

高级过程控制

顾钟文 孙优贤 等编著
王 慧 戴连奎

顾钟文 主 编

浙江大学出版社

73

5

高级过程控制

顾钟文 孙优贤 等编著
王 慧 戴连奎

顾钟文 主编

浙江大学出版社

内 容 简 介

本书介绍了几种经实际使用证明对具有时变、非线性特性或结构复杂难以精确建模的工业对象有良好控制性能的高级控制策略的基本原理和工业应用实例。其中不少内容是作者及同事们多年研究成果的结晶。

本书是工业自动化及相关专业领域工程技术人员继续工程教育系列教材之一,也可作高等学校有关专业高年级大学生和研究生的教科书。

高级过程控制

顾钟文 孙优贤 等 编著
王 慧 戴连奎

顾钟文 主编
责任编辑 洪保平

* * *

浙江大学出版社出版
浙江大学工控所电脑排版
德清第二印刷厂印刷
浙江省新华书店发行

* * *

787×1092 16开 10.5印张 26.8千字
1995年11月第1版 1995年11月第1次印刷
印数 0001—1560

ISBN 7-308-01343-X/TP·111 定价: 11.00元

出版说明

生产过程的大型化、复杂化和连续化,要求生产控制自动化。为此,国内外已广泛应用具有十分方便和友好人机界面的集散型计算机及其它自动化装置,对生产过程进行监督、控制和管理,从而改变了人在生产中的地位;同时运用现代控制理论、系统工程和计算机科学中的最新成果及它们的有机结合,研究、开发与设计先进的工业控制策略与系统,并应用于生产控制,从而提高企业的经济效益。

为了适应国内外自动化发展的形势及贯彻国家经委、国家科委和中国科协经教[1987]676号文关于《企业科技人员继续教育暂行规定》的通知精神,中国石化总公司从1988年起连续四年委托浙江大学举办“化工自动化及仪表”专业工程师进修班。浙江大学工业控制研究所着眼于提高企业科技人员的知识深度、拓宽知识面、增强技术改造、技术攻关的创造能力,结合多年的教学和科学研究实践经验,为进修班设置了“线性系统理论”、“工业过程模型化”、“工业过程计算机仿真”、“最优化与最优控制”、“集散型计算机控制系统”和“高级过程控制”等课程,并编写了相应的教材。

考虑到模型化、计算机和控制学科已遍及众多部门和领域,贯穿其中的思想和方法已用于经济与社会现象的研究,这些领域的科技人员亦有继续教育的愿望,为此,现在特将这套教材整理出版。这套教材既反映了这些学科的基本理论,又反映浙江大学工业控制研究所近几年工业过程控制研究实践的成果。希望这套教材既能为工业自动化以及相关领域的科学工作者和工程技术人员提供一套较为系统的继续教育教材,也能为在校大学生和研究生提供有价值的参考书。

组编和出版这套教材是一次尝试。我们热忱欢迎选用和阅读这套教材的同志提出批评、建议。

浙江大学工业自动化国家工程研究中心
中国石油化工总公司人事部
1995年6月

前 言

在过程控制领域,通常把单变量的PID控制称为简单控制,而把串级、均匀、比例、前馈、超驰、解耦控制等称作复杂控制,这些控制方法在工业生产过程的自动控制中发挥了重要的作用,特别是简单控制已成为工业生产过程控制不可缺少的组成部分。但是,随着工业生产过程大型化、复杂化程度的提高,对生产的安全、平稳、优质、高效等方面提出了更高的要求,以至上述控制方法已不能满足具有复杂结构和实际存在不确定性与非线性特性的工业对象的控制要求,于是人们在科学实践中提出了许多解决这类复杂过程控制的方法。本书作为工业自动化专业技术人员继续工程教育的教材,仅介绍几种经作者及同事们科研实践证明并发展了的在复杂过程控制中行之有效的控制方法,如自适应控制、预测控制、鲁棒控制、容错控制、模糊控制、专家系统与人工神经网络控制等,并把它们称为高级过程控制。

为了便于读者阅读,本书把各种控制方法独立成章,自成体系,对有关基础知识也分别作了介绍。本书在写法上注意深入浅出,讲清基本原理,在此基础上,各种方法都给出了工业应用实例,以引导读者的实际应用。

本书共有七章,第一、二章由顾钟文编著,第三、四章由孙优贤、冯旭编著,第五章由王慧、李平编著,第六、七章由戴连奎编著。

本书由林庆女士、邓赤女士、何燕女士等精心打字,傅烈勇博士、赵豫红硕士为本书的出版做了大量工作,在此作者向她(他)们表示衷心的感谢!

