francisco Damasceno, Yolando, Thair, André, Luís Otávio, Idmilson, Aberides, Alexandre, Busch e Ricardo pela amizade e convívio agradável durante todo o trabalho.

Em especial aos meus pais, Geilza e José, pelo apoio, compreensão, estímulo e carinho durante a realização deste trabalho.

RESUMO

Este trabalho consiste na implementação, teste e avaliação de desempenho de um controlador GPC adaptativo, de propósito geral, para aplicações industriais (em especial para plantas químicas).

Uma das limitações da utilização do controlador GPC está no ajuste de seus parâmetros (horizontes de predição, horizonte de controle, ponderação da ação de controle, polinômios observador e seguidor de modelo) que deve ser realizado por um especialista. Para solucionar este problema, propõe-se, neste trabalho, um sistema de ajuste automático dos parâmetros de projeto do controlador GPC adaptativo.

Vários testes de simulação foram realizados utilizando um ambiente de simulação de controladores adaptativos.

Ensaio experimentais foram conduzidos em uma unidade piloto de laboratório (de estrutura variável e de características não lineares), objetivando o controle de nível de um sistema de tanques acoplados e de um tanque em forma cônica .

Os resultados obtidos, através do simulador e sobre a unidade experimental, permitem avaliar o desempenho do controlador proposto.

ABSTRACT

This work consists in the implementation, test and performance evaluation of an adaptive GPC controller for industrial application (in special for chemicals plants).

Unfortunately, the use of GPC controllers requires the tuning of several parameters, which should be performed by GPC experts. According to this, an automatic tuning system of the GPC parameters is proposed.

Several test simulations to evaluate the performance of the autotuning strategy were performed on a adaptive control software simulator for workstations.

Experimental trials were conducted on a pilot laboratory plant in order to maintain output performance specifications. That plant consists of level control loop of a conical tank which has non-linear characteristics.

Results have allowed the drawing of conclusions about the performance of the autotuning strategy proposed for the adaptive GPC controller.

SUMÁRIO

RESUMO	v
ABSTRACT	vi
CAPÍTULO I - INTRODUÇÃO	01
CAPÍTULO II - GPC: ALGORÍTMO BÁSICO E EXTENSÕES	
2.1 Introdução	04
2.2 Histórico dos controladores preditivos	04
2.3 Descrição do algoritmo GPC	06
2.3.1 Modelo utilizado	06
2.3.1.1 Modelo CARMA	06
2.3.1.2 Modelo CARIMA	07
2.3.2 Preditor de saída	07
2.3.3 Solução recursiva da equação diofantina	10
2.3.4 Lei de controle preditiva	12
2.3.5 Horizonte de controle	17
2.4 Extensões do GPC	18
2.4.1 Ruído Colorido	18
2.4.2 Polinômio seguidor de modelo $P(q^{-1})$	19
2.5 Conclusões	20
CAPÍTULO III - IDENTIFICAÇÃO RECURSIVA DO MODELO	
3.1 Introdução	21
3.2 Mínimos quadrados recursivos estendido	23
3.3 Fatorização U-D	25
3.4 Rastreamento de parâmetros e saturação do estimador	27
3.5 Estimação recursiva da ordem do modelo	29
3.6 Criterio PLS	31
3.7 Enfoque Bayesiano modificado	32
3.8 Critério de Verossimilhança modificado	34
3.9 Conclusões	35

CAPÍTULO IV - SISTEMA DE AJUSTE AUTOMÁTICO DO GPCA

4.1 Introdução	36
4.2 Estrutura do controlador adaptativo implementado	37
4.3 Identificação em malha aberta	38
4.3.1 Cálculo da faixa de ruído	38
4.3.2 Obtenção do atraso de transporte e do tempo de subida	39
4.3.3 Definição do tempo de amostragem	40
4.3.4 Inicialização do estimador	41
4.4 Definição dos horizontes de previsão e da ponderação da ação de controle	42
4.5 Aumento da robustez utilizando as extensões do GPC	43
4.5.1 Análise da Função de Transferência de Malha Fechada (FTMF)	43
4.5.2 Influência do polinômio observador $T(q^{-1})$ sobre a FTMF	46
4.5.3 Influência do polinômio seguidor de modelo $P(q^{-1})$ sobre a FTMF	47
4.5.4 Escolha dos polinômios $T(q^{-1})$ e $P(q^{-1})$	48
4.6 Conclusões	49

CAPÍTULO IV - RESULTADOS DE SIMULAÇÃO

5.1 Introdução	50
5.2 Rastreamento de parâmetros e estabilidade do RELS	51
5.2.1 RELS com zona morta	55
5.2.2 Fator de esquecimento vetorial variável	57
5.2.3 Escolha do índice de adequação	59
5.4 Comportamento do GPCA em função do sistema de ajuste	71
5.3.1 Atuação da ponderação da ação de controle em regime permanente	71
5.3.2 Atraso de transporte variável	73
5.3.3 Processo com fase não-mínima	74
5.3.4 Variações paramétricas	75
5.3.5 Variação estrutural	77
5.4 Conclusões	78

CAPÍTULO VI - APLICAÇÃO EM PLANTA PILOTO

6.1 Introdução	80
6.2 Descrição da planta piloto	80
6.2.1 Sistema de Tanques acoplados	80
6.2.2 Tanque cônico	82
6.3 Controle de nível de tanques acoplados	84
6.4 Controle de nível de tanque de forma cônica	85
6.5 Conclusões	88

CAPÍTULO VII CONCLUSÕES 89**APÊNDICE A - EQUAÇÃO DIOFANTINA** 92**APÊNDICE B - ALGORITMO ITERATIVO DO GPC** 96**BIBLIOGRAFIA** 98

CAPÍTULO I

INTRODUÇÃO

Na sociedade moderna (ou pós-moderna), as questões relacionadas com o Controle, em geral, e com o Controle Automático, em particular, estão assumindo maior importância a cada dia. Sobretudo, considerando que os diversos sistemas, tanto sociais como tecnológicos, estão seguindo um caminho marcado pela complexidade crescente e pela alta interconectabilidade.

Neste modelo de organização da sociedade, a disputa por novos mercados cria a necessidade de modernização das plantas industriais, de forma a aumentar a qualidade e reduzir os custos dos produtos elaborados. Com a modernização, técnicas mais avançadas de controle automático, que utilizam sistemas computacionais, são adotadas a fim de melhorar o desempenho dos sistemas de controle e, portanto, a eficiência na produção.

Nesta série de incessantes mudanças tecnológicas, o processo revolucionário provocado pela tecnologia dos microprocessadores tem influenciado o pensamento dos teóricos de controle e por conseguinte, o progresso da teoria de controle automático.

Atualmente, a velocidade e o tamanho dos computadores associados com o seu baixo custo de produção estão viabilizando a implementação prática de complexos algoritmos de controle (adaptativo, ótimo, robusto, etc...) em situações inconcebíveis uma década atrás. De fato, está se tendendo rapidamente para uma visão da aplicação do controle limitada somente pela própria teoria de controle e pela criatividade do engenheiro de controle [Narendra, 1989].

Nesta perspectiva, a teoria de controle adaptativo vem sendo aplicada cada vez mais com sucesso em plantas cujas características (não-linearidades e parâmetros variantes no tempo) tornam ineficiente ou até inviável a utilização de controladores a parâmetros fixos (ex: clássico controlador PID).

Embora esta teoria tenha surgido nos anos 60, ainda não existe, entre os autores, uma definição consensual do que seja um controlador adaptativo. Dentre as inúmeras abordagens de controle adaptativo existentes na literatura, a STR (Self-Tuning Regulator) têm obtido mais destaque. A estrutura de um controlador do tipo STR é composta por três elementos básicos: um algoritmo de controle, um método de identificação paramétrica e um mecanismo de ajuste dos parâmetros do algoritmo de controle.

Por outro lado, a escolha do algoritmo de controle, para o desenvolvimento de um controlador adaptativo de propósito geral, deve levar em conta, também, que estas plantas, cujas características foram mencionadas acima, podem ainda apresentar atraso de transporte variável. Este fato, muito comum na indústria química, sugere a utilização de um algoritmo de controle preditivo.

Um algoritmo de controle preditivo caracteriza-se por transformar o problema clássico de controle da saída no instante presente, para o controle da predição da saída em um instante futuro [SEBORG 86]. Esta noção de saída predita permite eliminar por completo o efeito do atraso de transporte, pois a predição é feita para um instante maior ou igual ao instante presente mais o atraso de transporte. O algoritmo escolhido para o desenvolvimento do controlador adaptativo preditivo deste trabalho foi o GPC (Generalized Predictive Control). Esta escolha baseou-se na crescente aceitação deste algoritmo em aplicações industriais e no fato de que este incorpora as principais características dos controladores preditivos até então conhecidos.

Objetivando ainda o uso geral do controlador, e sabendo-se que num ambiente industrial nem sempre se dispõe do modelo do processo, decidiu-se associar ao algoritmo de controle uma técnica de identificação recursiva que permite definir "on-line" qual o modelo do processo mais apropriado a cada instante de amostragem, a partir de uma faixa de modelos pré-definidos. Pretende-se com a adoção destas técnicas, rastrear não só mudanças paramétricas na planta, mas mudanças estruturais (ordem).

E por fim, é proposto um sistema de ajuste que baseia-se na identificação em malha aberta do processo e que, a partir do tempo de subida e do atraso de transporte, possibilita a escolha dos parâmetros do controlador e do tempo de amostragem.

A estrutura deste trabalho consiste em:

- No capítulo II é realizado um breve histórico dos controladores preditivos até o surgimento do GPC e o seu algoritmo é descrito de forma detalhada.
- No capítulo III, é descrito o algoritmo de identificação paramétrica que se baseia em uma estrutura competitiva de modelos.
- O sistema de ajuste é descrito no capítulo IV, bem como os mecanismos em que este se fundamenta, como a identificação de malha aberta e a análise da função de transferência de malha fechada.

Vários testes de simulação, para avaliação da performance do mecanismo de identificação e do sistema de ajuste, foram realizados em um simulador de controladores adaptativos para estações de trabalho e os resultados são expostos no capítulo V.

Ensaio experimentais foram conduzidos em uma planta piloto de laboratório para avaliar o desempenho do controlador frente a condições reais de funcionamento. Esta planta consiste em um controle de nível de um sistema de tanques acoplados e de um tanque de forma cônica com característica fortemente não linear. Os resultados obtidos são apresentados e discutidos no capítulo VI

Finalmente, no capítulo VII, são apresentados as conclusões e as perspectivas deste trabalho.

CAPÍTULO II

GPC - ALGORITMO BÁSICO E EXTENSÕES

2.1 Introdução

Neste capítulo é apresentado um breve histórico dos controladores preditivos até o surgimento do GPC. Em seguida é realizada uma descrição do desenvolvimento matemático que leva à obtenção do algoritmo básico do GPC. Concluindo este capítulo são introduzidos as principais extensões do algoritmo básico que permitem aumentar a robustez e especificar os objetivos de controle.

2.2 Histórico dos controladores preditivos

Os estudos relativos ao controle preditivo iniciaram-se nos anos 60. Smith foi o primeiro a propor um controlador baseado na utilização de um modelo de predição e de uma lei de controle clássica [Smith 59].

Uma das mais importantes contribuições ao estudo do controle preditivo é o algoritmo de controle a variância mínima [ASTRÖM 73]. Este controlador é baseado na predição a d passos a frente, onde d é o número de amostragens correspondente ao atraso de transporte do sistema. O controlador é, então, sintetizado a partir da minimização de um critério quadrático, composto pelo erro de predição em relação à referência no instante $t+d$, e o valor da ação de controle. O inconveniente maior do controle a variância mínima é a necessidade de se conhecer o valor exato do atraso de transporte (que não é tão evidente na prática) e de se dispor de um modelo discreto de predição de fase mínima (inversa estável). Porém, sabe-se que a discretização de um sistema contínuo de fase mínima comumente leva a um modelo discreto de fase não-mínima [CLARKE 84]. Uma solução encontrada para o problema é a incorporação de um critério de ponderação do termo de controle [CLARKE 75]. Este tipo de controle é conhecido por variância mínima generalizada "GMV".

Dois outros importantes métodos foram introduzidos posteriormente: o posicionamento de pólos [ASTROM 80] e o conceito de horizonte estendido [RICHLET 78]. O controle por posicionamento de pólos não requer conhecimento do atraso de transporte, nem um modelo de fase mínima. Efetivamente, é aumentada a ordem do modelo (numerador) para eliminar a incerteza no valor do atraso de transporte. O problema inerente a este método é a falta de

robustez numérica da solução da equação de Bezout, ou diofantina. Isto ocorre quando a ordem do denominador escolhida leva a uma singularidade na equação (presença de fatores comuns).

Finalmente, a noção de controle preditivo estendido, ou também chamado controle preditivo de longo alcance "LRPC", aparece como uma solução possível pois ele utiliza um conjunto de predições efetuadas em um horizonte superior ao atraso de transporte. O fato de se efetuar predições mais longe do comportamento do sistema, permite obter ações de controle mais suaves, melhorando, então, a regularidade de funcionamento do processo.

Os métodos se diferenciam, portanto, pela maneira em que é efetuada a predição, pelo horizonte que se deseja fazer a predição e pela expressão do critério a minimizar.

Função de custo típica à minimizar:

$$\text{-Controle preditivo: } J = E\{y(t+N) - y_{sp}\}$$

$$\text{-Controle preditivo estendido: } J = \sum_1^N E\{y(t+j) - y_{sp}(t+j)\}$$

onde y e y_{sp} são a saída e o "set-point" no instante t , $y(t+j)$ e $y_{sp}(t+j)$, a saída e o "set-point" no instante $t+j$ e N é o horizonte de predição.

O conceito de horizonte estendido foi introduzido por Richalet [Richalet 78]. Desenvolvido a partir de um procedimento heurístico, o controle heurístico com modelo de predição ou "MPHC" (Model Predictive Heuristic Control) ou "IDCOM" (IDentification-COMmand), é um método baseado na modelagem do processo pela resposta ao impulso, acoplada à síntese de uma trajetória de referência, representando o comportamento desejado em malha fechada, e o cálculo de um vetor de ações de controle.

Cutler, paralelamente a Richalet, desenvolveu o "DMC" (Dynamic Matrix Control) [CUTLER 80], que adota uma estratégia semelhante ao "MPHC", no entanto, a representação interna do processo utiliza a resposta ao degrau. Uma contribuição importante introduzida por esta técnica é o emprego do chamado "horizonte de controle", que corresponde a um valor de horizonte a partir do qual a ação de controle permanece constante.

Mais recentemente, Clarke et al introduziram o controle preditivo generalizado "GPC" (Generalized Predictive Control) [CLARKE 87], que é um membro da família dos controladores a horizonte estendido, e uma generalização dos algoritmos citados anteriormente.

O modelo linearizado utilizado no GPC é o CARIMA (Controlled Auto-Regressive Integrated Moving-Average), que incorpora a ação integral responsável pela eliminação do "offset".

2.3 DESCRIÇÃO DO ALGORITMO GPC

O algoritmo do GPC, assim como todos os controladores preditivos, consiste em três partes fundamentais: um modelo linearizado do processo, uma equação de predição da saída gerada a partir deste modelo e a lei de controle preditiva que visa minimizar uma dada função de custo.

2.3.1 Modelo utilizado

Um modelo realista para as aplicações práticas deve representar o determinismo (variação na saída correspondente a uma variação na entrada) e as perturbações estocásticas [ASTRÖM 84]. O modelo utilizado para representar o processo no algoritmo do GPC é o CARIMA, derivação do CARMA, que é descrito a seguir.

2.3.1.1 Modelo CARMA

Seja o modelo:

$$A(q^{-1}).y(t) = B(q^{-1}).u(t-1) + x(t) \quad (2.1)$$

onde $A(q^{-1}) = 1 + a_1.q^{-1} + \dots + a_{na}.q^{-na}$ (2.2)

$$B(q^{-1}) = b_0.q^{-d} + \dots + b_{nb}.q^{-(nb+d)} \quad (2.3)$$

e $x(t)$ é uma perturbação estocástica e d o atraso de transporte. Com $x(t)$ dado por:

$$x(t) = C(q^{-1}).\xi(t) \quad (2.4)$$

onde $\xi(t)$ é um sinal completamente não correlacionado de média nula, e de distribuição de amplitude gaussiana (ruído branco). E:

$$C(q^{-1}) = 1 + c_1.q^{-1} + \dots + c_{nc}.q^{-nc} \quad (2.5)$$

é o polinômio do ruído colorido com todas as suas raízes no círculo unitário.

Assim as flutuações estocásticas são modeladas pelo ruído colorido $n(t)$, que corresponde ao ruído branco filtrado.

$$n(t) = \frac{C(q^{-1})}{A(q^{-1})} \xi(t) \quad (2.6)$$

2.3.1.2 Modelo CARIMA

Apesar de levar em consideração, em seu modelo interno, as perturbações, um algoritmo de controle baseado na representação CARMA, não apresenta ação integral. Surgiu, então, uma forma de representação que leva em conta as perturbações e que possui ação integral inerente. Chamada de CARIMA (Controlled Auto-Regressive Integrated Moving-Average), esta representação é semelhante à anterior com exceção da introdução do operador $\Delta = 1 - q^{-1}$, [CLARKE 87].

Assim a perturbação é redefinida:

$$x(t) = \frac{C(q^{-1})}{\Delta} \xi(t) \quad (2.7)$$

Por simplicidade no desenvolvimento, considera-se, inicialmente, $C(q^{-1})=1$. Então, o modelo torna-se:

$$A(q^{-1}) \cdot y(t) = B(q^{-1}) \cdot u(t-1) + \frac{\xi(t)}{\Delta} \quad (2.8)$$

2.3.2 Preditor de saída

O preditor de saída consiste em uma equação que baseada no modelo linearizado do processo exprime o provável comportamento da sua saída nos instantes futuros.

Para derivar o preditor deve-se considerar o modelo do processo dado pela eq.(2.8). Dividindo toda a equação por $A(q^{-1})$, obtém-se:

$$y(t) = \frac{B(q^{-1})}{A(q^{-1})} u(t-1) + \frac{\xi(t)}{\Delta \cdot A(q^{-1})} \quad (2.9)$$

Realizando a divisão euclidiana $\frac{1}{\Delta \cdot A(q^{-1})}$, tem-se:

$$\frac{1}{\Delta \cdot A(q^{-1})} = E_j + \frac{q^{-j} \cdot F_j}{\Delta \cdot A(q^{-1})} \quad (2.10)$$

onde: E_j é o quociente da divisão

$$\frac{q^{-j} \cdot F_j}{\Delta \cdot A(q^{-1})} \text{ é o resto.} \quad (2.11)$$

Os polinômios E_j e F_j são únicos, dados $A(q^{-1})$ e o intervalo de predição j e valem:

$$E_j(q^{-1}) = e_0 + e_1 \cdot q^{-1} + \dots + e_{j-1} \cdot q^{-(j-1)} \quad (2.12)$$

$$F_j(q^{-1}) = f_{0j} + \dots + f_{naj} \cdot q^{-na} \quad (2.13)$$

A partir da eq. (2.10) pode-se obter as seguintes equações:

$$\frac{1}{A(q^{-1}) \cdot \Delta} = \frac{E_j}{1 - q^{-j} \cdot F_j} \quad (2.14)$$

$$\frac{1}{A(q^{-1})} = \frac{E_j \cdot \Delta}{1 - q^{-j} \cdot F_j} \quad (2.15)$$

$$1 = E_j \cdot \Delta \cdot A(q^{-1}) + q^{-j} \cdot F_j \quad (2.16)$$

A equação (2.16) expressa na forma de identidade polinomial a equação (2.10). Esta, é chamada de equação diofantina (vide apêndice A).

