

专家式控制参数实时自学习 算法 (LARGE)

田 华 蒋慰孙

(华东化工学院自动化研究所, 上海 200237)

摘 要

本文通过更深刻和贴切地模拟专家整定控制参数的启发式过程, 开发了一种高级的专家式控制参数实时自学习算法。首先解决了如何从序贯采集进来的被各种噪声和扰动污染了的控制偏差数据中识别出瞬态过程的模式、抽取其特征的问题, 然后解决了如何将反映了基本反馈控制系统各种特性的瞬态过程特征映射为能进一步改善其性能的控制参数的问题。

关键词: 实时模式识别, 实时产生式系统, 框架表达, 控制器自整定, 叠代学习。

一、引 言

尽管控制参数整定方法很多, 但实时自整定技术迄今主要只有两类, 一类是基于实时辨识被控过程数学模型的解析控制参数实时自整定技术^[1], 另一类是基于实时识别瞬态过程某些特征的启发式控制参数实时自整定技术^[2-4]。后者只需瞬态过程的特征, 控制参数的整定来自这些特征的某种映射。这是一类更有效的控制参数实时自整定技术, 但存在如下缺陷: 1) 没有注意瞬态过程特征获取的举足轻重地位, 或者未能采取有效的识别瞬态过程模式的技术措施; 2) 从瞬态过程特征到控制参数整定的映射是由源自经验、直觉、仿真等一组产生式规则(或其变形)来完成的, 这种映射的完备性和最优性等不能保证, 而且是针对具体的控制器和特性较规范的被控过程总结出来的, 适用范围狭窄。一旦控制器或(和)被控过程特性变离原来情形后, 这些控制参数整定规则都不能自动修正自身去适应上述变化。

本文通过更深刻和贴切地模仿专家整定控制参数的启发式过程, 开发了一种高级的专家式控制参数实时自学习算法, 命名为 LARGE (Learning Automatically Regulator Gains as an Expert)。该算法的根本即综合利用各种技术(如: 数据处理、特征识别、知识表达、产生式系统、动态优化、系统辨识等)使上述启发式过程完全实时算法化。

二、瞬态过程的实时模式识别

为克服噪声和扰动对模式识别的影响,将被噪声和扰动污染了的从现在开始向后一定长度 L (远小于瞬态过程的演变时间) 内的控制偏差数据拟合成抛物线和折线。这一预处理过程被开发成五种递推形式,其结果是拟合抛物线的系数向量 $\alpha(t) \in R^3$ 和拟合折线的系数向量 $\beta(t), \pi(t) \in R^2$ 。计算瞬态过程的各个孤立变化特征是利用这些拟合系数向量进行的,这样使算法能够透过个别采样数据的不规整波动而看出一小段时期内那组采样数据的群体变化趋势。

现建造如下动态的框架表达瞬态过程的知识:

TRAP(k, t)

STEADY-STATE (k, t):(true 和 false, true)

PEAK-ST(k, t):(实数, 0)

TIMER(k, t):(非负实数, 0)

UPTIME(k, t):(非负实数, 0)

PEAK-ND(k, t):(实数, 0)

PEAK-COVER(k, t):(非负实数, 0)

PEAK-RD(k, t):(实数, 0)

COMPLETENESS(k, t):(true 和 false, false)

其中 TRAP(k, t) (TRANSient Process) 是动态框架名, k 表示瞬态过程出现次数, t 表示采样时刻指数。各槽名后括号中前项表示相应槽的值域,后项表示相应槽的缺省值。各槽被设置的相对位置蕴含了它们在被搜索时的优先顺序。

框架内部的逻辑推理表现在每当向其任何槽赋值时都须遵循必要的赋值规则,下面分述之。

• 槽 STEADY-STATE(k, t) 的赋值规则:

如果拟合成的抛物线 $[1, \tau, \tau^2]\alpha(t), \forall \tau \in [0 \cdot T_s, L \cdot T_s]$ 完全落在预定的小范围 $[-\Delta, +\Delta]$ 上,则将 true 赋给 STEADY-STATE(k, t) 槽;否则将 false 赋给 STEADY-STATE(k, t) 槽。

• 槽 PEAK-ST(k, t) 的赋值规则:

如果 $PEAK-ST(k, t-1) = 0, STEADY-STATE(k, t) = false, (|\beta_1(t)| \geq \varepsilon, |\pi_1(t)| \geq \varepsilon, \beta_1(t) \cdot \pi_1(t) < 0)$ (记为 DIFF(t) = true), $|-\alpha_1(t)/\alpha_2(t)/2 - LT_s/2| \leq 10\% LT_s/2$ (记为 CENTR(t) = true), 则将 $[\alpha_0(t) - \alpha_1^2(t)/\alpha_2(t)/4]$ (记为 EXTREM(t)) 赋给 PEAK-ST(k, t) 槽;否则将 PEAK-ST($k, t-1$) 赋给 PEAK-ST(k, t) 槽。