由于作者水平有限,缺点和不足之处在所难免,恳请读者批评指正。

作者于浙江大学

1995年6月

目 录

第一章 自适应控制

§ 1.1 引言	1
§ 1.2 具有被控过程数学模型在线辨识的自适应控制系统	2
1.2.1 参数估计的最小二乘法	2
1.2.2 最小方差控制	8
1.2.3 自校正调节器	10
1.2.4 极点配置自校正调节器	18
§ 1.3 模型参考自适应控制系统	19
1.3.1 局部参数最优化的设计方法	20
1.3.2 基于李雅普诺夫稳定理论的设计方法	21
参考文献	24

第二章 预测控制

§ 2.1 引言	26
§ 2.2 预测控制算法的方法机理	27
§ 2.3 典型的预测控制算法	28
2.3.1 动态矩阵控制	28
2.3.2 模型算法控制	30
§ 2.4 预测控制的发展及其推广	34
2.4.1 与自校正原理相结合的预测控制算法	34
2.4.2 非线性系统的预测控制	37
§ 2.5 预测控制的特点及其工业应用	40
2.5.1 预测控制的特点	40
2.5.2 预测控制的工业应用	41
参考文献	48

第三章 鲁棒控制

§ 3.1 绪言	50
§ 3.2 不确定系统的描述与鲁棒性分析	51
§ 3.3 鲁棒控制器设计的参数空间法	54
3.3.1 从 Λ 空间到 P 空间投影	55
3.3.2 从 P 空间到 K 空间投影	56
§ 3.4 鲁棒线性二次型最优控制	59
§ 3.5 鲁棒调节器设计方法	62
§ 3.6 纸机鲁棒控制设计	63

参考文献	74
第四章 容错控制	
§ 4.1 绪论	75
§ 4.2 故障的分类	77
§ 4.3 完整性控制器的综合	78
§ 4.4 分散可靠控制	83
4.4.1 引言	83
4.4.2 分散积分可控制性的定义	84
4.4.3 分散积分可控性的必要条件	85
§ 4.5 故障检测、分离与补偿	88
参考文献	89
第五章 模糊逻辑控制	
§ 5.1 模糊集理论的基本知识	91
5.1.1 普通集合及其运算	91
5.1.2 模糊集及其运算	94
5.1.3 模糊集的隶属函数	96
5.1.4 模糊关系	97
§ 5.2 模糊逻辑控制及其应用	99
5.2.1 引言	99
5.2.2 模糊逻辑控制器 FLC 的基本工作原理	100
5.2.3 经典 FLC 设计方法	101
5.2.4 FLC 的工业应用及设计举例	105
5.2.5 自适应(自组织)FLC	111
§ 5.3 模糊系统模型与辨识	115
5.3.1 模糊模型概述	115
5.3.2 模糊模型辨识	116
参考文献	119
第六章 专家系统	
§ 6.1 概述	121
6.1.1 专家系统的概念	121
6.1.2 专家系统的基本结构	122
6.1.3 实用专家系统的类型与特点	122
§ 6.2 知识表达	125
6.2.1 产生式系统	125
6.2.2 框架结构	128
§ 6.3 问题求解	130
6.3.1 不确定性推理	131

6.3.2 控制策略	133
§ 6.4 应用举例	136
6.4.1 知识获取子系统	136
6.4.2 数据采集子系统	137
6.4.3 故障诊断子系统	137
6.4.4 运行举例	139
参考文献	141

第七章 人工神经网络

§ 7.1 概述	142
7.1.1 生物神经网络结构和基本特性	142
7.1.2 人工神经网络的模型和功能	143
7.1.3 神经网络在过程建模和控制中的应用	145
§ 7.2 常用的神经网络模型	146
7.2.1 Hopfield 网络	146
7.2.2 多层感知机和反向传播算法	147
7.2.3 概率神经网络模型	150
§ 7.3 应用举例——催化裂化过程粗汽油干点的实时估计	151
7.3.1 问题的提出	153
7.3.2 基于神经网络的粗汽油干点质量估计模型	153
7.3.3 粗汽油干点的闭环预测控制系统	155
参考文献	156

第一章 自适应控制

§ 1.1 引言

大家熟知,最优控制所研究的对象和环境是确定性的,解决问题的方法是将被控过程的运动规律定量化为一个数学模型,并将控制的要求用一个性能指标来描述,然后用适当的最优化方法求出使性能指标取极值的控制律(控制作用)。这就是说,最优控制只有在确知过程模型的情况下,才有可能综合出最优控制律。

但是实际过程往往存在不同程度的不确定性,这种不确定性可能表现为过程模型结构和参数的未知与时变,也可能表现为干扰的随机性与突发性,且它们的统计特性又往往未知。对具有这些不确定性的过程,就无法用最优控制理论综合出最优的控制律,而只能是根据过程和环境的变化情况,不断修正控制律,以适应过程和环境的变化,也就是要设计一种在一定范围内能“适应”过程和环境条件变化的控制系统。自适应控制系统是能满足这一要求的自动控制系统。

所以,自适应控制的研究对象是具有不确定性的系统。面对这些不确定性,如何综合适当的控制作用,使得某一性能指标达到并保持最优或近似最优就是自适应控制所要解决的问题。

从这里我们初步看到最优控制问题与自适应控制问题在提法上的一些差别,前者是在过程模型已知及干扰统计特性已知的情况下设计最优控制律,而后者则是在过程和环境的数学模型不完全确定的条件下设计最优控制律。但我们同时也看到,自适应控制律的设计和最优控制律的设计一样,也是基于过程的数学模型和某一性能指标综合出来的,不过由于自适应控制依据的数学模型先验知识较少,需要在系统的运行过程中去提取有关模型的信息(通常采用的手段是通过在线辨识),使模型逐步完善。这样,基于这种模型综合出来的控制作用也将随之不断改进,在这个意义下,控制系统具有一定的适应能力。所以可以说,通过在线辨识而获得自适应能力是自适应控制系统的主要特点。