Substituindo as eqs. (2.14) e (2.15) em (2.9), obtem-se:

$$y(t) = \frac{1}{1 - q^{-j} \cdot F_j} E_j \cdot B \cdot \Delta \cdot u(t-1) + \frac{1}{1 - q^{-j} \cdot F_j} E_j \cdot \xi(t) \quad (2.17)$$

ou
$$y(t) \cdot (1 - q^{-j} \cdot F_j) = E_j \cdot B \cdot \Delta \cdot u(t-1) + E_j \cdot \xi(t) \quad (2.18)$$

Obtendo-se finalmente a equação de predição de saída:

$$y(t+j) = E_j \cdot B \cdot \Delta u(t+j-1) + E_j \cdot \xi(t+j) + F_j \cdot y(t) \quad (2.19)$$

Como o grau de E_j é $j-1$, as componentes do ruído estão todas no futuro, e como também é assumido que o controle é realizado em malha aberta, pode-se ignorá-las. Assim, conhecendo-se o valor da saída até o instante t e dada $u(t+i)$ para $i > 1$, tem-se:

$$y_p(t+j|t) = G_j \cdot \Delta u(t+j-1) + F_j \cdot y(t) \quad (2.20)$$

onde $y_p(t+j|t)$ representa o valor estimado de y no instante $t+j$ com os dados obtidos até o instante t e:

$$G_j(q^{-1}) = E_j \cdot B \quad (2.21)$$

ou:
$$G_j(q^{-1}) = e_0 \cdot b_0 \cdot q^{-d} + (b_0 \cdot e_1 + b_1 \cdot e_0) \cdot q^{-(d+1)} + \dots \quad (2.22)$$

$$G_j(q^{-1}) = g_0 \cdot q^{-d} + g_1 \cdot q^{-(d+1)} + \dots \quad (2.23)$$

Nota-se que o cálculo de $y_p(t+j|t)$ para $j > d$, depende de valores futuros da ação de controle pois o termo de menor grau de $G_j(q^{-1})$ é $g_0 \cdot q^{-d}$. Ou seja:

$$y_p(t+j|t) = g_0 \cdot \Delta q^{-d} \cdot u(t+j-1) + g_1 \cdot q^{-(d+1)} \cdot \Delta u(t+j-1) + \dots + F_j \cdot y(t) \quad (2.24)$$

$$y_p(t+j|t) = g_0 \cdot \Delta u(t+j-d-1) + g_1 \cdot \Delta u(t+j-d-2) + \dots + F_j \cdot y(t) \quad (2.25)$$

Para $j > d+1$ tem-se $j-1-d=k > 0$, assim:

$$y_p(t+j|t) = g_0 \cdot \Delta u(t+k) + g_1 \cdot \Delta u(t+j+k+1) + \dots + F_j \cdot y(t)$$

Portanto, para $k > 0$, ou seja $j > d+1$, $y_p(t+j|t)$ dependerá de valores futuros da entrada. Para resolver este problema, introduz-se o conceito de "horizonte de controle" (NU), [CUTLER 80], que corresponde a assumir que após o instante de tempo NU, a ação de controle mantém-se constante.

$$u(t+j) = u(t+NU), \quad j > NU \quad (2.26)$$

ou $\Delta.u(t+j) = 0, \quad j > NU \quad (2.27)$

2.3.3 Solução recursiva da equação diofantina

Observa-se que no desenvolvimento do preditor j-passos surge a necessidade de se resolver uma equação diofantina (eq. 2.16). Uma solução possível é a recursiva, que pode ser obtida equacionando-se as potências iguais da equação (2.9), ou de uma forma computacionalmente mais simples, como é sugerido por Clarke [CLARKE 87].

A solução sugerida por Clarke baseia-se no cálculo de E_{j+1} e F_{j+1} a partir de E_j e F_j . Seja, então, as seguintes identidades diophantina do passo j e $j+1$:

$$1 = E_j \cdot \tilde{A} + q^{-j} \cdot F_j \quad (2.28)$$

$$1 = E_{j+1} \cdot \tilde{A} + q^{-(j+1)} \cdot F_{j+1} \quad (2.29)$$

com $\tilde{A} = A \cdot \Delta. \quad (2.30)$

Subtraindo a equação (2.29) da (2.28):

$$(E_{j+1} - E_j) \cdot \tilde{A} + q^{-j} \cdot (q^{-1} \cdot F_{j+1} - F_j) = 0 \quad (2.31)$$

como o polinômio $(E_{j+1} - E_j)$ é de grau j , reescreve-se:

$$(E_{j+1} - E_j) = R + r_j \cdot q^{-j} \quad (2.32)$$

onde R é um polinômio de grau $j-1$ dado por:

$$R(q^{-1}) = r_0 + \dots + r_{j-1} \cdot q^{-(j-1)} \quad (2.33)$$

Substituindo a equação (2.32) na (2.31), tem-se:

$$\tilde{A} \cdot R + q^{-j} (\tilde{A} \cdot r_j + q^{-1} \cdot F_{j+1} - F_j) = 0 \quad (2.34)$$

Da equação anterior tem-se que o grau do 1º termo ($na+j$) é menor que o do 2º termo ($na+j+1$), portanto:

$$R=0 \quad (2.35)$$

e

$$F_{j+1} = q \cdot (F_{j+1} - \tilde{A} \cdot r_j) = 0 \quad (2.36)$$

Como $\tilde{a}_0 = a_0 = 1$, tem-se:

$$r_1 = f_{0i} \quad (2.37)$$

$$f_{1+i} = f_{i+1} - \tilde{a}_{1+i} \cdot r_i, \quad i = 0 \dots na - 1 \quad (2.38)$$

$$f_{na+i} = -\tilde{a}_{na} \cdot r_i \quad (2.39)$$

Reescrevendo (2.32):

$$E_{j+1} = E_j + r_j \cdot q^{-j} \quad (2.40)$$

Para inicializar as iterações, faz-se $j=1$ em (2.28):

$$1 = E_1 \cdot \tilde{A} + q^{-1} \cdot F_1 \quad (2.41)$$

Mas o grau de E_j é 0, então $E_j=1$. E como $\tilde{a}_0=1$, tem-se:

$$F_1 = q(1 - \tilde{A}) \quad (2.42)$$

2.3.4 Lei de controle preditiva

De posse dos valores preditos de saída, o próximo passo é a obtenção da ação de controle.

O objetivo da lei de controle é levar a saída predita para perto de uma trajetória de referência disponível como ilustrado na fig 2.1 (sequência de futuros set-points $y_{sp}(t+j)$; $j=1..N_2$). Esta trajetória pode ser obtida, recursivamente, utilizando-se um modelo simples de 1º ordem, inicializando-se com a saída real do processo $y(t)$ no tempo considerado:

$$y_{sp}(t) = y(t) \quad ; j = 1.. \quad (2.43)$$

$$y_{sp}(t+j) = \alpha \cdot y_{sp}(t+j-1) + (1-\alpha) \cdot y_{sp} \quad (2.44)$$




Fig 2.1 Set-point, controle e saídas no GPC

com y_{sp} sendo o valor real do set-point, $y_{sp}(t+j)$ o set-point filtrado e α um parâmetro de projeto que varia entre 0 e 1. Para transições lentas do valor corrente de saída, $y(t)$, para o valor real do set-point, y_{sp} , usa-se α próximo de 1 e para transições bruscas, α igual a zero. O objetivo da lei de controle é conduzir a saída futura da planta na direção do "set-point" usando a menor energia

possível. Isto é feito utilizando a abordagem do "horizonte retrocedido" para cada amostragem, ou seja:

1. Calcula-se a sequência futura do setpoint $y_{sp}(t+j)$
2. Gera-se a partir da eq.(2.8) as saídas preditas $y_p(t+j|t)$ com os erros correspondentes de predição $e(t+j)=y_{sp}(t+j) - y_p(t+j|t)$
3. Uma função quadrática de custo (equação 2.45) dos futuros erros e da ação de controle deve ser minimizada assumindo a existência de um horizonte de controle, para fornecer uma sequência de futuras ações de controle $u(t+j)$
4. O primeiro elemento de $u(t)$ é implementado e os vetores de dados são deslocados para permitir os cálculos na próxima amostragem.

Introduzindo uma função de custo da forma:

$$J(N_1, N_2) = \sum_{N_1}^{N_2} [y(t+j) - y_{sp}(t+j)]^2 + \lambda(j) \cdot [\Delta \cdot u(t+j-1)]^2 \quad (2.45)$$

onde: N_1 é o horizonte mínimo de predição
 N_2 é o horizonte máximo de predição
 $\lambda(j)$ é a sequência de ponderação da ação de controle

Se o atraso de transporte d for conhecido, N_1 pode assumir o seu valor, ou mais, para minimizar o tempo de computação. N_2 é escolhido de forma a englobar toda a resposta afetada significativamente pela entrada atual, devendo ser maior que o grau de $B(q^{-1})$. Usualmente, usa-se valores próximos ao tempo de subida da planta. E a sequência de ponderação $\lambda(j)$ é responsável pela limitação da ação de controle, com valor inicial nulo (não penaliza a ação de controle), podendo ser aumentada se for necessário um maior amortecimento. As saídas futuras são geradas pela eq.(2.19):

$$\begin{aligned}
 y(t+1) &= G_1 \cdot \Delta u(t) + F_1 \cdot y(t) \\
 y(t+2) &= G_2 \cdot \Delta u(t+1) + F_2 \cdot y(t) \\
 &\vdots \\
 &\vdots \\
 &\vdots \\
 y(t+N_2) &= G_{N_2} \cdot \Delta u(t+N_2) + F_{N_2} \cdot y(t)
 \end{aligned}$$

(2.46)

Rearrmando as equações anteriores :

$$\begin{aligned}
 y(t+1) &= g_{10} \cdot \Delta u(t) + [G_1 - g_{10}] \cdot \Delta u(t) + F_1 \cdot y(t) \\
 y(t+2) &= g_{21} \cdot \Delta u(t) + g_{20} \cdot \Delta u(t+1) + \\
 &\quad + q \cdot [G_2 - q^{-1} \cdot g_{21} - g_{20}] \cdot \Delta u(t) + F_2 \cdot y(t) \\
 &\vdots \\
 &\vdots \\
 &\vdots
 \end{aligned}$$

(2.47)

$$\begin{aligned}
 y(t+N_2) &= g_{N_2, N_2-1} \cdot \Delta u(t) + \dots + g_{N_2, 0} \cdot \Delta u(t+N_2) \\
 &\quad + q^{N-1} \cdot [G_{N_2} - q^{-(N-1)} \cdot g_{N_2, N_2-1} - \dots - g_{N_2, 0}] \cdot \Delta u(t) \\
 &\quad + F_{N_2} \cdot y(t)
 \end{aligned}$$

$$\text{Com } G_i = g_{i0} + g_{i1} \cdot q^{-1} + \dots + g_{i, (nb+i-1)} \cdot q^{-(nb+i-1)} \quad (2.48)$$

Lembrando que os primeiros j -termos de G_j são os parâmetros da resposta ao degrau ($g_{ij}=g_j, j=0, 1, \dots, i$), independentemente do polinômio particular G_j .

Definindo $f(t+j)$ como sendo as componentes de $y(t+j)$ referentes à resposta livre do sistema, assumindo que $u(k)=0$, qualquer que seja $k>0$ no instante de tempo t . Ou seja:

$$f(t+1) = [G_1 - g_{10}] \cdot \Delta u(t) + F_1 \cdot y(t)$$

$$f(t+2) = q \cdot [G_2 - q^{-1} \cdot g_{21} - g_{20}] \cdot \Delta u(t) + F_2 \cdot y(t)$$

etc

(2.49)

Pode-se escrever a equação (2.14) na forma vetorial:

$$Y_p = G \cdot \tilde{u} + f \tag{2.50}$$

com $Y_p = [y_p(t+1), y_p(t+2), \dots, y_p(t+N_2)]^T$ (2.51)

$$\tilde{u} = [\Delta u(t), \Delta u(t+1), \dots, \Delta u(t+N_2-1)]^T \tag{2.52}$$

$$f = [f(t+1), f(t+2), \dots, f(t+N_2)]^T \tag{2.53}$$

A matriz G é, então, triangular inferior de dimensão $N_2 \times N_2$:

$$G = \begin{bmatrix} g_0 & 0 & \dots & 0 \\ g_1 & g_0 & \dots & 0 \\ \vdots & \vdots & & \vdots \\ g_{N_2} & g_{N_2-2} & \dots & g_0 \end{bmatrix}_{N_2 \times N_2} \tag{2.54}$$

Observa-se que se a planta tiver um tempo morto $d > 1$, as primeiras $d-1$ linhas serão nulas para que os primeiros $d-1$ elementos de \tilde{u} não exerçam influência no cálculo do vetor da predição da saída Y_p na eq. (1.14).

Considerando o sinal de referência na forma vetorial:

$$Y_{sp} = [y_{sp}(t+1), y_{sp}(t+2), \dots, y_{sp}(t+N_2)]^T \quad (2.55)$$

A função de custo torna-se:

$$J_1 = (Y - Y_{sp})^T (Y - Y_{sp}) + \lambda \cdot \tilde{u} \cdot \tilde{u}^T \quad (2.56)$$

A minimização da função de custo J_1 , desconsiderando restrições nas ações de controle futuras, resulta no vetor de incremento da ação de controle.

$$\frac{\partial(J_1)}{\partial(\tilde{u})} = 0 \quad (2.57)$$

$$2 \cdot (G^T) \cdot (G \cdot \tilde{u} + f - Y_{sp}) + 2 \cdot \lambda(1) \cdot \tilde{u} = 0 \quad (2.58)$$

$$G^T \cdot G \cdot \tilde{u} + \lambda \cdot \tilde{u} = G^T \cdot (Y_{sp} - f) \quad (2.59)$$

$$\tilde{u} = (G^T \cdot G + \lambda \cdot I)^{-1} \cdot G^T \cdot (Y_{sp} - f) \quad (2.60)$$

Mas o primeiro elemento de \tilde{u} é $\Delta u(t)$, daí a ação de controle corrente vale:

$$u(t) = u(t-1) + Lg(Y_{sp} - f) \quad (2.61)$$

onde Lg é a primeira linha de $(G^T \cdot G + \lambda \cdot I)^{-1} \cdot G^T$.

A equação (2.16) para $q=1$ vale:

$$1 = E_j(1) \cdot A(1) \cdot D(1) + F_j(1) \quad (2.62)$$

e como $\Delta(1)=0$, então $F_j(1)=1$, assim:

$$f(t+j) = F_j \cdot y(t) \quad (2.63)$$

cujo valor médio é igual ao valor médio de $y(t)$. Tomando a equação (2.16) e multiplicando por $y(t)$, tem-se:

$$F_j(q^{-1}).y(t) = (1 - E_j(q^{-1}).A.\Delta).y(t) \quad (2.64)$$

$$F_j(q^{-1}).y(t) = y(t) - E_j(q^{-1}).A.\Delta.y(t) \quad (2.65)$$

Considerando que $y(t)=cte$, tem-se $\Delta.y(t)=0$, o que leva a:

$$y_p = F_j(q^{-1}).y(t) = y(t) = cte \quad (2.66)$$

assegurando, assim, a eliminação do "off-set" pela ação integral.

2.3.5 Horizonte de controle (NU)

O cálculo da equação (2.62) envolve a inversão de uma matriz $N_2 \times N_2$. Para reduzir o esforço computacional, é possível introduzir restrições às futuras ações de controle, assumindo que os incrementos de controle são zero depois de $N_u < N_2$ passos, onde NU é chamado "horizonte de controle" [Cutler 80]. Assim:

$$\Delta.u(t + j - 1) = 0, \quad j > NU \quad (2.67)$$

isto significa que a ação de controle é assumida como constante após N_u passos. Desta forma, obtem-se:

$$Y_p = G_1.u + f \quad (2.68)$$

onde

$$G = \begin{bmatrix} g_0 & 0 & \dots & 0 \\ g_1 & g_0 & \dots & 0 \\ \vdots & \vdots & & \vdots \\ g_{N_2-2} & g_{N_2-3} & \dots & g_0 \\ g_{N_2} & g_{N_2-2} & \dots & g_{N_2-N_u} \end{bmatrix}_{N_2 \times N_u} \quad (2.69)$$

A lei de controle muda para:

$$\tilde{u} = (G_1^T \cdot G_1 + \lambda \cdot I)^{-1} \cdot G_1^T \cdot (Y_R - f) \quad (2.70)$$

A matriz para ser invertida é agora de ordem $NU \times NU$. O valor NU unitário normalmente fornece bons resultados para processos simples (estável em malha aberta e fase não-mínima). Para sistemas mais complexos NU deve ser pelo menos igual ao número de polos instáveis ou pouco amortecidos.

2.4 Extensões do GPC

O algoritmo básico do GPC foi descrito na seção anterior. No entanto, este pode ter o seu desempenho melhorado por meio de duas modificações: a introdução de um polinômio observador para representar o ruído colorido e a utilização de um polinômio seguidor de modelo. Estas modificações são descritas em seguida.

2.4.1 Ruído colorido $C(q^{-1})$

A maioria dos processos industriais apresenta mais de uma perturbação ou ruído atuando sobre ele, então, um modelo mais real das perturbações $x(t)$ pode ser escrito:

$$x(t) = C_1 \cdot x_1(t) + \dots + C_n \cdot x_n(t) \quad (2.71)$$

As componentes do ruído podem ser combinadas numa sequência simples $\frac{C(q^{-1}) \cdot x(t)}{A(q^{-1}) \cdot \Delta}$, onde $C(q^{-1})$ tem todas as suas raízes no círculo unitário, desde que, pelo menos um elemento do ruído ($x_i(t)$) tenha média não nula e seja excitado persistentemente. Observa-se que para $C(q^{-1})$ ser invariante no tempo, a variância de cada componente do ruído deve permanecer constante. Como isto raramente ocorre em processos industriais, uma identificação com sucesso de $C(q^{-1})$ é pouco provável. Assim, um polinômio de projeto $T(q^{-1})$ pode ser utilizado, no lugar do polinômio $C(q^{-1})$, o que torna as predições não ótimas, mas que proporciona maior robustez frente às dinâmicas não modeladas.

Geralmente $T(q^{-1})$ pode ser tomado como um polinômio de 1ª ordem, o que implica em $\frac{1}{T(q^{-1})}$ ser um filtro passa-baixa. Tomando a eq. (2.1) e introduzindo $T(q^{-1})$:

$$A(q^{-1}).y(t) = B(q^{-1}).u(t-1) + \frac{T(q^{-1})}{\Delta} \xi(t) \quad (2.72)$$

que pode ser reescrita como:

$$A(q^{-1}).y^f(t) = B(q^{-1}).u^f(t-1) + \xi(t) \quad (2.73)$$

onde :

$$y^f(t) = \frac{\Delta}{T(q^{-1})} y(t) \quad (2.74)$$

$$u^f(t) = \frac{\Delta}{T(q^{-1})} u(t). \quad (2.75)$$

Os sinais $w^f(t)$ e $y^f(t)$ são filtrados por funções de transferência passa-faixa para eliminar as componentes de alta frequência e o nível dc.

O projeto de $T(q^{-1})$ para o caso adaptativo, onde $T(q^{-1})$ funciona como filtro para o estimador e como polinômio observador para a lei de controle, é descrito no capítulo III.

2.4.2 Polinômio seguidor de modelo $P(q^{-1})$

Algumas abordagens de controladores auto-ajustáveis utilizam uma saída auxiliar $\psi(t)$ definida por:

$$\psi(t) = P(q^{-1}).y(t) \quad (2.76)$$

onde $P(q^{-1})$ é uma função de transferência de ganho unitário escolhida pelo usuário, objetivando alcançar uma determinada especificação de controle.

Para se introduzir o polinômio $P(q^{-1})$ no algoritmo do GPC deve-se considerar a planta aumentada:

$$A(q^{-1}) \cdot P(q^{-1}) \cdot y(t) = B(q^{-1}) \cdot P(q^{-1}) \cdot u(t-1) + \frac{T(q^{-1})}{\Delta} x(t) \quad (2.77)$$

ou reescrevendo:

$$A(q^{-1}) \cdot \psi(t) = B(q^{-1}) \cdot v(t-1) + \frac{T(q^{-1})}{\Delta} x(t) \quad (2.78)$$

onde

$$\psi(t) = \frac{\Delta \cdot P(q^{-1})}{T(q^{-1})} y(t) \quad (2.79)$$

$$v(t) = \frac{\Delta \cdot P(q^{-1})}{T(q^{-1})} u(t) \quad (2.80)$$

2.5 Conclusões

Neste capítulo, o GPC foi situado no contexto histórico dos controladores preditivos e o seu algoritmo foi descrito matematicamente. Partindo de um modelo linearizado (CARIMA) da planta obteve-se a equação de predição da saída. De posse desta, chegou-se à lei de controle preditiva a partir da minimização de uma função de custo.

Extensões do algoritmo básico do GPC que permitem o aumento da robustez e a especificação de objetivos de controle foram apresentadas.