因此,对于那些对象特性或扰动特性变化较大,同时又要求经常保持高性能指标的一类控制系统采用自适应控制方法是很有效的。

应当指出的是:因自适应控制系统比常规反馈控制系统复杂得多,所以只有在常规反馈控制达不到期望的性能指标时才考虑采用。

自从 50 年代末期美国麻省理工学院提出第一个自适应控制系统以来,先后出现过许多形式完全不同的自适应控制系统,但是发展到现阶段,无论从理论研究和实际应用的角度,比较成熟的自适应控制系统有以下两大类:一类是具有被控对象数学模型在线辨识的自适应控制系统,另一类是模型参考自适应控制系统。

§ 1.2 具有被控过程数学模型在线辨识的自适应控制系统

这类自适应控制系统由被控过程、辨识器和控制器等组成,如图 1.2-1 所示。其中辨识器根据一定的估计算法,在线计算被控过程未知参数 θ 的估计值 $\hat{\theta}(k)$, 控制器利用估计值 $\hat{\theta}(k)$ 及事先指定的性能指标综合出相应的控制作用 $u(k)$, 对过程实施控制。这样, 尽管过程和环境特性在不断地变化, 由于控制作用是根据这些变化着的环境及过程的特性数据不断辨识, 不断综合出来的, 因而系统具有一定的适应能力, 系统的动态指标将逐渐趋向最优。

通常这类系统在设计辨识算法和控制算法时, 考虑了随机扰动和量测噪声的影响, 所以属于随机自适应控制系统这一类, 设计这类自适应控制系统的理论基础是估计理论和随机最优控制理论。因而随机自适应控制与随机控制关系就十分密切。如果对象和环境的模型已知时, 系统的控制问题属于随机控制问题; 而当模型参数未知时的控制问题, 就转化为随机自适应控制问题了。

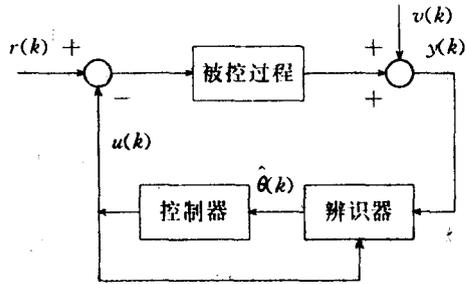


图 1.2-1 具有在线辨识的自适应控制系统

目前, 参数估计方法很多, 如递推最小二乘法 (RLS)、递推广义最小二乘法 (RGLS)、递推增广最小二乘法 (RELS)、递推辅助变量法 (RIV)、递推极大似然法 (RML) 等。最优控制的算法也很多, 如最小方差和广义最小方差控制算法、最小时间 (最小拍) 控制算法、极点配置控制算法、PID 控制算法等。从原则上讲, 采用不同的参数估计方法和不同的性能指标 (控制算法), 可以构成不同形式的带辨识器的自适应控制系统, 但目前真正获得实际应用的仍是递推最小二乘估计方法和最小方差性能指标相结合的最小方差自校正调节器。

当被控过程的结构和参数已知, 且系统经常处于随机扰动作用之下, 如何设计一个控制器使随机干扰对系统输出的影响减小到最小限度的控制问题, 称为最小方差控制问题。如果在设计最小方差控制器时, 过程模型的参数未知, 或者参数随环境和工作条件变化, 这时如何设计一个能自动整定自身参数的调节器, 以适应环境和过程参数的变化, 这类调节器称为最小方差自校正调节器。

下面将主要介绍最小方差自校正调节器的设计。但由于它与最小方差控制有密切的关系, 所以将首先介绍最小方差控制。同时由于这类调节器的自校正作用是基于在线辨识, 所以也对最小二乘参数估计方法作简单的介绍。

1.2.1 参数估计的最小二乘法

参数估计问题是随机自适应控制中的一个重要问题, 现有的参数估计方法很多, 限于篇幅, 本书不可能对各种方法一一介绍, 下面仅从应用的角度介绍随机自适应控制中常用的最小二乘参数估计方法。

1. 系统描述

表征过程动态特性的数学模型有多种形式,由于在线辨识往往是直接得到输入输出模型,而且工业过程控制领域行之有效的自校正控制等控制方法都采用输入输出模型,并且这些控制策略是通过数字计算机来实现的,所以下面只介绍过程离散时间输入输出的描述方法——差分方程描述。

对于单输入单输出(SISO)线性时不变过程,可用以下差分方程描述

$$\begin{aligned} y(k) + a_1 y(k-1) + \cdots + a_n y(k-n) \\ = b_0 u(k) + b_1 u(k-1) + \cdots + b_n u(k-n) \end{aligned} \quad (1.2-1)$$

其中, k 为离散时间,取整数; $u(k)$, $y(k)$ 为过程某时刻的输入、输出变量; n 为模型的阶; a_j , b_j ($j=1, \dots, n, j=0, \dots, n$) 为模型参数。

引进时间移位算子 z , 定义 $z^{-1}y(k) = y(k-1)$, 则式(1.2-1)可表示成算子形式

$$A(z^{-1})y(k) = B(z^{-1})u(k) \quad (1.2-2)$$

式中 $A(z^{-1}) = 1 + a_1 z^{-1} + \cdots + a_n z^{-n}$

$$B(z^{-1}) = b_0 + b_1 z^{-1} + \cdots + b_n z^{-n}$$

由于大多数化工过程,往往具有纯滞后和容量滞后,而且往往受到随机干扰和量测噪声的影响,因而对应的差分方程模型为

$$\begin{aligned} y(k) + a_1 y(k-1) + \cdots + a_n y(k-n) \\ = b_1 u(k-1-d) + \cdots + b_n u(k-n-d) + v(k) \end{aligned} \quad (1.2-3)$$

或 $y(k+n+d) = -a_1 y(k+n+d-1) - \cdots - a_n y(k+d)$

$$+ b_1 u(k+n-1) + \cdots + b_n u(k) + v(k+n+d) \quad (1.2-4)$$

其中, $v(k)$ 为零均值、方差为 σ^2 的正态白噪声; d 为纯滞后。

若定义 $\varphi^T = [-y(k+n+d-1) \quad \cdots \quad -y(k+d) \quad u(k+n-1) \quad \cdots \quad u(k)]$

$$\theta^T = [a_1 \quad \cdots \quad a_n \quad b_1 \quad \cdots \quad b_n]$$

则式(1.2-4)可表示为

$$y(k+n+d) = \varphi^T \theta + v(k+n+d) \quad (1.2-5)$$

对于具有 r 个输入、 m 个输出的多变量过程,其动态特性可用向量差分方程描述

$$y(k) + \sum_{j=1}^n A_j y(k-j) = \sum_{j=1}^n B_j u(k-j) + v(k) \quad (1.2-6)$$

其中 $y^T(k) = [y_1(k) \quad \cdots \quad y_m(k)]$ 是 m 维输出向量,

$u^T(k) = [u_1(k) \quad \cdots \quad u_r(k)]$ 是 r 维输入向量,

A_j, B_j 分别是 $m \times m$ 维和 $m \times r$ 维参数矩阵,

$v(k)$ 为零均值、独立、同分布随机噪声向量。

如果以算子形式表示,则为

$$A(z^{-1})y(k) = B(z^{-1})u(k) \quad (1.2-7)$$

其中 $A(z^{-1}) = I + A_1 z^{-1} + \cdots + A_n z^{-n}$

$$B(z^{-1}) = B_1 z^{-1} + \cdots + B_n z^{-n}$$

$$A_i = \begin{bmatrix} a_{i11} & a_{i12} & \cdots & a_{i1m} \\ a_{i21} & & & \vdots \\ \vdots & & & \vdots \\ a_{im1} & \cdots & \cdots & a_{imn} \end{bmatrix}_{m \times m}$$

$$B_i = \begin{bmatrix} b_{i11} & b_{i12} & \cdots & b_{i1r} \\ b_{i21} & & & \vdots \\ \vdots & & & \vdots \\ b_{im1} & \cdots & \cdots & b_{imr} \end{bmatrix}_{m \times r}$$

2. 模型参数的最小二乘估计方法

对于式(1.2-4)或式(1.2-5)的系统,参数估计问题的提法是:已知模型阶 n 及纯滞后 d , 利用输入、输出数据估计未知参数 $a_1, \dots, a_n, b_1, \dots, b_n$ 。

参数最小二乘估计的基本思想是选择 $\hat{a}_i, \hat{b}_i (i=1, \dots, n)$ 使得系统模型对输入输出数据拟合的误差平方和为最小。即若以下列模型进行拟合

$$y(k+n+d) = -\hat{a}_1 y(k+n+d-1) - \cdots - \hat{a}_n y(k+d) + \hat{b}_1 u(k+n-1) + \cdots + \hat{b}_n u(k) + e(k+n+d) \quad (1.2-8)$$

$$\text{或} \quad y(k+n+d) = \phi^T \theta + e(k+n+d) \quad (1.2-9)$$

其中, $e(k+n+d)$ 为模型残差, 是零均值、方差为 σ^2 的白噪声。

参数最小二乘估计, 即是基于数据 $\{y(k)\}, \{u(k)\} (k=1, \dots, N+n+d, N \geq 2n)$ 寻求使损失函数

$$J = \sum_{k=1}^N e^2(k+n+d) = \sum_{k=1}^N [y(k+n+d) - \phi^T \theta]^2 \quad (1.2-10)$$

为最小的 $\hat{\theta}$ 。因而参数 θ 的最小二乘估计量 $\hat{\theta}$ 可通过极小化 J , 即由

$$\left. \frac{\partial J}{\partial \theta} \right|_{\hat{\theta}} = 0 \quad (1.2-11)$$

求得。

下面介绍几种算法。

(1) 最小二乘估计的一次完成算法

经试验采集到 $N+n+d$ 组输入输出数据 $\{u(k)\}, \{y(k)\} (k=1, \dots, N+n+d)$, 可构成如下矩阵方程

$$y = \Phi \theta + e \quad (1.2-12)$$

$$\text{其中} \quad y^T = [y(n+d+1) \quad y(n+d+2) \quad \cdots \quad y(n+d+N)] \triangleq y_N^T \quad (1.2-13)$$

$$\Phi = \begin{bmatrix} -y(n+d) & \cdots & -y(d+1) & u(n) & \cdots & u(1) \\ -y(n+d+1) & \cdots & -y(d+2) & u(n+1) & \cdots & u(2) \\ \vdots & & \vdots & \vdots & & \vdots \\ -y(n+d+N-1) & \cdots & -y(d+N) & u(n+N-1) & \cdots & u(N) \end{bmatrix}$$

$$= [\phi_1^T \quad \phi_2^T \quad \cdots \quad \phi_N^T] \triangleq \Phi_N \quad (1.2-14)$$

$$e^T = [e(n+d+1) \quad \cdots \quad e(n+d+N)] \quad (1.2-15)$$

则损失函数

$$J = (y - \Phi \theta)^T (y - \Phi \theta) \quad (1.2-16)$$

于是有 $\frac{\partial J}{\partial \theta} \Big|_{\hat{\theta}} = -2\Phi^T y + 2\Phi^T \Phi \hat{\theta} = 0$