No capítulo seguinte é introduzido o conceito de controle adaptativo, junto com uma técnica de identificação recursiva "on-line" dos parâmetros do modelo do processo. Esta técnica consiste na utilização de vários algoritmos de estimação recursiva, operando em paralelo, associado com um critério de seleção do modelo mais adequado, a ser utilizado pelo controlador.

CAPÍTULO III

IDENTIFICAÇÃO RECURSIVA DO MODELO

3.1 Introdução

No capítulo anterior, verificou-se que o algoritmo de controle GPC baseia-se fundamentalmente no modelo do sistema a controlar. Surge, então a primeira dificuldade quando da aplicação do GPC no controle de sistemas cujos parâmetros são desconhecidos ou incertos.

Para solucionar este problema, combina-se o algoritmo de controle com uma técnica "on-line" de estimação paramétrica. Este conjunto traduz a idéia básica de um controlador adaptativo.

Muitas abordagens de controle adaptativo, aparentemente diferentes, são propostas na literatura. Dentre elas, destacam-se duas: controle adaptativo por modelo de referência (MRAC) e reguladores auto-ajustáveis (STR). Estas técnicas fundamentam-se no Princípio da Equivalência à Certeza, que consiste na utilização, a cada amostragem, do modelo estimado como se fosse o modelo verdadeiro.

No controle adaptativo por modelo de referência impõe-se ao sistema um comportamento dado por um modelo de referência como pode ser visto na figura 3.1.

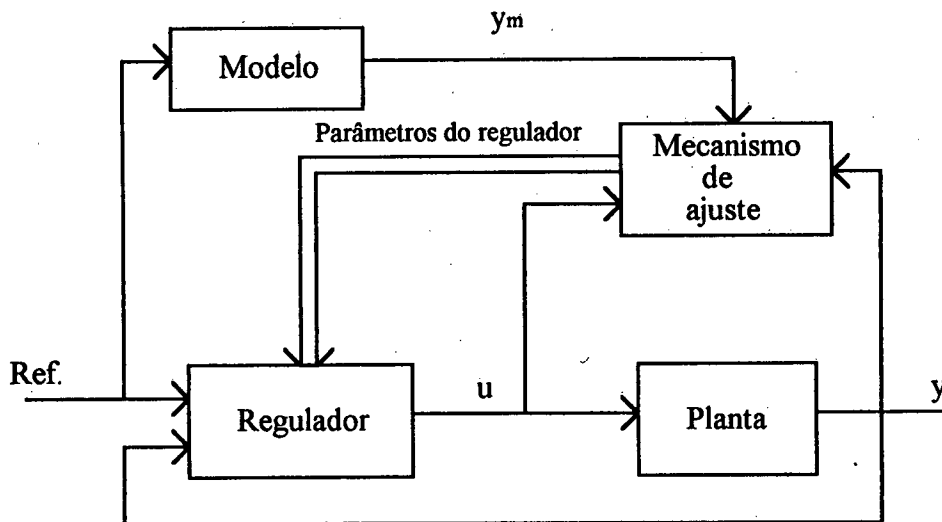


Figura 3.1 Diagrama em blocos de um controlador adaptativo por modelo de referência (MRAC)

Para o regulador auto-ajustável, o projeto do controlador é realizado a partir de um modelo estimado (vide fig 3.2). Esta abordagem além de ser a mais utilizada, apresenta, também, uma estrutura mais apropriada para o desenvolvimento de um GPC adaptativo (GPCA).

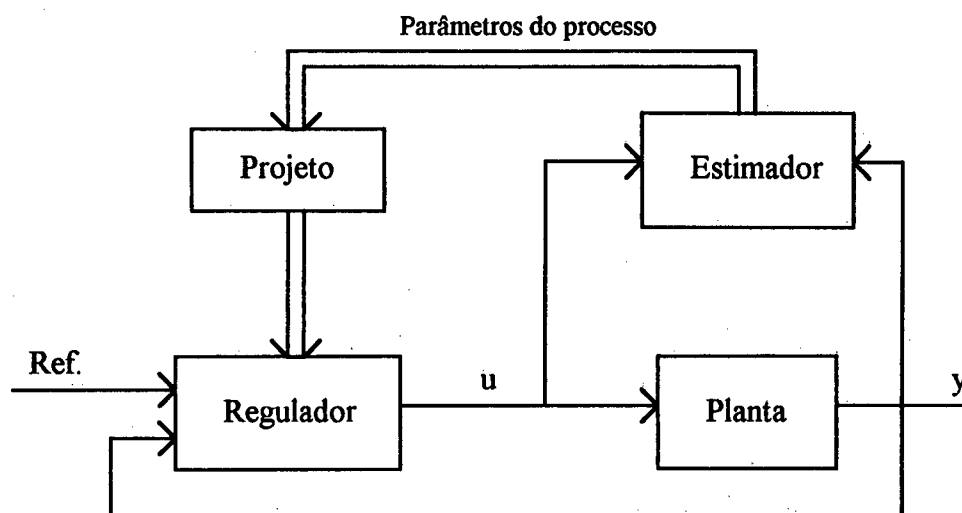


Figura 3.2 Diagrama em blocos de um regulador auto-ajustável

Definida a abordagem a ser utilizada, necessita-se decidir qual a técnica de identificação a ser empregada. As técnicas com melhor desempenho segundo a literatura [SÖDERSTROM 78], [ISERMANN 74] e [LANDAU 79] são: em primeiro lugar o RML (Recursive Maximum Likelihood) ou Máxima Verossimilhança, seguido de perto pelo RELS (Recursive Extended Least Square) ou Mínimos Quadrados Estendido Recursivo. Estas técnicas, além de demonstrarem boa convergência, não apresentam "bias" quando da presença de ruído (presença de "off-set"). Optou-se pela utilização do RELS devido ao menor esforço computacional necessário à sua implementação e por ser esta técnica mais difundida e, tradicionalmente, mais aceita.

Um dos requisitos para se utilizar o RELS é o conhecimento a priori da ordem do modelo a ser pesquisado, o que nem sempre é disponível. A superestimação da ordem do modelo introduz no algoritmo de controle um carga adicional indesejável e a subestimação do modelo leva à deteriorização da performance do GPC e até, em alguns casos, à instabilidade. Assim, tendo em vista o desenvolvimento de um controlador de propósito geral, faz-se necessário a introdução de um mecanismo no algoritmo de controle, que indique "on-line" ao estimador, a ordem do modelo a ser utilizado. Foi adotado para solução deste problema uma estrutura competitiva de modelos, a qual se baseia em um critério de medida de adequação dos modelos pesquisados. Neste trabalho foram estudados três critérios: o PLS (Predictive Least Square), o critério de verossimilhança modificado e o enfoque Bayesiano modificado [MEDEIROS 90]. Neste capítulo os três critérios são apresentados e no capítulo V, resultados de simulação permitem inferir conclusões sobre a escolha do mais apropriado para o desenvolvimento do GPCA.

3.2 Mínimos quadrados estendido recursivo (RELS)

O princípio dos mínimos quadrados foi formulado por Gauss no século XVIII e enuncia que: "a soma dos quadrados das diferenças entre os valores efetivamente observados e os calculados, ponderados pelo grau de precisão, deve ser mínima". Seja, então, um sistema descrito por um modelo DARMA:

$$A(q^{-1}).y(t) = q^{-d}.B(q^{-1}).u(t) \quad (3.1)$$

onde: $A(q^{-1}) = 1 + a_1.q^{-1} + \dots + a_{na}.q^{-na}$ (3.2)

$$B(q^{-1}) = b_0 + b_1.q^{-1} + \dots + b_{nb}.q^{-nb} \quad (3.3)$$

Se o atraso de transporte for diferente de zero e igual d , os d primeiros termos do polinômio $B(q^{-1})$ serão nulos.

Os parâmetros desconhecidos são:

$$\theta = [a_1 \ a_2 \ \dots \ a_{na} \ b_0 \ b_1 \ \dots \ b_{nb}] \quad (3.4)$$

Definindo-se:

$$\varphi(t) = [-y(t-1) \ \dots \ -y(t-na) \ u(t-d) \ \dots \ u(t-d-nb)]^T \quad (3.5)$$

Pode-se reescrever a eq. 3.1 da seguinte forma:

$$y(t) = \varphi(t). \theta(t) \quad (3.6)$$

E a partir da eq. (3.6) pode-se obter recursivamente a estimativa de θ no instante t , denominada $\hat{\theta}$ da seguinte forma:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + k(t). [y(t) - \varphi(t). \hat{\theta}(t-1)] \quad (3.7)$$

$$k(t) = \frac{P(t-1). \varphi(t)}{\lambda + \varphi(t)P(t-1). \varphi^T(t)} \quad (3.8)$$

$$P(t) = \frac{[I - k(t) \cdot \varphi(t)] \cdot P(t-1)}{\lambda} \quad (3.9)$$

$$P(0) = \alpha \cdot I, \quad \alpha \gg 0 \quad (3.10)$$

$$\hat{\theta}(0) = \underline{0} \quad (3.11)$$

As eqs. 3.7 a 3.10 definem o bem conhecido na literatura mínimos quadrados recursivos (RLS), que se diferenciam dos mínimos quadrados estendido recursivo (RELS) pelo modelo a ser pesquisado.

O RELS utiliza o modelo CARIMA:

$$A(q^{-1}) \cdot y(t) = B(q^{-1}) \cdot u(t) + C(q^{-1}) \cdot \xi(t) \quad (3.12)$$

onde: $A(q^{-1}) = 1 + a_1 \cdot q^{-1} + \dots + a_{na} \cdot q^{-na}$ (3.13)

$$B(q^{-1}) = b_0 + b_1 \cdot q^{-1} + \dots + b_{nb} \cdot q^{-nb} \quad (3.14)$$

$$C(q^{-1}) = c_0 + c_1 \cdot q^{-1} + \dots + c_{nc} \cdot q^{-nc} \quad (3.15)$$

Isto implica, porém, apenas no aumento do vetor de parâmetros $\hat{\theta}$, e do vetor de dados $\varphi(t)$, conservando as mesmas equações que descrevem o RLS (eqs 3.7 a 3.10). Assim temos:

$$\theta = [a_1 \ a_2 \ \dots \ a_{na} \ b_0 \ b_1 \ \dots \ b_{nb} \ c_0 \ c_1 \ \dots \ c_{nc}] \quad (3.16)$$

Definindo-se:

$$\varphi(t) = [-y(t-1) \ \dots \ -y(t-na) \ u(t-1) \ \dots \ u(t-1-nb) \ \varepsilon(t) \ \dots \ \varepsilon(t-nc)]^T$$

onde: $\varepsilon(t) = y(t) - \varphi(t) \cdot \hat{\theta}(t-1)$ (3.17)

correspondente ao erro de estimação no instante t .

Observando-se a eq. (3.12), verifica-se a necessidade de se conhecer os graus dos polinômios $A(q^{-1})$, $B(q^{-1})$ e $C(q^{-1})$ (na, nb, nc respectivamente). Porém, de acordo com Goodwin [GOODWIN 84] pode-se assumir que estes são iguais ao maior valor entre eles, sem que isto

interfira na convergência do algoritmo de estimação. Isto é válido, desde que $C(z^{-1})$ seja um polinômio estável (se o atraso de transporte d não for nulo, considera-se o maior valor entre $na, nb-d, nc$).

A afirmação anterior é muito importante, pois permite limitar o universo dos modelos a ser pesquisado. Isto porque, foi assumido que não se tem nenhuma informação do modelo, inclusive dos graus dos polinômios que o definem. Sendo assim, o número de modelos a ser pesquisado, caso não houvesse a restrição, seria igual ao produto dos maiores graus possíveis de cada polinômio.

3.3 Fatorização U-D

O algoritmo RELS apresenta problemas de instabilidade numérica quando é deixado em operação por milhares de iterações [CLARKE 85]. Este problema pode ser evitado usando-se a fatorização U-D, proposta por Biermann [BIERMANN 75]. Com a fatorização, a matriz de covariância $P(t)$ é definida como:

$$P(t) = U(t).D(t).U^T(t) \quad (3.18)$$

onde a matriz $U(t)$ é triangular superior e com 1's ao longo da diagonal principal, e a matriz $D(t)$ é diagonal. Assim o RELS assume a seguinte forma:

$$\begin{cases} f(t) = U^T(t-1). \varphi^T(t) & f^T(t) = [f_1(t) \ f_2(t) \ \dots \ f_n(t)] \\ V(t) = D(t-1). f(t) & V_i(t) = d_i(t). f_i(t) \quad i = 1 \dots n \end{cases} \quad (3.19)$$

$$a_1(t) = r + v_1 \cdot f_1 \quad b_2^T = \begin{bmatrix} v_1 & \overbrace{0 \ \dots \ 0}^{n-1} \end{bmatrix} \quad (3.20)$$

$$d_1(t) = \frac{d_1(t-1).r}{a_1} \quad (3.21)$$

for $j = 2 \dots n$

$$a_j = a_{j-1} + v_j \cdot f_j$$

$$d_j(t) = d_j(t-1) \cdot \frac{a_{j-1}}{a_j \lambda}$$

$$u_j(t) = u_j(t-1) + P_j \cdot b_j \quad P_j = \frac{-f_j}{a_{j-1}}$$

(3.22)

onde: $U(t) = [u_1(t) \dots u_n(t)]$

(3.23)

e $u_i(t)$ é a i -ésima coluna da matriz $U(t)$.

O ganho $k(t)$ é dado por:

$$k(t) = \frac{b_{n+1}}{a_n} \quad (3.24)$$

e a atualização do vetor de parâmetros obedece a mesma expressão anterior (eq. 3.6), ou seja:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + k(t) \cdot [y(t) - \varphi(t) \cdot \hat{\theta}(t-1)] \quad (3.25)$$

A inicialização é feita de forma similar à eq. 3.9:

$$D(0) = \alpha \cdot I, \quad \alpha \gg 0 \quad (3.26)$$

$$\hat{\theta}(0) = \underline{0} \quad (3.27)$$

$$U(0) = I \quad (3.28)$$

3.4 Rastreamento de parâmetros e saturação do estimador

O aspecto mais importante em um controlador adaptativo é a sua capacidade de rastrear variações na dinâmica do processo. Para tal, é necessário reduzir os efeitos dos dados antigos. Esta é uma atitude que requer um compromisso, pois uma redução excessiva pode levar à estimativa incertas se os parâmetros são constantes, e por outro lado, uma redução pequena pode impossibilitar o rastreamento se a dinâmica do processo for muito rápida.

O esquecimento exponencial é uma maneira de se descartar dados antigos, e está presente no algoritmo do RELS através do parâmetro λ (eq. 3.7 e 3.8 ou eq. 3.12).

Quando $\lambda=1$, todos os dados têm o mesmo peso, mas com $\lambda<1$, os dados mais recentes têm maior peso que os antigos. Porém o esquecimento exponencial só funciona bem se o processo é excitado todo o tempo. Se ocorrer longos períodos sem excitação, as incertezas começam a crescer, isto é conhecido como saturação do estimador. O problema é devido ao crescimento exponencial da matriz de covariância, pois se não existir informação na última medida, o termo $P(t-1) \cdot \varphi(t)$ na eq. (3.9) não mudará de direção, tornando-se:

$$P(t) = \frac{P(t-1)}{\lambda} \quad (3.29)$$

E se $\lambda<1$, $P(t)$ crescerá exponencialmente, enquanto $\varphi(t)$ não mudar de direção, fazendo com que o ganho $k(t)$ na eq. 3.7 também cresça. Assim, poderá haver grandes mudanças nos parâmetros estimados, quando depois de longo período sem excitação ocorrer, por exemplo, uma mudança na referência.

Existem várias técnicas para evitar a saturação do estimador, as quais se baseiam em manter a matriz de covariância limitada. Uma das soluções propostas na literatura é o uso do fator de esquecimento vetorial variável [TUFFS 85], que também utiliza a fatorização U-D.

Isto é feito, através das seguintes modificações na eq. 3.9:

$$P(t) = F^{-1} \cdot [I - k(t) \cdot \varphi(t)] \cdot P(t-1) \cdot F^{-1} \quad (3.30)$$

onde F é uma matriz diagonal de fatores de esquecimento.

$$F = \begin{bmatrix} f_1 & & \\ & \ddots & \\ & & f_n \end{bmatrix} \quad (3.31)$$

Rearrumando em termos de U-D:

$$P'(t) = [I - k(t) \cdot \varphi(t)] \cdot P(t-1) \quad (3.32)$$

$$P'(t) = U'(t) \cdot D'(t) \cdot U'^T(t) \quad (3.33)$$

$$D(t) = F^{-1} \cdot D'(t) \cdot F^{-1} \quad (3.34)$$

$$U(t) = F^{-1} \cdot U'(t) \cdot F \quad (3.35)$$

e

$$f_i^2 = \max \left(\frac{d_i(t)}{d_i(t-1)}, \lambda \right) \quad (3.36)$$

Uma outra modificação que pode ser feita no algoritmo que aumenta a sua robustez e também evita a saturação é o desligamento do estimador através da utilização de uma zona morta no estimador [GOODWIN 89]. Esta zona morta impede a atualização dos vetores de parâmetros e da matriz de covariância $P(t)$ caso o erro de estimação seja menor que uma determinada faixa relacionada com a faixa de ruído. O algoritmo RELS com zona morta é descrito a seguir:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + a(t) \cdot k(t) \cdot [y(t) - \varphi(t) \cdot \hat{\theta}(t-1)] \quad (3.37)$$

$$k(t) = \frac{P(t-1) \cdot \varphi(t)}{\lambda + \varphi(t) P(t-1) \cdot \varphi^T(t)} \quad (3.38)$$

$$P(t) = \frac{P'(t-1) - a(t) \cdot k(t) \cdot \varphi(t) \cdot P(t-1)}{\lambda} \quad (3.39)$$

$$P(t) = F^{-1} \cdot P'(t) \cdot F^{-1} \quad (3.40)$$

$$a(t) = \begin{cases} 0.5, & |y(t) - \varphi(t) \cdot \hat{\theta}(t-1)| > 2 \cdot \delta \\ 0, & |y(t) - \varphi(t) \cdot \hat{\theta}(t-1)| < 2 \cdot \delta \end{cases} \quad (3.41)$$

onde δ é a faixa de ruído.

3.5 Estimação Recursiva da ordem do modelo

Como foi colocado no início deste capítulo, a utilização do RELS requer um conhecimento a priori da ordem do modelo. Foi introduzido, para solução deste problema, uma Estrutura Competitiva de Modelos [ISERMANN 93]. Esta estrutura consiste em um conjunto de estimadores de diferentes ordens operando em paralelo (simultaneamente) e de um mecanismo de seleção do modelo mais adequado para cada instante de amostragem. A seleção do modelo é função de um índice adequação (critério de adequação) obtido a partir dos erros quadráticos de estimação. Neste trabalho três critérios foram implementados e analisados: o PLS (Predictive Least Square), o critério de verossimilhança modificado e o enfoque Bayesiano modificado [MEDEIROS 90].

Esta estrutura competitiva de modelos opera sobre uma faixa de modelos definida previamente pelo usuário (ordem mínima, n_{min} , e ordem máxima, n_{max}). Esta faixa (Φ) pode ser expressa como:

$$\Phi = \{p, \quad n_{min} \leq p \leq n_{max}\} \quad (3.43)$$

onde p é a ordem do modelo.

E o conjunto de modelos é formulado como:

$$M(t) = \left\{ \hat{\theta}_p(t), \quad p \in \Phi \right\} \quad (3.44)$$

Portanto, a saída prevista para o sistema no instante t , supondo seu comportamento regulado pelo modelo selecionado no instante t é:

$$\hat{y}(t) = \hat{\theta}_p \cdot \varphi_p(t), \quad \text{onde } p \in \Phi \quad (3.45)$$

A estrutura do sistema de controle pode ser vista na figura 3.3, onde a linha pontilhada delimita a estrutura competitiva de modelos, que corresponde ao algoritmo de identificação recursiva da ordem do modelo.