得正规方程组

$$\Phi^T \Phi \hat{\theta} = \Phi^T y \quad (1.2-17)$$

当 $\Phi^T \Phi$ 为非奇异矩阵,由式(1.2-17)可得参数 θ 的最小二乘估计为

$$\hat{\theta} = (\Phi^T \Phi)^{-1} \Phi^T y \quad (1.2-18)$$

按式(1.2-17)或式(1.2-18)求 $\hat{\theta}$,是在取得足够数据后,一次计算出来的,所以该方法只能用于离线计算。但自适应控制系统的参数估计要求在线进行,即不断采集新数据,希望利用这些新的观测信息不断改进参数估计量(即不断修正模型),这种要求必须用递推算法才能实现。

(2) 最小二乘估计的递推算法

当用 $N+n+d$ 组数据求得 $\hat{\theta}_N$ 后,又采到一组新数据 $y(N+n+d+1)$ 、 $u(N+n+d+1)$,则对应于式(1.2-13)、(1.2-14)有

$$y_{N+1} = \begin{bmatrix} y_N \\ y(N+n+d+1) \end{bmatrix} \quad (1.2-19)$$

$$\Phi_{N+1} = \begin{bmatrix} \Phi_N \\ \varphi_{N+1}^T \end{bmatrix} \quad (1.2-20)$$

其中 $\varphi_{N+1}^T = [-y(N+n+d) \quad \cdots \quad -y(N+d+1) \quad u(N+n) \quad \cdots \quad u(N+1)]$

于是新的估计量为

$$\hat{\theta}_{N+1} = (\Phi_{N+1}^T \Phi_{N+1})^{-1} \Phi_{N+1}^T y_{N+1} \quad (1.2-21)$$

令 $P_k \triangleq (\Phi_k^T \Phi_k)^{-1}$

$$\begin{aligned} \text{则 } P_{N+1} &= (\Phi_{N+1}^T \Phi_{N+1})^{-1} = \left\{ \begin{bmatrix} \Phi_N^T \\ \varphi_{N+1}^T \end{bmatrix} \begin{bmatrix} \Phi_N \\ \varphi_{N+1} \end{bmatrix} \right\}^{-1} \\ &= \{ \Phi_N^T \Phi_N + \varphi_{N+1}^T \varphi_{N+1} \}^{-1} = \{ P_N^{-1} + \varphi_{N+1}^T \varphi_{N+1} \}^{-1} \end{aligned}$$

应用矩阵求逆公式,得

$$P_{N+1} = P_N - P_N \varphi_{N+1} (1 + \varphi_{N+1}^T P_N \varphi_{N+1})^{-1} \varphi_{N+1}^T P_N \quad (1.2-22)$$

将式(1.2-22)、(1.2-19)、(1.2-20)代入式(1.2-21),经展开、整理,得

$$\hat{\theta}_{N+1} = \hat{\theta}_N + K_{N+1} [y(N+n+d+1) - \varphi_{N+1}^T \hat{\theta}_N] \quad (1.2-23)$$

其中 $K_{N+1} = P_N \varphi_{N+1} (1 + \varphi_{N+1}^T P_N \varphi_{N+1})^{-1}$ (1.2-24)

于是,式(1.2-22)又可写成

$$P_{N+1} = P_N - K_{N+1} \varphi_{N+1}^T P_N \quad (1.2-25)$$

式(1.2-23)、(1.2-24)、(1.2-25)就是一组参数最小二乘估计的递推算式。这就是说, $\hat{\theta}$ 、 P 及 K 在每个采样时刻的值,可以利用式(1.2-23)、(1.2-24)、(1.2-25)递推计算,但 $\hat{\theta}$ 、 P 的初值需事先设定。

通常 $\hat{\theta}$ 及 P 的初值作如下设定:

$$P(0) = \alpha^2 I, I \text{ 为单位阵, } \alpha^2 \text{ 为足够大的标量,例如 } \alpha^2 = 10^5 \sim 10^{10}.$$

$$\hat{\theta}(0) = 0 \text{ 或任意值.}$$

值得指出的是,由于式(1.2-24)中的因子 $(1 + \varphi_{N+1}^T P_N \varphi_{N+1})^{-1}$ 是标量,因此该递推算法没有矩阵求逆的运算,计算效率大大提高。

以上递推算法适用于线性定常(时不变)系统模型参数的在线估计,对于时变过程(实际过程往往具有一定的时变性和非线性)的参数估计,需要采用一种能适应参数变化的实时估计算法。

(3) 时变参数的实时估计算法

上述递推估计算法的特点是:每个新、老数据在计算中所处的地位是平等的,这对于线性定常系统的参数估计是合理的。而对于时变过程,当前的新数据必然最能反映过程当前的特性,数据愈老,偏离当前特性的可能性愈大。因而,为了较好地反映时变过程的特性,在进行参数估计时必需重视当前数据,而将历史数据作某种“遗忘”。带遗忘因子的递推最小二乘法能满足这个要求。

带遗忘因子的递推最小二乘法的基本思想是:当采到一组新数据后,用小于1的加权因子 ρ 对历史数据进行“加权”,这就削弱了历史数据在估计计算中的作用。于是有

$$\Phi_{N+1} = \begin{bmatrix} \rho \Phi_N \\ \varphi_{N+1}^T \end{bmatrix} \quad (1.2-26)$$

$$y_{N+1} = \begin{bmatrix} \rho y_N \\ y(N+n+d+1) \end{bmatrix} \quad (1.2-27)$$

$$\begin{aligned} \text{则 } P_{N+1} &= (\Phi_{N+1}^T \Phi_{N+1})^{-1} = (\rho^2 \Phi_N^T \Phi_N + \varphi_{N+1} \varphi_{N+1}^T)^{-1} \\ &= \frac{1}{\lambda} [P_N - P_N \varphi_{N+1} (\lambda + \varphi_{N+1}^T P_N \varphi_{N+1})^{-1} \varphi_{N+1}^T P_N] \end{aligned}$$

$$\text{或 } P_{N+1} = \frac{1}{\lambda} [P_N - K_{N+1} \varphi_{N+1}^T P_N] \quad (1.2-28)$$

$$\text{其中 } K_{N+1} = P_N \varphi_{N+1} (\lambda + \varphi_{N+1}^T P_N \varphi_{N+1})^{-1} \quad (1.2-29)$$

$\lambda = \rho^2$, 称为遗忘因子

$$\begin{aligned} \hat{\theta}_{N+1} &= P_{N+1} [\rho \Phi_N^T \varphi_{N+1}] \begin{bmatrix} \rho y_N \\ y(N+n+d+1) \end{bmatrix} \\ &= P_{N+1} [\rho^2 \Phi_N^T y_N + \varphi_{N+1} y(N+n+d+1)] \\ &= \hat{\theta}_N + K_{N+1} [y(N+n+d+1) - \varphi_{N+1}^T \hat{\theta}] \end{aligned} \quad (1.2-30)$$

式(1.2-28)、(1.2-29)、(1.2-30)是一组带遗忘因子的递推最小二乘算式,其中遗忘因子 λ 取不同的值,就有不同的遗忘效果。 λ 愈小,历史数据的作用削弱得愈厉害,新数据的作用相对愈大,所以对时变参数的跟踪能力愈强。但是 λ 的取值也不能太小,否则计算误差较大,一般 $0.9 < \lambda < 1$ 。

(4) 最小二乘估计方法的缺陷

可以证明,当噪声是零均值的白噪声时,动态模型参数的最小二乘估计量是渐近无偏的估计量,但当噪声是有色噪声时(实际过程中的噪声往往是有色的)最小二乘估计是有偏估计。为了获得参数的无偏估计量,需采用广义最小二乘法、增广最小二乘法、极大似然法等。有关这些方法的介绍,可参阅系统辨识书籍,这里从略。

3. 模型阶的确定

在前面讨论参数估计时,认为SISO模型的阶和纯滞后是已知的,但是实际问题中,模型的阶 n 和纯滞后 d 很少事先知道,它们也要利用输入输出数据来确定。

由于纯滞后的确定可以包括在确定阶的一般程序中,故在这里只笼统提阶的确定。

目前确定阶的方法,基本上是通过统计检验,在众多的检验方法中,最简单实用的方法是损失函数检验法。

考虑 SISO 模型

$$y(k) + a_1 y(k-1) + \dots + a_n y(k-n) = b_1 u(k-1) + \dots + b_n u(k-n) + e(k) \quad (1.2-31)$$

损失函数

$$J(n) = \sum_{k=n+1}^{n+N} e^2(k)$$

其中, $e(k)$ 为模型残差,即模型与数据的拟合误差。

显然 $J(n)$ 依赖于阶 n (也包括纯滞后 d), 因而可依据 $J(n)$ 的数值来确定 n 。

由于我们希望求得的模型是残差相对较小的模型, 因而使损失函数 $J(n)$ 取相对最小值的 n 就是理想的阶。

一般来说, 模型阶增加, 损失函数将随着减小, 阶次愈接近真阶, $J(n)$ 应愈小, 当阶 \hat{n} 等于真阶 n_0 时, $J(\hat{n})$ 应为最小值, 而阶 n 超过真阶后, $J(n)$ 就接近常值 (或略增大)。于是, 就可以得到一个粗略的检验方法:

令 $n=1, 2, \dots$ 逐次计算参数和损失函数 $J(n)$ 的值, 随着 n 的增加, $J(n)$ 逐渐减小, 如果对某一个 \hat{n} , $J(\hat{n}+1)$ 比 $J(\hat{n})$ 没有明显减小, 就可取 \hat{n} 为模型阶的估计值, 如图 1.2-2 所示。