Associa-se a cada um dos modelos no conjunto $M(t)$ um índice percentual de adequação, $S_p(t)$, que reflete o quão próximo do comportamento do sistema está o comportamento do modelo $\hat{\theta}_p(t)$, e que obedece às seguintes condições:

$$\begin{cases} \text{a) } 0 \leq S_p(t) \leq 1, & \forall p \in \Phi \\ \text{b) } \sum_{p \in \Phi} [S_p(t)] = 1 \end{cases} \quad (3.46)$$

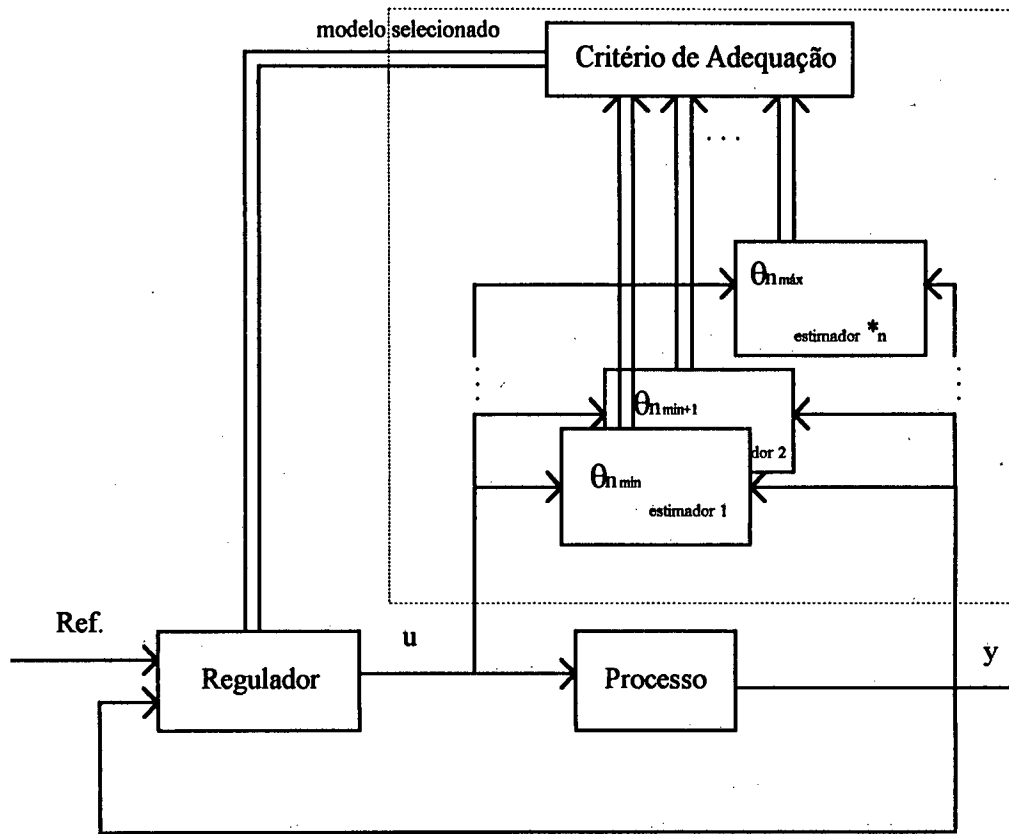


Figura 3.1 Diagrama em blocos de um controlador adaptativo auto-ajustável (STR)

$$* n = n_{\text{máx}} - n_{\text{mín}}$$

Dispondo-se de medidas de adequação $\mu_p(t) \geq 0$, pode-se proceder a uma normalização de forma a obter índices que satisfaçam a eq. (3.46):

$$S_p(t) = \frac{\mu_p(t)}{\sum_{n_{\text{mín}}}^{n_{\text{máx}}} \mu_i(t)} \quad (3.47)$$

Existem várias formas para determinação destas medidas de adequação. Dentre elas, destacam-se, o PLS ("Predictive Least Square"), introduzido por Rissanen [RISSANEN 86],

uma modificação do enfoque Bayesiano proposto por Niedzwieck [NIEDZWIECK 84] e o critério de verossimilhança modificado [AKAIKE 77]. Nas seções que se seguem, estes métodos são descritos e os resultados de simulação obtidos, que permitem definir o critério a ser utilizado no desenvolvimento do GPCA proposto, são apresentados no capítulo V.

3.6 Critério PLS

Nos algoritmos de identificação recursiva, usualmente se avalia a cada passo o erro de predição do modelo, ou seja, a diferença entre o valor efetivamente lido da saída do sistema e o valor previsto pelo modelo para aquele momento. Em uma notação precisa:

$$e(t) = y(t) - \hat{y}(t) = y(t) - \hat{\theta}_p(t) \cdot \varphi_p(t) \quad (3.48)$$

O somatório dos erros de predição no tempo t é dado por:

$$E_p(t) = \sum_0^t [e(i)]^2 = \sum_0^t [y(i) - \hat{y}(i)]^2 \quad (3.49)$$

o qual é de forma intuitiva, inversamente proporcional à adequação do modelo, pois quanto menores tiverem sido os erros gerados ao se prever o comportamento passado do sistema pelo modelo, menores se espera que sejam os erros ao se prever o comportamento atual e futuro do sistema usando o modelo.

Foi a partir dessa idéia que surgiu a motivação empírica para o critério PLS, o qual prescreve que a ordem estimada para o sistema em um dado instante de amostragem é a ordem do modelo que apresentar menor erro de predição quadrático médio naquele instante. Pode-se definir, portanto, uma medida de adequação como sendo:

$$\mu_p(t) = \frac{t}{E_p(t)} \quad (3.50)$$

Tal medida de adequação é bastante apropriada para estimação recursiva da ordem, dado que o somatório dos erros quadráticos de predição pode ser calculado empregando-se a recursão:

$$E_p(t) = [e(t)]^2 + E_p(t-1), \quad t > 0 \quad (3.51)$$

$$E_p(0) = 0 \quad (3.52)$$

Além da forte motivação intuitiva do critério PLS, Hemerly [HEMERLY 85] mostrou sua consistência ao se estimar a ordem de processos auto-regressivos.

Heuristicamente pode-se tentar melhorar a adaptabilidade do critério PLS a possíveis alterações na ordem mais adequada do modelo do sistema, atribuindo-se peso maior às informações mais recentes. Assim, define-se um fator de esquecimento λ ($0 < \lambda \leq 1$) e uma soma ponderada dos erros de predição, ou seja:

$$E_p^*(t) = \sum_0^t \lambda^{t-i} [e(i)]^2 = \sum_0^t \lambda^{t-i} [y(i) - \hat{y}(i)]^2 \quad (3.53)$$

Procedendo da mesma forma, a medida de adequação passa a ser dada por:

$$\mu_p(t) = \frac{k(t)}{E_p^*(t)} \quad (3.54)$$

onde $k(t)$ é o número efetivo de observações, que vale:

$$k(t) = \sum_0^t \lambda^{t-i} = \frac{1 - \lambda^{t+1}}{1 - \lambda} \quad (3.55)$$

Integrando-se este fator de esquecimento ao somatório quadrático dos erros de predição, preserva-se a característica recursiva do cálculo da medida, pois:

$$E_p^*(t) = [e(t)]^2 + \lambda E_p^*(t-1), \quad t > 0 \quad (3.56)$$

$$E_p^*(0) = 0 \quad (3.57)$$

3.7 Enfoque Bayesiano modificado

O resíduo de um modelo é a diferença entre a saída efetiva do sistema no instante t e a saída prevista pelo modelo para o instante t . Ou seja:

$$r_t(t) = y(t) - \hat{y}_t(t) \quad (3.58)$$

Onde o t' indica que o cálculo do resíduo é realizado utilizando-se o modelo disponível no instante arbitrário t' ($t' \geq t$).

De forma similar, as equações (3.49) e (3.53) definem os somatórios quadráticos e quadráticos ponderado dos resíduos:

$$R_p = \sum_0^t [r_t(i)]^2 = \sum_0^t [y(i) - \hat{y}_t(i)]^2 \quad (3.59)$$

$$R_p^*(t) = \sum_0^t \lambda^{t-i} [r_t(i)]^2 = \sum_0^t \lambda^{t-i} [y(i) - \hat{y}_t(i)]^2 \quad (3.60)$$

Apesar do cálculo recursivo de tais somatórios ser ineficiente para o cálculo de medidas de adequação em tempo real (no instante t , precisa-se dispor de todos os sinais de saída anteriores), algumas estratégias para estimação recursiva de ordem baseadas nestes somatórios têm sido propostas. Niedzwiecki [NIEDZWIECKI 84] sugeriu a utilização das medidas de probabilidade condicional para sistemas CARIMA como índice de adequação, $S_p(t)$. Esta propriedade é dada por:

$$S_p(t) = \frac{e^{-\varphi_p(t)}}{\sum_{n_{\min}}^{n_{\max}} e^{-\varphi_p(t)}} \quad (3.61)$$

onde, em uma versão simplificada tem-se:

$$\varphi_p(t) = \frac{t}{2} \ln [R_p(t) + p \ln t] \quad (3.62)$$

No caso não estacionário, obtém-se [NIEDZWIECKI 84]

$$S_p(t) = \frac{e^{-\varphi_p^*(t)}}{\sum_{n_{\min}}^{n_{\max}} e^{-\varphi_p^*(t)}} \quad (3.62)$$

onde, também em uma versão simplificada:

$$\varphi_p^*(t) = \frac{K(t)}{2} \ln[R_p^*(t)] + p \ln[k(t)] \quad (3.63)$$

Em [Medeiros 90] é sugerida uma modificação nestes índices de forma a torná-los adequados para aplicações em tempo real. Para tanto, é feita uma substituição, nas expressões de cálculo dos índices, dos somatórios dos resíduos pelos dos erros de predição. Com isto os índices de adequação baseados no enfoque Bayesiano modificado são calculados segundo a eq. (3.62), fazendo-se:

$$\varphi_p^*(t) = \frac{K(t)}{2} \ln[E_p^*(t)] + p \ln[k(t)] \quad (3.64)$$

3.8 Critério de Verossimilhança Modificado

Esta abordagem é baseada no conceito de Akaike [AKAIKE 77] de uma "verossimilhança" associada com o modelo. As medidas de adequação são escolhidas de forma proporcional às verossimilhanças associadas aos modelos que estão competindo.

Os índices de adequação podem ser obtidos na seguinte forma [NIEDZWIECKI 85]:

$$\varphi_p(t) = \frac{t}{2} \ln[R_p(t)] + (p^2 t)^3 \quad (3.65)$$

E para o caso não-estacionário, faz-se:

$$\varphi_p^*(t) = \frac{K(t)}{2} \ln[R_p^*(t)] + 2\delta(t)p \quad (3.66)$$

onde $K(t)$ é o número efetivo de observações já definido, e $\delta(t)$ é um coeficiente de decremento de energia, dado por:

$$\delta(t) = \frac{\sum_1^t (\lambda^{t-i})^2}{\sum_1^t \lambda^{t-i}} = \frac{1 - \lambda^{2t}}{1 - \lambda^2} = \frac{1 + \lambda^t}{1 + \lambda} \quad (3.67)$$

Da mesma forma que no enfoque Bayesiano modificado, Medeiros [Medeiros 90] sugere a substituição dos somatórios dos resíduos pelos somatórios dos erros de predição. Assim, os índices são calculados pela equação (3.61), fazendo-se:

$$\varphi_p^*(t) = \frac{K(t)}{2} \ln[E_p^*(t)] + 2\delta(t)p \quad (3.67)$$

3.9 Conclusões

Neste capítulo introduziu-se o conceito de controle adaptativo e uma das abordagens mais utilizadas (STR) foi escolhida para o desenvolvimento do GPC adaptativo (GPCA).

O método dos mínimos quadrados estendido recursivo foi descrito, assim como, técnicas que permitem o aumento da sua eficiência e robustez como a fatorização U-D, o emprego de fator de esquecimento vetorial variável e de zona-morta, foram apresentadas.

Uma estrutura competitiva de modelos, para solução da estimação recursiva da ordem do modelo, foi descrita. Esta estrutura utiliza um critério para seleção do modelo. Três critérios foram estudados: o PLS (Predictive Least Square), o enfoque Bayesiano modificado e o da verossimilhança modificado.

O capítulo seguinte dedica-se à apresentação do sistema de ajuste automático do GPCA proposto que baseia-se em uma identificação em malha aberta e na análise da função de transferência de malha fechada. Também é abordada a escolha de polinômios auxiliares que permitem aumentar a robustez do GPC e especificar a resposta do sistema para mudanças no "set-point" e rejeição de perturbações de carga.

CAPÍTULO IV

SISTEMA DE AJUSTE AUTOMÁTICO DO GPCA

4.1 Introdução

Nos capítulos anteriores foram apresentados os algoritmos de controle GPC e o de identificação recursiva do modelo do processo. Estes dois subsistemas associados compõe o controlador GPCA. Uma das limitações da utilização deste controlador no ambiente industrial reside na dificuldade encontrada no ajuste de seus parâmetros de projeto: horizontes de predição mínimo e máximo, horizonte de controle, ponderação sobre a ação de controle, polinômio observador e seguidor de modelo, e tempo de amostragem. Estes parâmetros são dependentes da dinâmica do processo a controlar, portanto para aplicações em ambientes industriais, onde nem sempre as informações disponíveis do modelo da planta são suficientes para determiná-los, é necessário realizar algum tipo de ensaio para obter estas informações.

Considerando, ainda, que o controlador a ser implementado deve ser de propósito geral e operado por engenheiros e/ou operadores de planta que não possuem conhecimento sobre as teorias de controle adaptativo e preditivo, é necessário introduzir mecanismos que possibilitem a operação do controlador de maneira acessível e com um mínimo de informação por parte do usuário.

Os aspectos levantados anteriormente, sugerem o desenvolvimento de um sistema de ajuste automático do GPCA que atenda as seguintes especificações:

- apresente uma interface simples com o operador da planta;
- permita a obtenção de um modelo inicial da planta baseado em um ensaio de malha aberta;
- possibilite a determinação automática dos parâmetros do controlador

Neste capítulo será abordado o sistema de ajuste automático do GPCA, detalhando os diferentes mecanismos implementados.

4.2 Estrutura do controlador adaptativo implementado

A estrutura do controlador adaptativo proposto neste trabalho é composta de três elementos principais: o algoritmo de controle (GPC) descrito no cap.II, o sistema de identificação paramétrica (algoritmo competitivo de modelos) descrito no cap. III e o sistema de ajuste dos parâmetros controlador a ser descrito neste capítulo. Esta estrutura pode ser vista na figura 4.1:

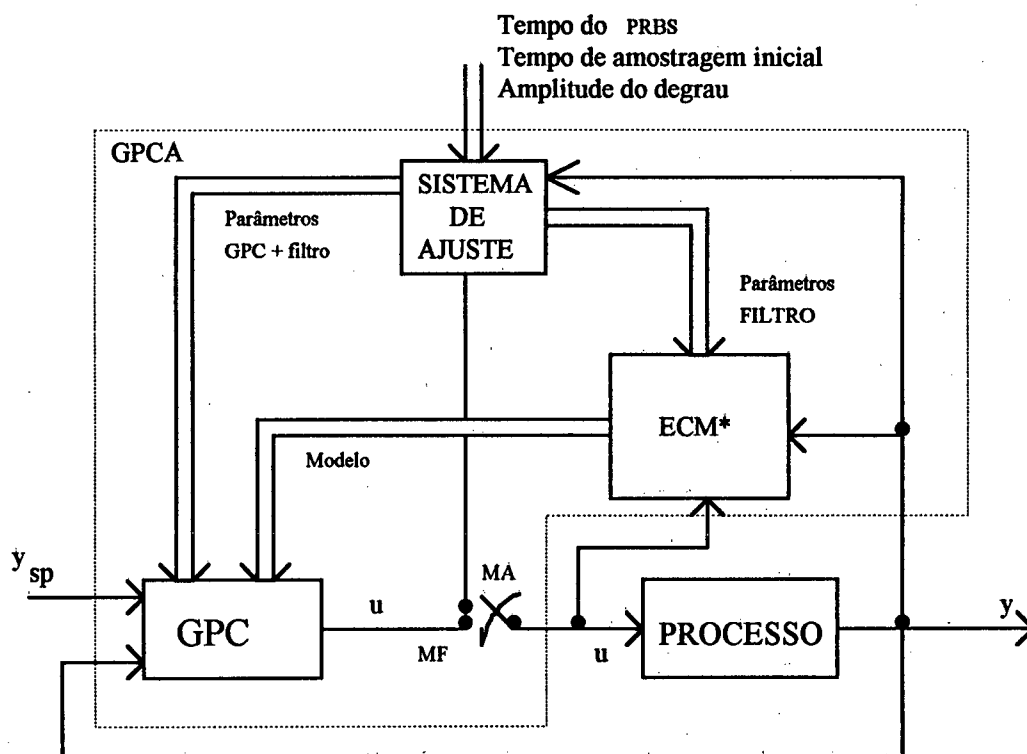


Figura 4.1 Estrutura do GPC-A proposto.

* ECM - Estrutura Competitiva de Modelos
MF - malha fechada
MA - malha aberta

O sistema de ajuste é composto basicamente por dois mecanismos:

- identificação em malha aberta
- atualização "on-line" do polinômio observador $T(q^{-1})$ e da ponderação da ação de controle (λ).

O mecanismo de identificação de malha aberta tem como atribuição a determinação do tempo de atraso de transporte e do tempo de subida, a definição do tempo de amostragem e a inicialização do estimador.

O mecanismo de atualização "on-line" possibilita a determinação do polinômio observador $T(q^{-1})$, através dos resultados obtidos na análise da função de transferência de malha fechada, e a redefinição da ponderação da ação de controle em função do erro do sistema (diferença entre a referência e a saída do processo). Como será mostrado nas próximas seções, este mecanismo propicia um aumento da robustez do controlador.

4.3 Identificação em malha aberta

A identificação em malha aberta objetiva levantar uma estimativa do atraso de transporte e do tempo de subida do processo que servirão de base para a definição dos horizontes de predição (N_1 e N_2) e do novo tempo de amostragem

Para a identificação ser mais exata, é necessário levar em consideração o ruído existente na planta. Isto implica, portanto, na adoção de uma técnica para estimação da faixa de ruído a qual é descrita a seguir.

4.3.1 Cálculo da faixa de ruído

O método adotado para o cálculo da faixa de ruído baseia-se na medição dos valores máximos e mínimos da saída do processo, quando esta está em regime permanente. Para tanto, é definido um intervalo de tempo T_n (da ordem do tempo de subida da planta) que é dividido em três outros intervalos como é mostrado na figura 4.2. Como é suposto que não é necessário conhecer a dinâmica da planta quando da utilização do GPCA, T_n é definido empiricamente em função do tempo de amostragem inicial dado pelo operador ($T_n = 30$ amostragens).




Figura 4.2 Definição dos intervalos de tempo utilizados para testar o estado estacionário do processo e calcular a faixa de ruído.

Analisando as médias e os desvios padrão nos intervalos acima definidos, pode-se afirmar se a saída está realmente em regime estacionário, permitindo, assim, calcular a faixa de ruído.

Em seguida são descritos quatro condições suficientes para se considerar a saída em regime estacionário [SALLÉ 91]. Apenas é assumido um valor mínimo (0,005) para o desvio padrão nos intervalos. Desta forma, um sistema é declarado em regime estacionário se:

1. A variação relativa da média da saída nos intervalos 1 e 3 for inferior à 5% ou 10% (a depender da confiança que se deseja).
2. A variação relativa do desvio padrão nos intervalos 1 e 3 for inferior à 10% ou 15% (a depender da confiança que se deseja).
3. A variação absoluta da média da saída do processo nos intervalos 1 e 3 for menor que o desvio padrão no intervalo 2.
4. O erro (diferença entre a saída e referência) médio no intervalo 2 for inferior à metade do desvio padrão nesse intervalo.

A média e o desvio padrão são dados por:

$$\bar{x} = \frac{1}{N} \sum_1^N x_i \quad (4.1)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_1^N (x_i - \bar{x})^2} \quad (4.2)$$

e finalmente a faixa de ruído é dada por:

$$\eta = \max(y(t)) - \min(y(t)) \quad (4.3)$$

onde os mínimos e máximos de $y(t)$ são calculados no intervalo 2.

4.3.2 Obtenção do atraso de transporte e do tempo de subida

Uma vez obtida a faixa de ruído, aplica-se um degrau, de amplitude definida pelo usuário (operador de planta), na entrada do processo. O atraso de transporte é obtido, então, a partir da

análise do comportamento do erro. O erro, que inicialmente é nulo (faz-se referência=saída), é acompanhado de forma a se detectar o instante em que este for cinco vezes consecutivas maior que a faixa de ruído. Neste instante, define-se o atraso de transporte como sendo o número de amostragens até o momento (a partir da aplicação do degrau) subtraído de cinco unidades. O intervalo de cinco unidades (valor empírico) foi adotado para garantir que a mudança no comportamento da saída do sistema seja devida realmente ao degrau aplicado na entrada e não ao próprio ruído presente no sinal.