当然, 这样判断是直观的, 但也是粗糙的, 有时不同 n 的 $J(n)$ 是否有明显的差别, 往往不能直观判断, 这时就要用 F 检验法来进行检验。

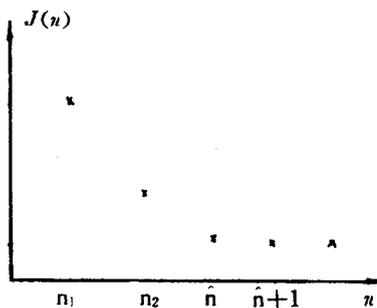


图 1.2-2 损失函数定阶

4. 闭环辨识与闭环可辨识性条件

以上介绍最小二乘参数估计方法时, 都假设系统的噪声与系统的输入信号是不相关的, 这个要求对处于开环状态的系统辨识, 可以满足。然而在自适应控制系统中, 被控对象的参数估计必须在闭环条件下进行, 而在闭环系统中, 由于存在反馈, 则系统输入信号与系统噪声必然相关。这样, 最小二乘等开环辨识方法应用于闭环系统的辨识, 就有可能得不到系统参数唯一的估计值, 即所谓系统不可辨识。这也就是说, 闭环条件下的辨识, 存在“可辨识性”问题。

对于如图 1.2-3 所示的闭环稳定的单输入单输出系统

$$A(z^{-1})y(k) = z^{-d}B(z^{-1})u(k) + C(z^{-1})v(k) \quad (1.2-32)$$

其中 $A(z^{-1}) = 1 + a_1 z^{-1} + \dots + a_n z^{-n}$

$B(z^{-1}) = b_1 z^{-1} + \dots + b_n z^{-n}$

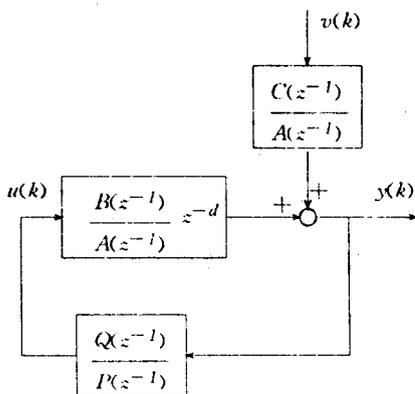


图1.2-3 闭环系统

$$C(z^{-1}) = 1 + c_1 z^{-1} + \dots + c_n z^{-n}$$

$$P(z^{-1}) = 1 + p_1 z^{-1} + \dots + p_r z^{-r}$$

$$Q(z^{-1}) = q_0 + q_1 z^{-1} + \dots + q_q z^{-q}$$

$v(k)$ 是零均值白噪声。

闭环可辨识的充分条件是(证明略)

$$n_r \geq n_b \text{ 或 } n_q \geq n_a - d \quad (1.2-33)$$

也就是说,只有当反馈通道(控制器)模型的阶次不低于前向通道(被控对象)模型的阶次,前向通道模型的参数才是可辨识的(前向通道如存在纯滞后,可辨识条件更易满足)。

因而,在设计自适应控制器时,必需使系统满足闭环可辨识性条件。

1.2.2 最小方差控制

最小方差控制问题,就是要根据被控过程的数学模型综合一个线性控制律,使过程输出的稳态方差为最小。

考虑具有纯滞后 d 的单输入单输出(SISO)过程,其差分方程为

$$\begin{aligned} y(k) + a_1 y(k-1) + \dots + a_n y(k-n) \\ = b_0 u(k-d) + b_1 u(k-d-1) + \dots + b_n u(k-d-n) + v(k) \end{aligned} \quad (1.2-34)$$

$$v(k) = \varepsilon(k) + c_1 \varepsilon(k-1) + \dots + c_n \varepsilon(k-n) \quad (1.2-35)$$

其中, $u(k)$, $y(k)$ 分别是过程的输入、输出变量; $\varepsilon(k)$ 是零均值、方差为 σ^2 、与 $u(k)$ 不相关的正态白噪声; n 是过程的阶。

合并式(1.2-34)、(1.2-35),过程模型又可表示为

$$y(k) = \frac{B(z^{-1})}{A(z^{-1})} u(k-d) + \frac{C(z^{-1})}{A(z^{-1})} \varepsilon(k) \quad (1.2-36)$$

其中 $A(z^{-1}) = 1 + a_1 z^{-1} + \dots + a_n z^{-n}$

$$B(z^{-1}) = b_0 + b_1 z^{-1} + \dots + b_n z^{-n}$$

$$C(z^{-1}) = 1 + c_1 z^{-1} + \dots + c_n z^{-n}$$

鉴于过程有纯滞后 d ,使得控制作用要在 d 个采样周期后才能对输出产生影响,因此,为补偿 k 时的扰动对输出 $y(k)$ 的影响,必须提前 d 步发出控制作用 $u(k-d)$;或者提前 d 步对输出进行预测,基于这个预测输出 $\hat{y}(k+d/k)$ 计算适当的控制作用 $u(k)$,以补偿随机扰动在 $k+d$ 时刻对输出的影响,并使输出的稳态方差最小。

由此可见,要实现最小方差控制,关键在于预测。所以,下面首先讨论最优预测问题。

1. 输出的 d 步最小方差预测

所谓输出的 d 步预测,就是基于在 k 时刻已取得的输入、输出量测 $u(0), \dots, u(k), y(0), \dots, y(k)$ 来预测 $k+d$ 时刻的输出,记为 $\hat{y}(k+d/k)$,若最优性能指标取预测误差的方差为最小,则该最优预测称为最小方差预测。

所以,现在要解决的问题是如何找到一个最优预测 $\hat{y}^*(k+d/k)$ 满足下式

$$E[y(k+d) - \hat{y}^*(k+d/k)]^2 \leq E[y(k+d) - \hat{y}(k+d/k)]^2 \quad (1.2-37)$$

其中, $y(k+d)$ 是 $k+d$ 时刻过程的实际输出; $\hat{y}(k+d/k)$ 是基于 $y(0), \dots, y(k)$ 及 $u(0), \dots, u(k)$ 对 $k+d$ 时刻过程输出的任一 d 步预测。

将式(1.2-36)中的 $\frac{C(z^{-1})}{A(z^{-1})}$ 进行分解,得

$$\frac{C(z^{-1})}{A(z^{-1})} = F(z^{-1}) + z^{-d} \frac{G(z^{-1})}{A(z^{-1})} \quad (1.2-38)$$

其中 $F(z^{-1})$ 是 $\frac{C(z^{-1})}{A(z^{-1})}$ 的商式, $z^{-d} \frac{G(z^{-1})}{A(z^{-1})}$ 是余式;

$F(z^{-1}) = 1 + f_1 z^{-1} + \dots + f_{d-1} z^{-d+1}$ 是 $d-1$ 阶多项式;

$G(z^{-1}) = g_0 + g_1 z^{-1} + \dots + g_{n-1} z^{-n+1}$ 是 $n-1$ 阶多项式。

将式(1.2-38)代入式(1.2-36),有

$$y(k) = \frac{B(z^{-1})}{A(z^{-1})} u(k-d) + F(z^{-1}) \epsilon(k) + z^{-d} \frac{G(z^{-1})}{A(z^{-1})} \epsilon(k) \quad (1.2-39)$$

$$\text{或 } y(k+d) = \frac{B(z^{-1})}{A(z^{-1})} u(k) + F(z^{-1}) \epsilon(k+d) + \frac{G(z^{-1})}{A(z^{-1})} \epsilon(k) \quad (1.2-40)$$

式(1.2-40)右边第二项是 $\epsilon(k+1), \dots, \epsilon(k+d)$ 的线性组合,它们与 k 时刻以前的输出 $y(0), \dots, y(k)$ 无关;第三项是 $\epsilon(k), \epsilon(k-1), \dots$ 的线性组合,它们与 $y(0), \dots, y(k)$ 相关。就是说,经式(1.2-38)的分解,将式(1.2-36)右边分解为与 $y(0), \dots, y(k)$ 相关和不相关的两部分。

若多项式 $C(z^{-1})$ 的所有零点都在单位圆内或单位圆上,则由式(1.2-36)有

$$\epsilon(k) = \frac{A(z^{-1})}{C(z^{-1})} y(k) - z^{-d} \frac{B(z^{-1})}{C(z^{-1})} u(k) \quad (1.2-41)$$

将式(1.2-41)代入式(1.2-40),得

$$y(k+d) = F(z^{-1}) \epsilon(k+d) + \frac{G(z^{-1})}{C(z^{-1})} y(k) + \left[\frac{B(z^{-1})}{A(z^{-1})} - z^{-d} \frac{G(z^{-1})B(z^{-1})}{A(z^{-1})C(z^{-1})} \right] u(k) \quad (1.2-42)$$

又由式(1.2-38)有

$$G(z^{-1}) = [C(z^{-1}) - A(z^{-1})F(z^{-1})] z^d \quad (1.2-43)$$

再将式(1.2-43)代入式(1.2-42),则式(1.2-42)可简化为

$$y(k+d) = F(z^{-1}) \epsilon(k+d) + \frac{G(z^{-1})}{C(z^{-1})} y(k) + \frac{B(z^{-1})F(z^{-1})}{C(z^{-1})} u(k) \quad (1.2-44)$$

式(1.2-44)右边第一项是 $\epsilon(k+1), \dots, \epsilon(k+d)$ 的线性组合,与该式右边第二、第三项是线性独立的。则输出预测误差的方差可表示为

$$\begin{aligned} E[y(k+d) - \hat{y}(k+d/k)]^2 &= E \left[F(z^{-1}) \epsilon(k+d) + \frac{G(z^{-1})}{C(z^{-1})} y(k) + \frac{B(z^{-1})F(z^{-1})}{C(z^{-1})} u(k) - \hat{y}(k+d/k) \right]^2 \\ &= E[F(z^{-1}) \epsilon(k+d)]^2 + E \left[\frac{G(z^{-1})}{C(z^{-1})} y(k) + \frac{B(z^{-1})F(z^{-1})}{C(z^{-1})} u(k) - \hat{y}(k+d/k) \right]^2 \end{aligned} \quad (1.2-45)$$

式(1.2-45)右边第一项是不可控的,要使预测误差方差最小,只有使该式右边第二项为零

$$\frac{G(z^{-1})}{C(z^{-1})} y(k) + \frac{B(z^{-1})F(z^{-1})}{C(z^{-1})} u(k) - \hat{y}(k+d/k) = 0 \quad (1.2-46)$$

因而得 d 步最小方差预测为

$$\hat{y}(k+d/k) = \frac{G(z^{-1})}{C(z^{-1})} y(k) + \frac{B(z^{-1})F(z^{-1})}{C(z^{-1})} u(k) \quad (1.2-47)$$

这样,式(1.2-45)右边第一项

$$E[F(z^{-1}) \epsilon(k+d)]^2 = (1 + f_1^2 + \dots + f_{d-1}^2) \sigma^2 \quad (1.2-48)$$