Para se estimar o tempo de subida, usa-se um método semelhante ao do cálculo do atraso de transporte. Para este caso, acompanha-se a derivada da saída do processo (a derivada da saída é aproximada pela diferença, $\Delta y(t)$), procurando-se detectar o instante em que esta for menor que a faixa de ruído por quarenta vezes consecutivas (valor empírico). Este instante é definido como sendo o tempo de subida subtraído de quarenta unidades e do atraso de transporte. Da mesma forma que para o cálculo do atraso de transporte, o intervalo de quarenta unidades objetiva aumentar a confiabilidade na medição. A escolha de um intervalo maior que o anterior se deve ao fato de que a derivada da saída assume valores bem menores que o próprio erro, conseqüentemente, sua medida é mais influenciada pelo ruído do que a medida do erro.

4.3.3 Definição do tempo de amostragem

Observou-se no capítulo II, que no algoritmo do GPC, como em todo controlador preditivo, a quantidade de cálculo está relacionada com o grau do polinômio $B(q^{-1})$ da eq. (2.2). Para o GPCA, especificamente, o grau do polinômio $B(q^{-1})$, que também influencia nas dimensões dos vetores e matrizes do RELS, depende do tempo de amostragem (se o atraso de transporte não for nulo). Isto porque quanto menor o tempo de amostragem, maior o valor do atraso de transporte em amostragens, e conseqüentemente maior o número de elementos de $B(q^{-1})$. Além disso, o horizonte de predição máximo também depende do grau de $B(q^{-1})$ (será mostrado na seção 4.3). Deve-se evitar, portanto, a utilização de um tempo de amostragem muito pequeno, pois a implementação do algoritmo pode tornar impraticável o controle de processos lentos ou com atraso de transporte dominante.

Em contrapartida o tempo de amostragem não pode assumir valores grandes (próximos ao tempo de subida da planta), dado que o sistema pode tornar-se instável.

Nota-se, portanto, que a escolha do tempo de amostragem é fundamental para o bom funcionamento do GPCA, e que esta é função de um compromisso entre a estabilidade do sistema e a praticabilidade do algoritmo. E, como não se garante que a escolha do tempo de amostragem inicial, feita pelo operador, é a mais adequada, o sistema de ajuste automático do GPCA redefine o tempo de amostragem.

O valor do tempo de amostragem adotado pelo sistema de ajuste automático, está dentro da faixa sugerida por Astrom [ASTROM 84]:

$$\frac{T_s}{4} \leq T_{am} \leq \frac{T_s}{10}$$

onde T_{am} e T_s são os tempo de amostragem e o tempo de subida da planta respectivamente

O valor utilizado é dado por:

$$T_{am} = \frac{T_s}{8} \quad (4.4)$$

4.3.4 Inicialização do estimador

Os parâmetros estimados do modelo são inicialmente desconhecidos, assim, uma identificação prévia do processo se faz necessária para evitar a ocorrência de transitórios grandes, quando o sistema estiver em malha fechada.

Desta forma, a injeção de um sinal com espectro amplo e uniforme é aconselhável. Na prática, o que se utiliza é um sinal do tipo PRBS (Pseudo Random Binary Sequence). O PRBS consiste em uma sequência randômica de pulsos binários como pode ser visto na fig 4.3. Este sinal apresenta características semelhantes às do ruído branco.




Figura 4.3 Sequência binária pseudo randômica (PRBS)

A amplitude dos pulsos, A , assume o mesmo valor definido pelo usuário para a amplitude do degrau aplicado ao processo quando da identificação em malha aberta. E o tempo durante o qual a sequência é injetada pode ser redefinido pelo usuário (valor "default" igual a 200 amostragens) caso este deseje uma inicialização mais rápida.

4.4 Definição dos horizontes de predição e da ponderação sobre a ação de controle

A escolha dos horizontes de predição e da ponderação sobre a ação de controle baseia-se nos parâmetros obtidos através do ensaio de malha aberta.

Após calcular os valores do atraso de transporte e do tempo de subida (em amostragens) em função do novo tempo de amostragem, define-se os horizontes de predição mínimo e máximo de forma semelhante à sugerida por Clarke [CLARKE 87]:

$$N_1 = \text{atraso de transporte} + 1 \quad (4.5)$$

$$N_2 = 2 (n_{m\acute{a}x} + \text{atraso de transporte m\acute{a}ximo}) \quad (4.6)$$

onde $n_{m\acute{a}x}$ é a maior ordem dos modelos pesquisados pela estrutura competitiva de modelos, e o atraso de transporte máximo é definido como:

$$\text{atraso de transporte m\acute{a}ximo} = \text{atraso de transporte} + 10 \quad (4.7)$$

Este *atraso de transporte máximo* tem como objetivo dar uma margem de segurança ao sistema. Isto pois não se garante que o valor do atraso de transporte, estimado em malha aberta, irá permanecer constante, podendo este aumentar durante a operação, o que levaria o GPCA à instabilidade.

O valor de 10 amostragens, adotado como margem de segurança (corresponde à uma variação equivalente a 125% do tempo de subida inicial da planta (T_s)), foi assumido como suficiente para a maioria dos processos.

O valor do horizonte de controle NU foi fixado em 1 (uma) amostragem como é sugerido na literatura [CLARKE 87].

A sugestão de Clarke para escolha da ponderação sobre a ação de controle λ é dada por:

$$\begin{cases} \lambda = \lambda_0 [B(1)]^2 \\ 0 < \lambda_0 < 1 \end{cases} \quad (4.8)$$

Esta sugestão não apresentou bons resultados para os casos testados. Assim, λ foi fixado em um valor próximo a zero (10^{-4}), já que este não pode assumir valor nulo pois isto causaria problemas numéricos no algoritmo otimizado do GPC (ver apêndice B).

No entanto, propõe-se a utilização de λ quando a saída estiver em regime permanente, objetivando, desta forma, a atenuação das componentes de alta frequência do sinal de controle causadas pelo ruído presente no sinal de saída do processo.

Isto pode ser feito da seguinte forma: λ é incrementado (a uma taxa de 5%, obtida empiricamente) durante o período em que o erro (diferença entre a referência e a saída) permanece menor que a faixa de ruído, caso contrário, este é reinicializado. Ou seja:

$$\begin{cases} e < \delta, & \lambda(t) = (1.05) \cdot \lambda(t-1) \\ e > \delta, & \lambda(t) = 10^{-4} \end{cases} \quad (4.9)$$

onde δ é a faixa de ruído e e o erro. O funcionamento deste mecanismo será ilustrado através de resultados de simulação apresentados no capítulo V.

4.5 Aumento da robustez utilizando as extensões do GPC

Nota-se, pelo que foi apresentado nas seções anteriores, que uma vez inicializado o controlador, através dos dados obtidos pela aplicação do degrau em malha aberta, os seus parâmetros são fixados. Assim, somente os polinômios $T(q^{-1})$ e $P(q^{-1})$ podem ser manipulados pelo sistema de ajuste automático de forma a melhorar a sua performance e a sua robustez.

A análise da função de transferência de malha fechada fornece subsídios para o projeto destes polinômios. Este é o tópico do próximo item.

4.5.1 Análise da função de transferência de malha fechada

Seja o diagrama em blocos do sistema em malha fechada mostrado na figura 4.4:




Figura 4.4 Diagrama em blocos de um sistema em malha fechada

onde G a função de transferência do processo ($G = \frac{\hat{B}}{\hat{A}}$, onde \hat{A} e \hat{B} são os polinômios estimados), G_c a função de transferência nominal de malha fechada e ΔG a dinâmica não modelada. Assim, o processo real pode ser escrito da seguinte forma:

$$G_p = G + \Delta G \quad (4.9)$$

A função de transferência real ($G_{c_{real}}$) em malha fechada vale:

$$G_{c_{real}} = \frac{G_p \cdot C}{1 + G_p \cdot C} = \frac{(G + \Delta G) \cdot C}{1 + (G + \Delta G) \cdot C} \quad (4.10)$$

mas

$$G_c = \frac{G \cdot C}{1 + G \cdot C} \Rightarrow C = \frac{G_c}{G \cdot (1 - G_c)} \quad (4.11)$$

Substituindo a eq. (4.10) em (4.11) tem-se:

$$G_{c_{real}} = \frac{\frac{G_c}{1 - G_c} \left[1 + \frac{\Delta G}{G} \right]}{1 + \frac{G_c}{1 - G_c} \left[1 + \frac{\Delta G}{G} \right]} = \frac{G_c \left[1 + \frac{\Delta G}{G} \right]}{1 + \frac{\Delta G \cdot G_c}{G}} \quad (4.12)$$

O critério de Nyquist deve ser satisfeito para garantir a estabilidade em malha fechada. Uma condição suficiente para que isto ocorra é dada no "Teorema do ganho pequeno" [DESOER 75], que requer que o módulo do termo dependente da frequência no denominador seja menor que a unidade em todas as frequências. Ou seja:

$$\left| \frac{\Delta G \cdot G_c}{G} \right| < 1 \quad (4.13)$$

reescrivendo:

$$|\Delta G| < \left| \frac{G}{G_c} \right| \quad (4.14)$$

De posse da eq. (4.14), o próximo passo é o projeto do GPC tal que o termo $\left| \frac{G_c}{G} \right|$ assumira o maior valor possível, mantendo-se uma performance aceitável no que se refere à mudança de "set-point" e a rejeição de perturbações de carga.

A forma mais conveniente para analisar o GPC é utilizar a representação polinomial dos controladores por alocação de pólos [ROBINSON 89]:

$$T.w(t) = R.\Delta.u(t) + S.y(t) \quad (4.15)$$

onde T ($T(q^{-1})$) é um polinômio definido pelo usuário e R ($R(q^{-1})$) e S ($S(q^{-1})$) são obtidos a partir da seguinte equação diofantina:

$$R.\hat{A}.\Delta + \hat{B}.S = P_c.T \quad (4.16)$$

com P_c sendo o polinômio que define a resposta em malha fechada do sistema. No caso do GPC, este polinômio não é especificado diretamente pelo usuário, mas através da escolha de seus parâmetros. No entanto, existem dois casos em que P_c é explicitamente especificado: quando o GPC é projetado para trabalhar como controlador "Mean-level" ou "Dead-beat". Na estratégia "Mean-level", os pólos de malha fechada são alocados na mesma posição dos pólos estimados em malha aberta e no caso do "Dead-beat", todos os pólos são alocados na origem. Ou seja: $P_c = \hat{A}$ para o controle "Mean-level" e $P_c = 1$ para o controle "Dead-beat".

Expressando o sistema descrito na figura 4.4 na forma da eq. (4.16) temos:

$$S = \alpha.T \quad (4.17)$$

$$C = \frac{S}{R.\Delta} \quad (4.18)$$

e a função de transferência de malha fechada torna-se:

$$G_c = \alpha \frac{\hat{B}}{P_c} \quad (4.19)$$

onde α é uma constante tal que G_c tenha ganho unitário em regime permanente. Substituindo a eq. (4.19) na (4.14):

$$|\Delta.A| = \left| \frac{\alpha.G.T}{G_c.S} \right| = \left| \frac{P_c.G.T}{\hat{B}.S} \right| \quad (4.20)$$

4.5.2 Influência do polinômio observador $T(q^{-1})$ sobre a função de transferência de malha fechada

Como, geralmente, a estratégia de controle "Dead-beat" é menos robusta que a "Mean-level" [ROBINSON 89], esta última foi adotada. Na estratégia "Mean-level" $P_c = \hat{A}$ e $G = \frac{\hat{B}}{\hat{A}}$, reescreve-se, então, as eq. (4.20) e (4.16):

$$R.\hat{A}.\Delta + \hat{B}.S = \hat{A}.T \quad (4.21)$$

$$|\Delta.A| = \left| \frac{\hat{A}.G.T}{\hat{B}.S} \right| = \left| \frac{T}{S} \right| \quad (4.22)$$

Na eq. (4.21) observa-se que \hat{A} é fator de dois dos três termos, conseqüentemente este é fator do terceiro termo. Assim, define-se:

$$S = \hat{A}.S_1 \quad (4.23)$$

e substituindo a eq. (4.23) em (4.21), tem-se:

$$R.\Delta + \hat{B}.S_1 = T \quad (4.24)$$

Sabe-se que a transformação do GPC na forma de um controlador por alocação de pólos resulta num polinômio S com o mesmo grau do polinômio \hat{A} [ROBINSON 89]. Selecionando-se $na=np+nt$, tem-se S_1 uma constante e para determina-la é suficiente analisar a eq. (4.16) em regime permanente. Como $\Delta(1)=0$, tem-se:

$$S_1 = \frac{T(1)}{\hat{B}(1)} \quad (4.25)$$

assim S vale:

$$S = \frac{T(1)}{\hat{B}(1)} \hat{A} \quad (4.26)$$

Substituindo a eq.(4.26) na eq. (4.22), obtem-se:

$$|\Delta.A| = \left| \frac{T \hat{B}(1)}{\hat{A} T(1)} \right| \quad (4.27)$$

A eq. (4.27) demonstra a importância do polinômio T para a estabilização de malha fechada. Em baixa frequência, T possui pequeno efeito sobre a estabilidade pois $\frac{T}{T(1)} \approx 1$, mas para as altas frequências, onde os efeitos das dinâmicas não modeladas são mais significantes, a presença de T no numerador permite melhorar a estabilidade.

4.5.3 Influência do Polinômio seguidor de modelo $P(q^{-1})$ sobre a função de transferência de malha fechada

Assim como o polinômio $T (T(q^{-1}))$, o polinômio $P (P(q^{-1}))$ também aumenta a robustez do sistema em malha fechada. No entanto, há uma diferença entre os dois: T afeta apenas a rejeição à perturbação e P além desta, afeta a resposta à mudança de "set-point".

Com a introdução de P a função de transferência de malha fechada é alterada para:

$$G_c = \frac{\alpha \cdot \hat{B}}{P_c \cdot P} \quad (4.28)$$

sendo que P é assumido ter ganho unitário em regime permanente ($P(1)=1$) para que não haja "off-set" em malha fechada.

Procedendo da mesma maneira que para T , obtem-se o seguinte limite de estabilidade:

$$\Delta.A < \left| \frac{P.T.\hat{B}(1)}{\hat{A}.T(1)} \right| \quad (4.29)$$

Observa-se, portanto, que P afeta a robustez da mesma forma que o polinômio T .

4.5.4 Escolha dos polinômios $T(q^{-1})$ e $P(q^{-1})$

Nota-se, pelo que foi descrito nas seções 4.4.2 e 4.4.3, que T e P possuem efeitos similares quanto à robustez. No entanto, como P também afeta a resposta em malha fechada, não se deve selecioná-lo tendo em mente apenas o aumento da robustez. Assim, o seguinte procedimento é sugerido por Robinson [ROBINSON 89]:

1. Escolhe-se $P(q^{-1})$ com raízes entre 0,5 e 0,9.
2. Define-se a ordem de $T(q^{-1})$ (n_t) como sendo: $n_t = n_a + n_p$, (com n_a e n_p as ordens dos polinômios $A(q^{-1})$ e $P(q^{-1})$ respectivamente)
3. Seleciona-se as raízes de $T(q^{-1})$, incluindo-se o efeito de $P(q^{-1})$, tal que o limite de alta frequência dado pela eq. (4.29) seja igual à 50% do ganho do

$$\text{modelo} \left(\frac{\hat{B}(1)}{\hat{A}(1)} \right).$$

O item 1 define a resposta em malha fechada do sistema além de contribuir para a redução da amplitude do sinal de controle. O item 2 atua diretamente no aumento da robustez pois quanto maior o grau de $T(q^{-1})$ maior será o limite de estabilidade (vide eq. 4.31). E, finalmente o item 3 pondera a robustez com a rejeição à perturbação de carga.

Assim, definido o polinômio $P(q^{-1})$, as raízes de $T(q^{-1})$ (τ) podem ser calculadas a partir da eq. (4.29). Para tanto, deve-se observar que, na conversão do tempo contínuo para o discreto, a frequência mais alta converge para π rad/s, ou $q^{-1} = -1$ [ROBINSON 89]. A eq. (4.29) torna-se:

$$|\Delta.A| = \left| \frac{P(-1).\hat{B}(1)}{\hat{A}(-1).T(1)} \right| \quad (4.30)$$

e considerando o item 3:

$$\left| \frac{P(-1) \cdot \hat{B}(1) (1+\tau)^n}{\hat{A}(1) (1-\tau)^n} \right| = \frac{1}{2} \left| \frac{\hat{B}(1)}{\hat{A}(1)} \right| \quad (4.31)$$

Finalmente obtém-se:

$$\tau = \frac{\beta - 1}{\beta + 1} \quad (4.32)$$

onde:

$$\beta = \sqrt[n]{\frac{1}{2} \left| \frac{\hat{A}(-1)}{\hat{A}(1) \cdot P(-1)} \right|} \quad (4.33)$$

4.6 Conclusões

Neste capítulo, a estrutura proposta para o GPCA foi apresentada. Esta baseia-se no algoritmo básico do GPC descrito no capítulo I, combinado com um algoritmo competitivo de modelos, que consiste na escolha do modelo mais apropriado, dentro de uma faixa pré-definida de modelos, a partir de um critério de adequação, descrito no capítulo II, e concluindo com o sistema de ajuste automático dos parâmetros de projeto do GPC descrito neste capítulo.

O sistema de ajuste fundamentou-se na identificação de malha aberta, a qual envolve a determinação da faixa de ruído, do atraso de transporte e do tempo de subida, e na análise da função de transferência de malha fechada, a qual permite definir regras para definição dos horizontes de predição e da ponderação da ação de controle e para a utilização das extensões do GPC (polinômios observador e seguidor de modelo).

O próximo capítulo será dedicado a mostrar os resultados dos testes do GPCA realizados em um ambiente de simulação, enfatizando aspectos do desempenho da estrutura de identificação paramétrica implementada e do sistema de ajuste automático descrito neste capítulo.

CAPÍTULO V

RESULTADOS DE SIMULAÇÃO

5.1 Introdução

Neste capítulo, o controlador GPCA implementado será testado em um ambiente de simulação de controladores adaptativos (SADECA[#]). Um conjunto de simulações permite, para os casos testados, avaliar o desempenho do controlador. As simulações se dividem em duas etapas:

- a) analisa-se a estabilidade do RELS e a sua capacidade de rastreamento de parâmetros. Também, é avaliado o comportamento da estrutura competitiva de modelos baseado no desempenho dos critérios de medida de adequação dos modelos;
- b) avalia-se o desempenho do controlador quando do controle de processos com fase não-mínima, atraso de transporte variável e variações estruturais e paramétricas.

O algoritmo implementado no GPCA, baseado no algoritmo iterativo do GPC proposto por Clarke [CLARKE 89], é descrito no apêndice B.

[#] SADECA - Sistema para Avaliação de DEsempenho de Controladores Adaptativos, desenvolvido no LCMI, para estações de trabalho. Este ambiente permite a implementação de diferentes controladores adaptativos e a realização de sequências de testes sobre diferentes processos de forma automática, através da elaboração de um banco de provas [KAMMER 92].

5.2 Rastreamento de parâmetros e estabilidade dos mínimos quadrados estendido (RELS)

O algoritmo básico do RELS foi descrito no capítulo III. Nesse capítulo, aspectos de implementação foram discutidos e as soluções mais adotadas na literatura foram apresentadas.

Nesta seção procura-se, através de resultados de simulação, mostrar o comportamento do RELS quanto a convergência e a estabilidade, quando da presença de perturbações estocásticas (ruído colorido), e o desempenho dos mecanismos utilizados em seu algoritmo básico para melhorar a sua performance.

Para aumentar a capacidade de rastreamento do estimador, um fator de esquecimento foi introduzido no algoritmo do RELS (seção 3.4). Porém, esta solução pode provocar problemas de estabilidade do estimador (fenômeno comumente conhecido como saturação).

Este problema é ilustrado através das simulações. Para isto, foi seguida uma estratégia sugerida por Tuffs [TUFFS 85], que consiste em simular diferentes níveis de excitação aplicados ao processo cujos parâmetros serão estimados. No primeiro exemplo, o sistema é excitado, por duas vezes, por um sinal PRBS de 200 amostras de comprimento aplicado com um intervalo de 200 amostras sem excitação (vide fig. 5.1 (a)). O processo simulado é representado pela seguinte equação de diferenças:

$$y(t) = 1.72y(t-1) - 0.74y(t-2) + 0.09u(t-1) + 0.08u(t-2)$$

e o modelo estimado é:

$$\Delta y = -\hat{a}_0 \Delta y(t-1) - \hat{a}_1 \Delta y(t-2) + \hat{b}_0 \Delta u(t-1) + \hat{b}_1 \Delta u(t-2) + e(t)$$

As figuras 5.1(b) a 5.1(d) mostram a convergência dos parâmetros estimados, $(\hat{a}_0, \hat{a}_1, \hat{b}_0, \hat{b}_1)$, porém observa-se na fig 5.1(e), que representa o logaritmo natural dos elementos da diagonal da matriz de covariância $P(t)$, um crescimento exponencial. Estes elementos estão relacionados às covariâncias de $\hat{\theta}(t)$ [TUFFS 85].




Figura 5.1(a) Sinal de excitação aplicado ao processo




Figura 5.1(b) Parâmetros do modelo - estimador padrão




Figura 5.1(c) Parâmetro do modelo - estimador padrão




Figura 5.1(d) Parâmetro do modelo - estimador padrão




Figura 5.1(e) Comportamento dos elementos da diagonal de $P(t)$

Para observar o efeito deste crescimento exponencial dos elementos de $P(t)$ sobre o rastreamento dos parâmetros, é suficiente injetar uma excitação mínima entre as sequências PRBS. O sinal injetado, na simulação, é um ruído de distribuição normal de amplitude, gerado via números randômicos, de desvio padrão igual a 0.0001. Este valor apesar de ser muito pequeno, causa instabilidade no RELS, como pode ser visto nas figs 5.2(a) a 5.2(c).




Figura 5.2(a) Instabilidade do estimador na presença de ruído




Figura 5.2(b) Instabilidade do estimador - parâmetro b_0




Figura 5.2(c) Instabilidade do estimador - parâmetro b_1




Figura 5.2(d) Saturação de $P(t)$ na presença de ruído

5.2.1 RELS com zona morta

Para eliminar a saturação do estimador, na literatura [ASTRÖM 89] é sugerido o congelamento da matriz de covariância e dos parâmetros estimados quando o erro de estimação for menor que uma faixa relacionada com a faixa de ruído (ver seção 3.4). Para o caso em estudo, adotou-se, inicialmente, a zona morta igual a faixa de ruído

Observa-se, claramente nas figuras 5.3(a) a 5.3(c), a estabilidade dos parâmetros estimados. Contudo, a injeção de ruído entre as sequências continua provocando o crescimento, ainda que com menor intensidade que no algoritmo sem zona morta, dos elementos diagonais de $P(t)$ (fig 5.3(d)). Com o aumento da zona morta (duas vezes a faixa de ruído), a taxa de crescimento dos elementos de $P(t)$ torna-se menor, mas não se anula, como seria desejado (fig. 5.3(e)).




Figura 5.3(a) Parâmetros do modelo - estimador com zona morta




Figura 5.3(b) Parâmetro do modelo - estimador com zona morta




Figura 5.3(b) Parâmetro do modelo - estimador com zona morta




Figura 5.3(d) Elementos da diagonal de $P(t)$ - estimador com zona morta




Figura 5.3(e) Elementos da diagonal de $P(t)$ - valor da zona morta dobrado

Assim, observa-se que, além de evitar a atualização de $P(t)$ e dos parâmetros estimados, é necessário garantir que os elementos de $P(t)$ mantenham-se limitados.

5.2.2 Fator de esquecimento vetorial variável

O algoritmo de estimação com fator de esquecimento vetorial, descrito na seção 3.4, também conhecido como algoritmo de SAELID-FOSS-TUFFS [TUFFS 85], é submetido as mesmas condições que o algoritmo com zona morta. Observa-se a boa convergência dos parâmetros (fig. 5.4(a) a (c)) e a limitação dos elementos diagonais de $P(t)$ (fig. 5.4(d)).




Figura 5.4(a) Parâmetros do modelo - esquecimento vetorial variável




Figura 5.4(b) Parâmetro do modelo - esquecimento vetorial variável




Figura 5.4(c) Parâmetros do modelo - esquecimento vetorial variável




Figura 5.4(d) Elementos da diagonal de P(t) - esquecimento vetorial variável

Nota-se, portanto, a eficiência da utilização do esquecimento vetorial variável no RELS pois, apesar da ausência de excitação persistente, os elementos da matriz de covariância mantiveram-se constantes.

5.2.3 Escolha do índice de adequação

Na seção 3.6 foram apresentados três formas de cálculo de medidas de adequação: o critério PLS (Predictive Least Square), uma modificação no enfoque Bayesiano e uma modificação no critério de verossimilhança. Nesta seção serão apresentados e discutidos os resultados obtidos em simulação do comportamento dessas formas de cálculo de medidas de adequação.

A primeira simulação realizada tinha como objetivo identificar a ordem do seguinte processo:

$$G(s) = \frac{2}{(s+1)(s+2)}$$

Esta foi realizada sob condições ideais, o que significa a ausência de ruído na saída do processo e de erro de quantização (erro dos conversores AD/DA). O tempo de amostragem foi fixado em 0.1s, o fator de esquecimento em 0.95, o grau máximo pesquisado em 3 e o sinal aplicado na entrada corresponde a uma sequencia PRBS de 100 amostras de comprimento.

As figuras 5.5(a), (b) e (c) exibem o comportamento dos índices gerados pelo critério PLS, pelo enfoque Bayesiano modificado e pelo critério de verossimilhança modificado respectivamente. Observa-se, claramente, a predominância do índice correspondente ao modelo de segunda ordem, que corresponde à ordem correta do processo que estava sendo simulado. Este exemplo serve como ilustração da eficiência dos critérios de medida quando submetidos a condições ideais.




Figura 5.5(a) Critério PLS - Índices de adequação




Figura 5.5(b) Enfoque Bayesiano modificado - índices de adequação




Figura 5.5(c) Critério de verossimilhança modificado - índices de adequação

Na segunda etapa, condições mais próximas da realidade são impostas ao sistema: ruído branco gaussiano com desvio padrão igual a 0.01 e simulação de um conversor AD/DA de 12 bits de resolução. Nesta fase, o processo inicialmente corresponde a:

$$G(s) = \frac{1}{(s+1)^3}$$

e para garantir a repetibilidade, todas as simulações foram realizadas com o tempo de amostragem igual a 0.1s (a identificação de malha aberta não é realizada) e o polinômio observador $T(q^{-1})$ é assumido constante e igual a $1-0.8q^{-1}$.

Após a inicialização em malha aberta (aplicação da sequência PRBS), o sistema fecha-se a malha (vide figura 5.6 (a) e (b)). Decorridas 1700 amostras, uma sequência de mudanças de referência é aplicada e em seguida o processo é deixado sem excitação até que em $T=4200$ amostras ocorre uma perturbação de carga do tipo degrau. Em $T=5500$ amostras uma nova sequência de mudanças de referência é aplicada e em $T=8000$ amostras ocorre uma nova perturbação de carga.




Figura 5.6 (a) Saída do processo




Figura 5.6 (b) Ação de controle

As figuras 5.7 a 5.9 representam os índices de adequação e a ordem estimada atribuídos pelo critério PLS, pelo enfoque Bayesiano modificado e pelo critério de verossimilhança modificado. Observa-se que nos intervalos que ocorrem as mudanças de referência ($T=1700$ a 2700 amostras e $T=5500$ a 6500 amostras) os critérios apresentaram bons resultados. No entanto, na ausência de excitação, os resultados tornaram-se imprecisos. Comparando-se os três métodos, neste intervalo, nota-se a superioridade dos critérios PLS e verossimilhança modificado sobre o enfoque Bayesiano modificado.




Figura 5.7(a) Critério PLS - índice de adequação




Figura 5.7(b) Critério PLS - ordem adotada




Figura 5.8 (a) Enfoque Bayesiano modificado - índice de adequação




Figura 5.8 (b) Enfoque Bayesiano - ordem adotada




Figura 5.9 (a) Critério de verossimilhança modificado - índice de adequação




Figura 5.9(b) Critério de verossimilhança modificado - ordem adotada

Prosseguindo com a simulação (vide figuras 5.10 a 5.13) em T=8000 amostras, o processo mudou para:

$$G(s) = \frac{1}{(s+1)}$$




Figura 5.10(a) Saída do processo




Figura 5.10(b) Ação de controle




Figura 5.11(a) Critério PLS - índice de adequação




Figura 5.11(b) Critério PLS - ordem adotada




Figura 5.12 (a) Enfoque Bayesiano modificado - índice de adequação




Figura 5.12(b) Enfoque Bayesiano - ordem adotada




Figura 5.13 (a) Critério de verossimilhança modificado - índice de adequação




Figura 5.13(b) Critério de verossimilhança modificado - ordem adotada

Uma sequência de mudanças de referência foi aplicada em $T=9300$ amostras e outra em $T=11800$ amostras, e em $T=11000$ e $T=13500$ amostras ocorreram perturbações de carga do tipo degrau. Durante este intervalo ($T=8000$ a 14000 amostras) o enfoque Bayesiano modificado e o critério da verossimilhança modificado foram os que apresentaram maiores índices de adequação para o modelo de primeira ordem, já o critério PLS demonstrou uma tendência a superestimação do modelo.

Em $T=14000$, o processo volta a ser de terceira ordem. No intervalo entre $T=14000$ e 22000 amostras (vide figura 5.14 a 17) é aplicado duas sequências de mudança de referência (em $T=14500$ e 18600) e duas perturbações de carga do tipo degrau (em $T=17000$ e $T=21000$). Observa-se pelos resultados apresentados que com a presença de excitação todos os métodos atribuíram índices mais elevados aos modelos de terceira ordem, tendo o PLS obtido um melhor desempenho, seguido pelo critério da verossimilhança modificado.




Figura 5.14(a) Saída do processo




Figura 5.14(b) Ação de controle




Figura 5.15(a) Critério PLS - índice de adequação




Figura 5.15(b) Critério PLS - ordem adotada




Figura 5.16 (a) Enfoque Bayesiano modificado - índice de adequação




Figura 5.16(b) Enfoque Bayesiano - ordem adotada




Figura 5.17(a) Critério de verossimilhança modificado - índice de adequação




Figura 5.17(b) Critério de verossimilhança modificado - ordem adotada

Assim, conclui-se, a partir destes resultados, que a presença de excitação é necessária para que os critérios apresentados atribuam maiores índices de adequação ao modelo correto. No entanto, o fato de que estes métodos não apresentam bom funcionamento na ausência de excitação não restringe totalmente a sua aplicação, pois a atuação do controlador só se faz presente quando alguma excitação é introduzida no sistema (mudança de referência ou perturbação de carga), e é justamente nestas ocasiões que o modelo selecionado tende a ser o modelo correto.

Apesar de que o comportamento dos métodos é bastante semelhante, o critério PLS apresentou um desempenho um pouco superior, para o caso em estudo, do que os outros dois. Isto pode ser justificado se considerarmos as figuras 5.5 (a) a (c). Nestas, observa-se que embora o índice do modelo correto (ordem 2) não tenha convergido para 1, como os outros dois

métodos, este estima, mais rapidamente, a ordem correta (2 e 3 vezes mais rápido que os critérios da verossimilhança modificado e do enfoque Bayesiano respectivamente, para o caso estudado).

Conclui-se, assim, que independentemente do critério adotado, estes não apresentam, quando da presença de ruído na saída do processo, garantia de que a ordem correta está sendo estimada. Portanto, a adoção desta técnica de identificação "on-line" da ordem do processo permite o aumento da faixa de atuação do controlador, em detrimento da sua robustez, dado que não se pode garantir que não ocorrerá subestimação da planta, durante as mudanças de referência ou nas ocorrências de perturbações.

5.3 Comportamento do GPCA em função do sistema de ajuste

Os resultados da seção 5.4 indicam que o critério PLS apresenta melhores resultados. Assim, com a estrutura do estimador definida, pode-se verificar o comportamento do GPCA, frente a processos variantes no tempo.

5.3.1 Atuação da ponderação da ação de controle em regime permanente

Para se avaliar a influência da escolha da ponderação da ação de controle, realizada pelo sistema de ajuste do GPCA, em regime permanente, adotou-se o seguinte processo e o tempo de amostragem de 0.1s:

$$G(s) = \frac{1}{(s+1)(s+2)}$$

e introduziu-se ruído branco de desvio padrão igual a 0.05, e utilizou-se o filtro $T(q^{-1})$ unitário. Nas figuras 5.18(a) e (b) são apresentados os resultados.




Figura 5.18 (a) Saída do processo - ponderação do controle em regime permanente




Figura 5.18 (a) Ação de controle - ponderação do controle em regime permanente

Inicialmente, a identificação de malha aberta é realizada, e em seguida a malha é fechada e são aplicadas duas mudanças na referência. Em $T=7500$ amostras ocorre uma perturbação de carga do tipo degrau, e em $T=10500$ amostras uma nova mudança na referência. Nota-se que, após as mudanças de referência e perturbações de carga, a ação de controle torna-se, gradativamente, mais suave, até que se estabiliza em um valor fixo, sem que isto interfira na sua resposta as mudanças ocorridas (referência e perturbação).

5.3.2 Atraso de transporte variável

As primeiras simulações foram realizadas em um processo com tempo de atraso de transporte variável. O processo é apresentado a seguir (o ruído injetado na saída do processo é branco gaussiano com desvio padrão igual a 0.03):

$$G(s) = \frac{e^{-Ts}}{(s+1)(s+2)}$$

A fig. 5.19(a) e (b) são a saída do processo e a ação de controle respectivamente. Inicialmente é aplicada a sequência PRBS e a seguir o sistema é posto em malha fechada. São realizadas mudanças na referência e em seguida é aplicado uma perturbação de carga do tipo degrau. O sistema cujo tempo de atraso de transporte inicial vale 1s, manteve-se com boa performance. Em $T=2000$ amostras, o atraso de transporte muda bruscamente para 4s e em seguida é aplicada uma sequência de mudança de referência e uma perturbação de carga do tipo degrau. Em $T=8000$ amostras, o tempo de atraso de transporte volta a valer 1s e a mesma sequência de mudança de referência e perturbação de carga é aplicada.




Figura 5.19(a) Saída e referência -processo com atraso de transporte variável




Figura 5.19(b) Ação de controle -processo com atraso de transporte variável

O controlador mostrou-se capaz de adaptar-se à variação do atraso, apesar do grande transitório apresentado, porém na prática mudanças discretas no atraso de transporte não são comuns, conseqüentemente estes transitórios podem ser de menor intensidade em aplicações reais.

5.4.3 Processos com fase não-mínima

O seguinte processo foi utilizado para verificar o comportamento do GPCA controlando sistemas com zero instável.

$$G(s) = \frac{s - \tau}{(s+1)(s+2)(s+\tau)}$$

A sequência de eventos aplicada (vide fig. 5.20(a) e (b)) é semelhante a aplicada no item anterior. Após a inicialização ($\tau=2$) o processo é submetido a mudança na referência e uma perturbação de carga é aplicada. Em $T=1700$ amostras, τ assume valor 4s, e uma nova sequência de mudança de referência e uma perturbação de carga são aplicadas. Em $T=5000$ amostras τ volta ao valor 2s e a mesma sequência é aplicada.




Figura 5.20(a) Saída e referência - processo com fase não-mínima




Figura 5.20(b) Ação de controle - processo com fase não mínima

Observa-se uma boa adaptação do controlador frente às mudanças impostas ao processo e a ausência de transitórios pronunciados.

5.4.4 Variações paramétricas

O comportamento do controlador frente a variações paramétricas é verificado através do seguinte processo:

$$G(s) = \frac{T_1 T_2}{(s + T_1)(s + T_2)}$$

O sistema é inicializado com $T_1=4$ e $T_2=8$, e em seguida uma sequência de mudanças de referência e perturbação de carga são aplicadas (fig. 5.21(a) e (b)).




Figura 5.21(a) Saída - processo com variação paramétrica




Figura 5.21(b) Ação de controle - processo com variação paramétrica

Em $T=700$ amostras, os parâmetros foram chaveados para $T_1=0.5$ e $T_2=1$, e a sequência de mudanças de referência e perturbação de carga foram aplicadas. Finalmente em $T=1300$ amostras, os parâmetros voltaram a valer $T_1=4$ e $T_2=8$ e novamente a sequência de eventos foi aplicada.

Verificou-se, que o controlador GPCA conseguiu acompanhar as variações paramétricas mantendo uma boa performance.

5.4.4 Variação estrutural

Concluindo a investigação, o controlador GPCA foi testado quando o processo controlado sofreu mudanças estruturais (fig. 5.22(a) e (b)). O processo inicial é mostrado em seguida:

$$G(s) = \frac{1}{(s+1)}$$

Após a identificação inicial, uma sequência de mudanças de referência e perturbação de carga são aplicadas. Em $T=2200$ amostras, o processo passa para segunda ordem (os dois pólos em -1), e em $T=4000$, para terceira ordem (os três pólos em -1). Em seguida ($T=6500$) a ordem é reduzida de uma unidade, voltando a ser de segunda ordem, e em $T=9500$, o processo volta a ser de primeira ordem.




Figura 5.22(a) Saída - processo com variação estrutural




Figura 5.22(b) Ação de controle - processo com variação estrutural

Os resultados mostram a robustez do GPCA frente a este tipo de mudanças estruturais.

5.5 Conclusões

Neste capítulo foi ilustrado, por meio de simulação, o fenômeno da saturação do estimador. Também foi mostrado o comportamento do estimador quando da utilização de recursos que evitam este fenômeno como a zona morta e o esquecimento vetorial variável.

A estrutura competitiva de modelos foi testada e os critérios PLS, verossimilhança modificada e o enfoque Bayesiano modificado foram avaliados. Observou-se um comportamento pouco confiável para os três critérios estudados, visto que na ausência de excitação e presença de ruído, estes não estimaram a ordem correta. Isto ocorre porque, na ausência de excitação, os modelos convergem para um ganho estático, tornando-se equiprováveis. De qualquer forma, a proposta inicial de desenvolver um controlador de propósito geral foi mantida, apesar deste apresentar uma estrutura pouco confiável. Apesar disto, poucos foram os casos em que o sistema tenha se tornado instável. O que normalmente ocorria, quando havia a estimação incorreta da ordem do modelo era (principalmente na subestimação) a presença de transitórios elevados, que em compensação forneciam excitação suficiente para que o critério de medida de adequação pudesse fornecer a ordem correta. Na conclusão geral do trabalho, no capítulo VII, sugere-se possíveis mecanismos que podem permitir o aumento da robustez do controlador, mantendo-se a sua faixa de aplicação.

Na segunda etapa processos variantes no tempo foram controlados utilizando o GPCA proposto. Os resultados mostram uma boa capacidade de adaptação do controlador, que manteve um bom desempenho ao controlar uma grande faixa de processos. A maior dificuldade de aplicação deste controlador, como da maioria dos controladores adaptativos, é a falta de confiabilidade, já que estes apresentam características não lineares inerentes em seu algoritmo

O próximo capítulo dedica-se a apresentação de resultados obtidos em ensaios experimentais com o GPCA. Estes ensaios consistiram na utilização do GPCA no controle de uma planta piloto de laboratório, que permitia avaliar o controlador em condições reais de funcionamento.

CAPÍTULO VI

APLICAÇÃO EM PLANTA PILOTO

6.1 Introdução

Este capítulo resume os principais resultados obtidos com a aplicação do GPCA em uma planta piloto de laboratório. Os ensaios realizados tinham como objetivo permitir a verificação do comportamento do controlador em condições reais de funcionamento.

6.2 Descrição da planta piloto

A planta piloto consiste no controle do nível de um sistema composto por dois tanques acoplados e de um composto por um tanque com forma cônica.

6.2.1 Sistema de Tanques acoplados

O primeiro processo controlado foi o de nível de um sistema de tanques acoplados mostrado na figura 6.1. Este sistema permite executar mudanças estruturais (ordem do processo) através da abertura e fechamento das válvulas de ajuste manual V1, V2 e V3. Ambos os tanques tem forma cilíndrica e 2m de altura. O *tanque 1* tem diâmetro igual a 20 cm e o *tanque 2* diâmetro igual a 10 cm. O computador utilizado foi um PC 386/33 Mhz e uma placa conversora AD/DA de 10 bits de resolução.

Com as válvulas V1 e V2 fechadas e V3 totalmente aberta, o sistema assume dinâmica de 1ª ordem. A função de transferência linearizada em torno do ponto de operação $h_0=h_2$:

$$\frac{h_2(s)}{Fe(s)} = \frac{K_p}{\tau s + 1} \quad (6.1)$$

onde
$$K_p = \frac{2\sqrt{h_0}}{K_v}$$

K_p : ganho do processo

K_v : ganho da válvula V4 ($K_v = 6,68723 \cdot 10^{-5} \frac{m^{5/2}}{s}$), levantado experimentalmente.

e $\tau = A_2 \cdot K_p$, com A_2 a área da seção transversal do tanque 2.

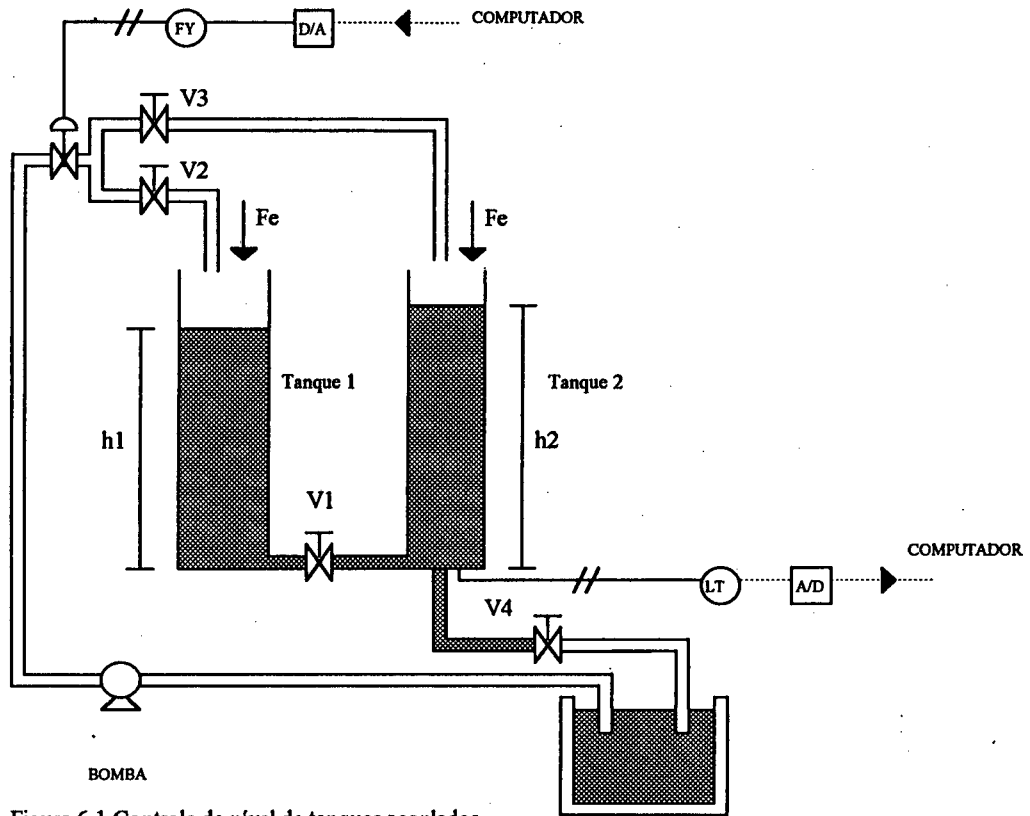


Figura 6.1 Controle de nível de tanques acoplados

Abrindo-se as válvulas V1 e V2 e fechando-se a válvula V3, o sistema passa a ter dinâmica de 2ª ordem. A função de transferência linearizada do processo é:

$$\frac{h_2(s)}{Fe(s)} = \frac{K_p}{(1 + \tau_1 s)(1 + \tau_2 s)} \quad (6.2)$$

onde $K_p = \frac{2\sqrt{h_0}}{K_v}$ e h_0 é o ponto de operação

e τ_1 e τ_2 são tais que:

$$\begin{cases} \tau_1 \cdot \tau_2 = \frac{A_1 \cdot A_2 \cdot K_p}{K'_v} \\ \tau_1 + \tau_2 = K_p(A_1 + A_2) + \frac{A_2}{K'_v} \end{cases} \quad (6.3)$$

onde K'_v é o ganho da válvula V1 (nesta planta as válvulas V1 e V4 são iguais, portanto $K'_v = K_v$), A_1 é a área da seção transversal do tanque 1 e Fe_0 , a vazão de entrada nominal para o ponto de operação h_0 .

6.2.2 Tanque cônico

O segundo processo consiste no controle de nível de um tanque cônico (fig. 6.2), cujas dimensões são mostradas na fig. 6.3. Este processo apresenta características altamente não lineares.

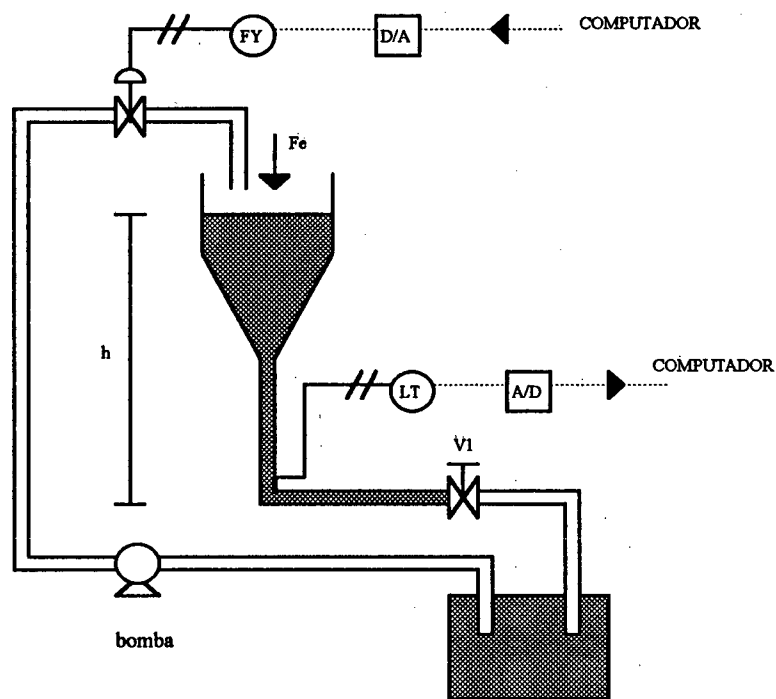


Figura 6.2 Controle de nível de tanque com forma cônica

A função de transferência linearizada do nível pela vazão de entrada em todas as seções é dada por:

$$\frac{h(s)}{Fe(s)} = \frac{K_p}{\tau s + 1} \tag{6.4}$$

onde $K_p = \frac{2\sqrt{h_0}}{K_v}$
 h_0 : ponto de operação

K_p é o ganho do processo

K_v : ganho da válvula ($K_v = 6,68723 \cdot 10^{-5} \frac{m^{5/2}}{s}$), levantado experimentalmente.




fig. 6.3 Dimensões do tanque cônico

A diferença da função de transferência entre as diferentes seções do tanque cônico está no cálculo da constante de tempo τ

Seção 1:
$$\tau = \frac{\pi D^2}{4} K_p \quad (6.5)$$

Seção 2:
$$\tau = \xi K_p \quad (6.6)$$

com
$$\xi = 1,2667 \cdot 10^{-4} + 5,4780 \cdot 10^{-3} \cdot x + 5,9223 \cdot x^2$$

e
$$0 \leq x \leq 0,5$$

e Seção 3:
$$\tau = \frac{\pi d^2}{4} K_p \quad (6.7)$$

A tabela da fig.6.4 mostra, para diversos pontos de operação, o ganho e a constante de tempo do processo.

Observa-se, a partir dos dados mostrados na tabela da figura 6.4 que este processo é fortemente não linear, pois apresenta, para cada ponto de operação, uma dinâmica diferente. A parte cônica do tanque, com seção menor, é a que tem dinâmica mais rápida (constante de tempo $\cong 3s$) e a parte superior, a mais lenta (constante de tempo $\cong 560s$).

x(m)	h(m)	Kp(m/m ³ /s)	cte. tempo(s)
—	1,65	38.417,20	678,89
—	1,40	35.387,33	625,34
—	1,15	32.072,49	566,78
0,05	1,14	31.932,74	543,83
0,25	0,90	28.372,98	147,47
0,49	0,70	25.022,62	13,73
—	0,65	24.112,39	3,05
—	0,40	18.915,32	2,39
—	0,20	13.375,15	1,69

Figura 6.4 Ganho e constante de tempo do tanque de forma cônica para vários pontos de operação

6.3 Controle de nível de tanques acoplados

O objetivo do experimento é verificar o comportamento do GPCA quando ocorrem mudanças estruturais no processo. Para tanto, utilizou-se o sistema composto pelos tanques acoplados, amostrados a uma taxa de 10s.

Inicialmente as válvulas V1 e V2 foram fechadas e V3 foi aberta Assim, o processo assumiu dinâmica de primeira ordem. Após a inicialização (injetou-se uma sequência PRBS de 20 amostras de comprimento), fechou-se a malha no ponto de operação correspondente a $h_2=0.75 m$ (vide fig 6.5) e aplicou-se duas mudanças no "set-point" ($0.9m$ e $0.75m$). Em $T \approx 6000$ amostras aumentou-se a abertura da válvula V4, o que significou a introdução de uma perturbação de carga. Em $T \approx 7000$ amostras, as válvulas V1 e V2 foram abertas e V3 foi fechada, o sistema, então, passou a ter dinâmica de segunda ordem. E, como os níveis dos tanques eram diferentes ($h_1 > h_2$), ocorreu simultaneamente uma perturbação de carga. Novas mudanças no "set-point" foram aplicadas em seguida ($0.5m$ e $0.75m$), e em $T \approx 9500$ amostras, reduziu-se a abertura da válvula V4, impondo-se uma perturbação de carga ao sistema. Em $T \approx 10000$ amostras as válvulas V1 e V2 foram fechadas e V3 foi aberta. Assim, o sistema voltou a ter dinâmica de primeira

ordem. Novas mudanças de "set-point" foram aplicadas ($0.9m$ e $0.75m$) e em $T \approx 12000$ amostras introduziu-se uma nova perturbação de carga, ao se aumentar a abertura da válvula V4.




Figura 6.5 (a) Tanques acoplados - Saída do processo




Figura 6.5 (b) Tanques acoplados - ação de controle

Observou-se um desempenho satisfatório do controlador, visto que, este conseguiu adaptar-se às variações estruturais, rejeitando as perturbações de carga e seguindo a referência.

6.4 Controle de nível de tanque de forma cônica

No primeiro experimento realizado com o tanque cônico, (vide fig. 6.6 (a) e (b)) o controlador foi inicializado no ponto de operação correspondente a $h=0.9m$ e amostrado a uma taxa de 5s (o comprimento da sequência PRBS foi de 30 amostras). Em seguida foi aplicada uma sequência crescente de mudanças no "set-point" (incrementos de $0.05m$) até o limite superior da parte cônica do tanque ($h=1.15m$). Em seguida uma sequência decrescente de mudanças no "set-point" foi aplicada até o retorno do "set-point" ao valor inicial ($0.95m$). Nota-se que, apesar dos transitórios apresentados e das componentes de alta frequência na ação de controle, o sistema apresentou desempenho satisfatório, dado que o ruído presente no sinal de saída era elevado

(0.02m) e que o processo é fortemente não-linear, além disso, a ação de controle não foi penalizada através do parâmetro λ .




Figura 6.6(a) Tanque com forma cônica - saída




Figura 6.6(b) Tanque com forma cônica - ação de controle

Um outro experimento semelhante ao anterior foi realizado. Porém, desta vez, aplicou-se mudanças de "set-point" mais significativas. Nas figuras 6.7 (a) e (b), os resultados são apresentados. O processo foi inicializado em $h=0.95m$, com tempo de amostragem igual a 5s. A partir de $T \approx 200$ amostras, ocorreram mudanças no "set-point" (0.75m, 0.95 e 1.15m). Em $T \approx 600$ amostras, reduziu-se a abertura da válvula de saída V1, de forma a perturbar o sistema. Novas mudanças no "set-point" são aplicadas (0.95m e 0.75m). Em $T \approx 1000$ amostras aumentou-se a abertura da válvula de saída V1. Este aumento na abertura foi suficiente para esvaziar completamente o tanque, pois para este ponto de operação do sistema a perturbação foi muito grande. Rejeitada a perturbação, novas mudanças no "set-point" foram aplicadas (0.95m e 1.15m).

Notou-se, de acordo com os experimentos realizados, que o sistema respondeu satisfatoriamente, rejeitando as perturbações de carga e seguindo o "set-point".

Um outro ponto importante observado foi a necessidade de se inicializar o controlador na parte mais rápida do processo. Isto porque o controlador proposto baseia-se na identificação em malha aberta para definir o tempo de amostragem. Assim, se a inicialização fosse realizada em

ponto de operação em que o sistema tivesse dinâmica lenta, o tempo de amostragem adotado poderia ser muito grande, o que poderia tornar o sistema em malha fechada instável.




Figura 6.7 (a) - Saída - Tanque com forma cônica




Figura 6.7 (b) - Ação de controle - Tanque com forma cônica

Para ilustrar este fato, o seguinte experimento foi realizado (vide fig 6.8(a) e (b)). Inicializou-se o processo no ponto de operação correspondente a $0.9m$ com uma taxa de amostragem de $5s$. Em seguida mudou-se o "set-point" para $1.0m$ em $T \approx 180$ amostras. Em $T \approx 250$ amostras o "set-point" voltou a assumir o valor $0.9m$. O sistema comportou-se de forma satisfatória para estas mudanças de ponto de operação. No entanto, em $T \approx 300$ amostras, aplicou-se uma mudança de "set-point" para um ponto de operação onde a dinâmica do processo é mais rápida ($h=0.75m$). Porém, apesar do grande transitório, o sistema manteve-se estável. Assim, em $T \approx 500$ amostras, aplicou-se uma outra mudança no "set-point" ($h=0.6m$), que ainda foi acompanhada pelo sistema. Mas em $T \approx 600$ amostras, o "set-point" foi fixado em $0.3m$, e o sistema, então entrou em oscilação, pois a dinâmica do processo era mais rápida ($\approx 2s$) que o tempo de amostragem ($5s$), definido com base na identificação em malha aberta.




Figura 6.8(a) Saída do processo - instabilidade devido a inicialização incorreta do controlador




Figura 6.8(b) Ação de controle - instabilidade devido a inicialização incorreta do controlador

6.5 Conclusões

Neste capítulo, foram apresentados os resultados obtidos em ensaios experimentais realizados numa planta piloto de laboratório. A planta consistia em um controle de nível de tanques acoplados que permitiam variações estruturais, e em um controle de nível de um tanque com forma cônica que possuía características fortemente não lineares.

A combinação do erro de quantização, devido ao uso de um conversor de baixa resolução (10 bits), com o ruído elevado presente na saída do processo, impõe condições desfavoráveis para utilização de um controlador com estimação "on-line" dos parâmetros do modelo. No entanto, os resultados obtidos são satisfatórios, pois o sistema acompanhou todas as mudanças de "set-point" aplicadas e rejeitou as perturbações de carga que lhe foram impostas.

Contudo, o sinal da ação de controle apresentou componentes de alta frequência com amplitude elevadas, apesar da utilização do polinômio observador $T(q^{-1})$. Este fato deve ser evitado, para não se danificar, prematuramente, o atuador.

CAPÍTULO VII

CONCLUSÕES E PERSPECTIVAS

Os controladores automáticos para plantas industriais devem ter capacidade para poder enfrentar as características dos processos sob controle. Em especial, nas plantas químicas, estas características se traduzem por perturbações, em geral, não mensuráveis, ruído, interação entre malhas de controle, limitações dos atuadores, não-linearidades e atraso de transporte. Além disto, em situações onde existe variação da dinâmica do processo em função do tempo ou freqüentes mudanças das condições de operação sobre regiões não-lineares, é desejável que o controlador tenha a capacidade de se adaptar ao longo da operação para compensar estas particularidades e melhorar o seu desempenho. Dentro desta perspectiva, as técnicas de Controle Adaptativo apresentam-se como uma alternativa interessante para o controle de processos em ambientes industriais.

Neste trabalho, apresentou-se a implementação, teste e avaliação de desempenho de um controlador adaptativo, de propósito geral, baseado em um algoritmo de controle preditivo.

Dentre os inúmeros algoritmos de controle preditivo sugeridos na literatura, o algoritmo desenvolvido por Clarke [CLARKE 87], GPC-Generalized Predictive Control, foi adotado em virtude dos bons resultados quando da aplicação deste em processos industriais [CLARKE 89].

No desenvolvimento do GPC adaptativo (GPCA), voltado para aplicação em processos industriais, preocupou-se em se implementar um algoritmo de estrutura robusta e de propósito geral. Para tal, o método dos mínimos quadrados recursivo estendido (RELS) foi adotado e mecanismos que permitem aumentar a sua robustez e adaptabilidade foram implementados, assim como: zona morta e fator de esquecimento vetorial variável. Concomitantemente ao estimador, implementou-se um algoritmo de estimação recursiva da ordem do modelo com o objetivo de rastrear eventuais mudanças estruturais do processo. O algoritmo implementado baseia-se em uma Estrutura Competitiva de Modelos, que a partir de um índice de adequação e de uma faixa de modelos dada, define qual o modelo mais apropriado para cada instante de amostragem.

Comparou-se os índices de adequação obtidos pelo critério PLS (Predictive Least Square), pelo enfoque Bayesiano modificado e pelo critério de Verossimilhança modificado. Observou-se que os critérios Bayesiano modificado e Verossimilhança modificado atribuem os maiores valores aos índices de adequação que correspondem a ordem correta da planta. No entanto, o critério PLS apresentou uma convergência mais rápida desses índices. Como os critérios só funcionam corretamente durante o transitório (período no qual há excitação no sistema), e o critério PLS é o mais rápido, este foi adotado na estrutura competitiva de modelos.

Visando-se a aplicação industrial do GPCA e, portanto, considerando que os usuários (engenheiros e operadores de planta) não possuem conhecimento sobre as teorias de Controle Adaptativo e Preditivo foi especificado e implementado um sistema de ajuste automático. Este sistema de ajuste baseia-se na identificação em malha aberta do processo e nos resultados obtidos a partir da análise da função de transferência de malha fechada para determinar os parâmetros do controlador e redefinir o tempo de amostragem. A redefinição do tempo de amostragem se faz necessária pois, em geral, não se conhece o atraso de transporte e o tempo de subida, cujas relações com o tempo de amostragem, definem o esforço computacional necessário à implementação do algoritmo de controle.

Para aumentar a robustez do sistema em malha fechada, a utilização do polinômio observador foi imprescindível. Observou-se que com o uso deste polinômio, as componentes de alta frequência do sinal de controle foram filtradas, e conseqüentemente, a robustez do sistema aumentada. A definição da ordem e das raízes do polinômio observador, baseada na análise da robustez do sistema em malha fechada, é realizada a cada amostragem em função do modelo estimado. Duas faixas de valores limites para as raízes do polinômio observador ($0.1 < \tau < 0.95$ e $0.4 < \tau < 0.95$) foram utilizadas. No entanto, não foi possível definir, para o conjunto de simulações realizadas, com qual das faixas o GPCA apresentou melhores resultados. Conclui-se que, um estudo, em profundidade, da influência do polinômio observador no desempenho do GPCA, pode permitir a elaboração de regras que possibilitem o aumento de sua robustez.

O desempenho do controlador GPCA implementado foi exaustivamente testado e avaliado utilizando um ambiente de simulação de controladores adaptativos que permite automatizar a sequência de testes sobre um banco de provas. Os resultados mostraram um bom desempenho do controlador em uma faixa grande de processos com dinâmica variante no tempo.

Ensaio experimentais foram realizados em uma planta piloto de laboratório objetivando o controle de nível de um sistema de tanques acoplados (processo de estrutura variável) e de um tanque cônico (processo com característica não-linear). Os resultados obtidos mostraram um bom desempenho do controlador implementado, frente a mudanças de referência e perturbações de carga sobre diferentes pontos de operação do sistema.

Entretanto, verificou-se no desenvolvimento do trabalho que o algoritmo do GPCA pode gerar consideráveis transitórios ou até tornar o sistema instável, quando o modelo estimado diverge do modelo real. Estes transitórios apesar de serem indesejáveis, na maioria dos casos fornecem informações suficientes para que o estimador obtenha um modelo mais adequado. Soluções para este problema foram discutidas, como por exemplo: o "reset" da matriz de covariância. Porém, este mecanismo não foi implementado devido a que não se ter conseguido identificar se os transitórios presentes na saída do processo deviam-se a perturbações paramétricas ou a perturbações de carga.

Como perspectivas deste trabalho propõe-se:

- a realização de um estudo detalhado do estimador, parte essencial da estrutura do GPCA, de forma a torna-lo robusto;
- o aperfeiçoamento do sistema de ajuste automático do GPCA, permitindo definir a resposta de malha fechada através da escolha do polinômio seguidor de modelo $P(t)$;
- a especificação e implementação de um sistema Supervisor do controlador GPCA para garantir a estabilidade do sistema e o seu correto funcionamento em um ambiente industrial;
- o estudo de uma estratégia de controle redundante consistente na incorporação de um algoritmo robusto operando em modo "stand-by" com o controlador GPCA, para aumentar a confiabilidade do controlador;
- a extensão deste trabalho para o caso multivariável tendo em vista as características das plantas industriais.

Finalmente, fechando o ciclo de desenvolvimento (projeto, implementação, validação, testes e avaliação de desempenho) de um controlador, este deverá ser testado em campo, isto é sobre plantas industriais.

APÊNDICE A

EQUAÇÃO DIOFANTINA

Seja a equação:

$$3X + 2Y = 5 \quad ; X, Y \in \mathbb{N} \quad (\text{A.1})$$

Esta equação é conhecida como Equação diofantina em homenagem a Diophantus (≈ 300 A. C.), um dos inventores da Álgebra.

Uma solução óbvia é $X=1$ e $Y=1$. Porém, outras soluções podem ser encontradas se aumentar X de duas unidades e diminuir Y de três unidades. Assim, se X_0 e Y_0 satisfazem a equação (A.1), então outra solução é dada por:

$$\begin{aligned} X &= X_0 + 2n & n &\in \mathbb{N} \\ Y &= Y_0 - 3n \end{aligned} \quad (\text{A.2})$$

A equação (A.1) pode ser expressa como:

$$aX + bY = c \quad \text{onde } a, b, c \in \mathfrak{R} \quad (\text{A.3})$$

$$X, Y \in \mathbb{N}$$

Os números inteiros e os polinômios, com coeficientes reais, obedecem as mesmas regras.

$$AX + BY = C \quad ; A, B, C, \text{ polinômios conhecidos} \quad (\text{A.4})$$

$$X, Y, \text{ polinômios}$$

A equação (A.4) é conhecida como equação diofantina (equação polinomial linear).

Os números inteiros e os polinômios podem ser multiplicados e somados usando as regras gerais da álgebra. Porém, a divisão de dois números inteiros (ou polinômios) não resultam necessariamente em um inteiro (ou polinômio). Isto é expresso na terminologia algébrica, como: inteiros e polinômios com coeficientes reais; ou seja; anéis.

TEOREMA: Sejam A, B, C polinômios com coeficientes reais. Então, a equação de DIOFANTINA tem uma solução se e somente se o maior fator comum (m.f.c) de A e B divide C .

$$AX + BY = C \quad (1)$$

$$\left. \begin{matrix} X_0 \\ Y_0 \end{matrix} \right\} \text{ é solução} \Rightarrow \begin{cases} X = X_0 + QB \\ Y = Y_0 - QA \end{cases} \text{ é também solução, onde } Q \text{ é um} \\ \text{polinômio arbitrário.}$$

Se a solução existe \Rightarrow é possível encontrar infinitas soluções através da adição ou subtração dos múltiplos de A e B .

COROLÁRIO: Existe uma única solução para (1) tal que

$$\begin{cases} \deg X < \deg B \\ \deg Y < \deg A \end{cases}$$

PROVA:

Assumimos que: $\deg A \geq \deg B$

Sejam: $A_0 = A$ $Q_1 = \text{polinômio quociente}$
 $A_1 = B$ $A_2 = \text{polinômio resto}$

então, $A_0 = A_1 Q_1 + A_2$ onde $\deg A_2 < \deg A_1$

Dividindo A_1 por A_2 tem-se

$$A_1 = A_2 Q_2 + A_3$$

Repetindo este procedimento tem-se:

$$\begin{aligned} A_0 &= A_1 Q_1 + A_2 \\ A_1 &= A_2 Q_2 + A_3 \\ A_2 &= A_3 Q_3 + A_4 \\ &\vdots \quad \vdots \quad \vdots \\ A_{n-2} &= A_{n-1} Q_{n-1} + A_n \\ A_{n-1} &= A_n Q_n + A_{n+1} \end{aligned}$$

mas $A_{n+1} = 0$ então, a equação acima fica

$$\frac{A_{n-1}}{A_n} = Q_n$$

onde A_{n+1} é o primeiro polinômio igual a zero. Desde que:

$$\deg A_0 > \deg A_1 > \deg A_2 > \dots > \deg A_{n+1}$$

o algoritmo deve terminar em um número finito de passos. O algoritmo é denominado de "ALGORITMO de EUCLIDES".

$$A_{n+1} = 0 \Rightarrow \frac{A_{n-1}}{A_n} = Q_n$$

o que implica que A_{n-1} é divisível por A_n .

∴ o polinômio A_n é o MÁXIMO COMUM DIVISOR de A_{n-1}

$$\begin{aligned} A_{n+1} &= 0 \\ A_{n-1} &= A_n Q_n \\ A_{n-2} &= A_{n-1} Q_{n-1} + A_n = A_n Q_n Q_{n-1} + A_n \end{aligned}$$

Portanto, se A_n é fator de A_{n-1} e A_{n-2} , então será também o maior fator comum.

Se $A_n = 0$ implica que contradiz a hipótese de que o algoritmo termina com $A_{n+1} = 0$. Portanto, A_n é o MAIOR FATOR COMUM de $A_0 = A$ e $A_1 = B$.

Então, a equação (1) pode ser escrita como:

$$AX + BY = (A'X + B'Y)A_n = C$$

A equação acima não tem solução a menos que A_n seja também fator comum de C .

$$A'X + B'Y = \frac{C}{A_n}$$

Se A e B não tem fatores comuns então $A_n = 1$ (m.f.c.)

$$\begin{aligned}
A_{n+1} &= 0 \\
A_{n-1} &= IQ_n \\
A_{n-2} &= A_{n-1}Q_{n-1} + A_n = Q_nQ_{n-1} + I \Rightarrow I = A_{n-2} - Q_nQ_{n-2} \\
A_{n-3} &= A_{n-2}Q_{n-2} + A_{n-1} = (Q_nQ_{n-1} + I)Q_{n-2} + Q_n
\end{aligned}$$

Então, tem-se

$$\begin{aligned}
I &= A_{n-2} - Q_{n-1}A_{n-1} \\
A_{n-1} &= A_{n-3} - A_{n-2}Q_{n-2} \\
I &= A_{n-2} - Q_{n-1}(A_{n-3} - A_{n-2}Q_{n-2}) \\
I &= A_{n-2} - Q_{n-1}A_{n-3} + Q_{n-1}A_{n-2}Q_{n-2} \\
I &= -Q_{n-1}A_{n-3} + (I + Q_{n-1}Q_{n-2})A_{n-2}
\end{aligned}$$

$$\Rightarrow I = U_{n-3}A_{n-3} + V_{n-2}A_{n-2}$$

Procedendo de forma recursiva (para $n=3$):

$$\begin{aligned}
I &= U_0A_0 + V_1A_1 \\
I &= U_0A + V_1B
\end{aligned}$$

Portanto, a solução da equação (1) é:

$$\begin{aligned}
X &= U_0C \\
Y &= V_1C
\end{aligned}$$

PROVA:

$$I = U_{n-3}A_{n-3} + V_{n-2}A_{n-2}$$

Multiplicando ambos os membros da equação acima por C tem-se:

$$\begin{aligned}
C &= CU_0A + CV_1B \\
C &= Xa + YB \\
AX + BY &= C
\end{aligned}$$

APÊNDICE B

ALGORITMO ITERATIVO DO GPC

Na prática a equação diofantina, descrita no cap. II, não é resolvida recursivamente. Na realidade, utiliza-se um algoritmo iterativo que consiste em cinco passos que serão descritos a seguir [CLARKE 89]:

Passo1: Cálculo da resposta ao degrau G_j .

$$g_{-k} = 0 \quad \forall k \geq 0$$

For $j = 1, N_2$

{

$$g_j = -\sum_{i=1}^j a_i g_{j-i} + \sum_{i=0}^{j-1} b_i$$

}

Se $P(q^{-1}) \neq 1$, convolve-se $G(q^{-1})$ com $P(q^{-1})$.

Passo2: Cálculo da resposta livre do sistema.

For $j = 1, N_2$

{

$$y^{*f}(t+j) = -\sum a_i y^{*f}(t+j-i) + \sum b_i u^{*f}(t+j-i)$$

onde $y^{*f}(t+k) = y^f(t+k)$ para $k \leq 0$

e calcula-se $u^{*f}(t+j)$ assumindo - se que:

$$u(t+N_2-1) = u(t+N_2-2) = \dots = u(t) = u(t-1)$$

}

Passo 3: Calcula-se $f(t+j)$ convoluindo-se $y^{*f}(t+j)$ com $\frac{T(q^{-1})}{\Delta}$

Passo 4: Cálculo de $[G^T G + \lambda I]^{-1}$ usando-se $N_2 - N_1 + 1$ chamadas recursivas do procedimento para atualização da inversa na forma U-D fatorada.

$$z = 0$$

$$P = \frac{I}{\lambda}$$

For $j = N_1, N_2$

{

$$r_j^T = \begin{bmatrix} \overbrace{g_j \cdots g_1}^{N_j \times 1} & 0 \cdots 0 \end{bmatrix}$$

$$P = P - P.r_j(1 + r_j^T P.r_j)^{-1} r_j^T P$$

$$z = z + r_j(y_r(t+j) - f(t+j))$$

}

Passo 5: Calcula-se $\Delta u(t) = [1 \dots 0]^T P Z$

BIBLIOGRAFIA

[ABREU 92]

ABREU A., BOLZAN A., PAGANO D., "Un Estudio Comparativo de Dos Controladores Industriales", V Congreso Latinoamericano de Control Automático, La Habana, Cuba, 1992.

[AKAIKE 77]

AKAIKE H., "On Entropy Maximization Principle", Applications of Statistics, North-Holland, Amsterdam, pp. 27-41, 1977.

[ASTROM 73]

ASTROM K.J. & WITTENMARK, B., "On Self-tuning Regulators", Automatica, vol. 9, pp. 185-199, 1973.

[ASTROM 80]

ASTROM K.J. & WITTENMARK, B., "Self-tuning Controllers Based on Pole-zero Placement". Proc. IEE-D, vol. 127, pp.120-130, 1980.

[ASTROM 84]

ASTROM K.J. & WITTENMARK, B., "Computer Controlled Systems - Theory and Design". Prentice Hall, New Jersey, 1984.

[ASTROM 89]

ASTROM K.J. & WITTENMARK, B., "Adaptive Control". Addison-Wesley Publishing Company, 1989.

[BIERMAN 75]

BIERMAN, G.J., "Measurement Updating Using the U-D Factorization". Proc. IEEE Control and Decision Conf., Houston, Texas, pp. 337-346, 1975.

[BITMEAD 90]

BITMEAD R., GEVERS M., WERTZ V., "Adaptive Optimal Control: the Thinking Man's GPC". Prentice-Hall, 1990.

[BOLZAN 91]

BOLZAN, A. & LIMA, E.L., "Controle de um Reator Semi-batelada Piloto Usando um Controlador Preditivo-adaptativo". XIII Congreso Latinoamericano de Ingeniería Química, Argentina, 1991.

[BOLZAN 91]

BOLZAN, A., "Ajuste e Implementação de um Controle Adaptativo para Reator Semi-batelada". Tese de Doutorado, COPPE/UFRJ, Dezembro 1991.

[BORDENEUVE 90]

BORDENEUVE-GUIBE, JOEL, *Commande Predictive Adaptative a des procedes Thermiques*. These "DU" Doctorat de L'Universite Paul Sabatier, 1990.

[CAMACHO 92]

CAMACHO, EDUARDO F. & CARLOS BORDON, "Reglas del tipo Ziegler-Nichols para Control Predictivo Generalizado". V Congreso Latinoamericano de Controle Automático. pp. 88-93, Feb. 1992.

[CLARKE 75]

CLARKE, D.W. & GAWTHROP, P.J., "Self-tuning Controller". Proc. IEE-D, vol. 122, pp. 929-934, 1975.

[CLARKE 79]

CLARKE, D.W. & GAWTHROP, P.J., "Self-tuning Control". Proc. IEE-D, vol. 126, pp. 633-640, 1979.

[CLARKE 84]

CLARKE, D.W., "Self-tuning Control of Nonminimum-phase Systems". Automatica, vol. 20, pp. 501-517, 1984.

[CLARKE 85]

CLARKE, D.W., "Implementation of Self-tuning Controllers in Self-tuning and Adaptive Control: Theory and Applications". Peter Peregrinus, London, 1985.

[CLARKE 87]

CLARKE, D.W., MOHTADI, C. & TUFFS, P.S., "Generalized Predictive Control - Part I. The Basic Algorithm". Automatica, vol. 23, pp. 137-148, "Part II - Extensions and Interpretations". Automatica, vol. 23, pp. 149-160, 1987.

[CLARKE 89]

CLARKE, D.W., MOHTADI, C., "Properties of Generalized Predictive Control". Automatica, vol. 25, nº 6, pp 859-875, 1989.

[CLARKE 91]

CLARKE, D.W. & R. SCATTOLINI, "Constrained Receding-horizon Predictive Control", Proceedings IEE-D. Vol. 138, nº 4, July 1991.

[COELHO 93]

COELHO A.A.R., AMARAL W.C., "Multivariable Generalized Predictive Controller: Analysis, Tuning and Application". vol. 3, pp. 331-334, 12th IFAC World Congress, Sydney, Australia, 1993.

[COSTA OLIVEIRA 92]

COSTA OLIVEIRA G.H., AMARAL W.C., GIMENO LATRE L., "O Controlador Preditivo Generalizado (GPC) com Ajuste do Polinômio Observador". 9^o Congresso Brasileiro de Automática, pp. 431-436, Vitória, ES, 1992.

[CUTLER 80]

CUTLER, C.R. & RAMAKER, B.L., "Dynamic Matrix Control- A Computer Control Algorithm". JACC, San Francisco, 1980.

[DEMIRCIOGLU 91]

DEMIRCIOGLU, H. & P.J. GAWTHROP, Continuous-time Generalized Predictive Control (CGPC). Automatica. Vol. 27, nº 1, pp 55-74, 1991.

[DESOER 75]

DESOER, C.A. & VIDYASAGAR, M., "Feedback Systems: Input-output Properties". Academic Press, New York, 1975.

[DION 91]

DION, S.M. & DUGARD, L. & FRANCO, A. & NGUYEN MINHTRI & REY, D., "Mimo Adaptive Constrained Predictive Control Case Study: An Environmental Test Chamber". Automatica, Vol. 27, nº 4, pp. 611-626, 1991.

[FAVIER 87]

FAVIER, G., "Self-tuning Long-Range Predictive Controllers". IFAC-World Congress, Munich, July 1987.

[FISHER 91]

FISHER, D. GRANT, "Process Control: An Overview and Personal Perspective". The Canadian Journal of Chemical Engineering. Vol. 69, pp. 5-26, Feb. 1991.

[GOODWIN 77]

GOODWIN, G.C. & PAYNE, R.L., Dynamic Systems Identification: Experiment Design and Data Analysis. Academic Press 1977.

[GOODWIN 84]

GOODWIN, G.C. & SIN, K.S., "Adaptative Filtering Prediction and Control". Prentice-Hall, 1984.

[HEMERLY 89]

HEMERLY, E.M. & DAVIS, M.H.A., "Strong Consistency of the PLS Criterion for Order Determination of Autoregressive Processes". The annals of Statistics, vol. 17, nº 2, pp. 941-946, 1989.

[ISERMANN 74]

ISERMANN, R. & BAUR, U. & BAMBERGER, W. & KNEPPO, P. & SIEBERT, H., Comparison of Six On-Line Identification and Parameter Estimation Methods. Automatica, vol. 10, nº 1, pp. 81-103, 1974.

[ISERMANN 93]

HECKER O., KNAPP T., ISERMANN R., "Robust Adaptive Control of a Time Varying Process Using Parallel Recursive Estimators", 12th IFAC World Congress, vol. 3, pp. 185-188, Sydney, Australia, 1993.

[LJUNG 83]

LJUNG, L. & SODERSTRONS, T., "Theory and Practice of Recursive Identification". The MIT Press 1983.

[KAMMER 92]

KAMMER L.C., "Desenvolvimento de um Ambiente de Simulação para Análise de Desempenho de Controladores Adaptativos". Dissertação de mestrado, Curso de Pós-graduação em Engenharia Elétrica, UFSC, Dezembro 1992.

[MEDEIROS 90]

MEDEIROS, A. A. D., "Controle adaptativo com identificação estrutural". Dissertação de Mestrado, Divisão de Pós - graduação do Instituto Tecnológico da Aeronáutica, 1990

[MENEZES 94]

MENEZES M., PAGANO D., BOLZAN A., "Adaptive GPC Control for Chemical Processes: Automatic Tuning and Implementation". IFAC Symposium ADCHEM' 94 - , Kyoto, Japan May 1994, (Submitted).

[McINTOSH 91]

McINTOSH & ANDREW, R. & SIRISH, L. SHAH & FISHER, D. GRANT, Analysis and Tuning of Adaptive Generalized Predictive Control. The Canadian Journal of Chemical Engineering. Vol. 69, pp 97-110, Feb. 1991.

[NARENDRA 89]

NARENDRA K., ANNASWAMY A., "Stable Adaptive Systems", Prentice-Hall International Editions, 1989.

[NIEDZWIECKI 84]

NIEDZWIECKI M., "Self-tuning Minimum Variance Regulators with Adaptive Determination of the Model Order". Technical Report, nº 2, University of Gdansk, 1984.

[NIEDZWIECKI 85]

NIEDZWIECKI M., "Self-tuning Minimum Variance Regulators with Adaptive Determination of the Model Order". Proc. 24th IEEE Conf. on Decision and Control, 1985.

[PETERKA 84]

PETERKA, V., Predictor-Based Self-tuning Control. Automatica 20, pp 39-50, 1984.

[RICHALET 78]

RICHALET, J., RAULT, A., TESTUD, L. & PAPPON, J., Model predictive heuristic control: applications to industrial processes. Automatica, 14, 413-418, 1978.

[RISSANEN 86]

RISSANEN, J., A predictive Least-Square Principle. IMA J. Math Control Inform., pp 211-212, 1986.

[ROBINSON 91]

ROBINSON, B.D. & CLARKE, D.W., Robustness effects of a prefilter in generalized predictive control. Proc. IEE -D, vol. 138, number 1, January 1991.

[SALLÉ 91]

SALLÉ S., "Application des Systemes Experts a la Supervision D'Algorithms en Automatique". These de L'INPG, França, 1991.

[SEBORG 86]

SEBORG, D.E. & EDGAR, T.F. & SHAH, S.L., "Adaptative control strategies for process control". AICHE Journal, vol. 32, nº 6, pp. 881-913., 1986.

[SODERSTROM 78]

SODERSTROM, T. & LJUNGS, L. & GUSTAVSSON, L., "Theoretical Analysis of Recursive Identification Methods". Automatica, vol. 14, nº 3, pp. 231-244, 1978.

[SOUZA 89]

SOUZA JUNIOR & BEZERRA, MAURÍCIO, "Controle Preditivo de Longo Alcance: uma Investigação". Tese de mestrado, COPPE/UFRJ, 1989.

[TUFFS 85]

TUFFS, P.S., "Self-tuning Control: Algorithms and Applications". Report OUEL number 1567/85, University of Oxford, 1985.

[WANG 91]

WANG, H. & JONES, A.H., "Rule based identifier for unknown systems". IEE Proceedings-D, vol. 138, pp. 500-506, Sep. 1991.

[WELLSTEAD 79]

WELLSTEAD, P.E. & PRAGER, D. & ZANKER, P., "Pole assignment Self-tuning Regulator". Proc. IEE-D, vol. 126, pp. 781-787, 1979.