• 槽 TIMER(k, t) 的赋值规则:

如果 $TIMER(k, t-1) > 0$, 则将 $[TIMER(k, t-1) + T_s]$ 赋给 TIMER(k, t) 槽;如果 $PEAK-ST(k, t) \neq 0$, 则将 $\{LT_s - [-\alpha_1(t)/\alpha_2(t)/2]\}$ 赋给 TIMER(k, t) 槽, 否则将 $TIMER(k, t-1)$ 赋给 TIMER(k, t) 槽。

- 槽 UPTIME(k, t) 的赋值规则:

如果 UPTIME($k, t-1$) = 0, PEAK-ST(k, t) \neq 0, $\exists i \in \{1, 2\}$, $|\tau_i - LT_i/2| \leq 10\% LT_i/2$ (τ_i 为方程 $[1, \tau, \tau^2] \cdot \alpha(t) = 20\% \text{ PEAK-ST}(k, t)$ 的根), 则将 $\{[\text{TIMER}(k, t) - LT_i] + \tau_i\}$ 赋给 UPTIME(k, t) 槽; 否则将 UPTIME($k, t-1$) 赋给 UPTIME(k, t) 槽.

- 槽 PEAK-ND(k, t) 的赋值规则:

如果 PEAK-ND($k, t-1$) = 0, UPTIME(k, t) > 0, DIFF(t) = true, CENTR(k, t) = true, 则将 EXTREM(t) 赋给 PEAK-ND(k, t) 槽; 否则将 PEAK-ND($k, t-1$) 赋给 PEAK-ND(k, t) 槽.

- 槽 PEAK-COVER(k, t) 的赋值规则:

如果 PEAK-COVER($k, t-1$) > 0, 则将 $[\text{PEAK-COVER}(k, t-1) - 1]$ 赋给 PEAK-COVER(k, t) 槽; 如果 PEAK-ND($k, t-1$) = 0, PEAK-ND(k, t) \neq 0, 则将 $\{[-\alpha_1(t)/\alpha_2(t)/2] \bmod T_s\}$ 赋给 PEAK-COVER(k, t) 槽; 否则将 PEAK-COVER($k, t-1$) 赋给 PEAK-COVER(k, t) 槽.

- 槽 PEAK-RD(k, t) 的赋值规则:

如果 PEAK-RD($k, t-1$) = 0, PEAK-COVER(k, t) = 0, PEAK-ND(k, t) \neq 0, DIFF(t) = true, CENTR(t) = true, 则将 EXTREM(t) 赋给 PEAK-RD(k, t) 槽; 否则将 PEAK-RD($k, t-1$) 赋给 PEAK-RD(k, t) 槽.

- 槽 COMPLETENESS(k, t) 的赋值规则:

如果 STEADY-STATE(k, t) = true, PEAK-ST(k, t) \neq 0, UPTIME(k, t) \neq 0; 或者 PEAK-ST(k, t) \neq 0, UPTIME(k, t) \neq 0, PEAK-ND(k, t) \neq 0, PEAK-RD(k, t) \neq 0, 则将 true 赋给 COMPLETENESS(k, t) 槽; 否则将 false 赋给 COMPLETENESS(k, t) 槽.

由上述规则可知, 各槽间存在复杂的逻辑耦合关系, 这是适应瞬态过程的各种变化特征间存在复杂的逻辑耦合关系所必需的.

在识别瞬态过程模式的整个算法中, 动态框架 TRAP(k, t) 及其内部推理是被整体引用的, 形成对该动态框架的外部逻辑推理.

除了在将新学习到的控制参数馈给控制器后一段适当长的时期外, 模式识别算法在每一采样时刻都会产生一个动态框架; 随着时间的推移, 就会产生一个动态框架序列. 如果用符号“ \leq ”表示“包含的关于同一瞬态过程的变化特征不多于”, 则有

$$\text{TRAP}(k, 0) \leq \text{TRAP}(k, 1) \leq \dots \leq \text{TRAP}(k, t_0), \quad (1)$$

所以动态框架实现了对瞬态过程的各个变化特征的表达、记忆、逻辑推理和识别, 因而对瞬态过程的模式识别算法起到了有效的引导作用, 是 LARGE 的关键基础.

三、从瞬态过程模式特征到控制参数修正值的映射

将基本反馈控制系统的性能向量 f 及其评价向量 Z 定义如下:

$$\left. \begin{aligned} f^{(1)} &\triangleq U(-\text{PEAK-ND}(k, t_0)/\text{PEAK-ST}(k, t_0)) \\ &\quad + U(\text{PEAK-RD}(k, t_0)/\text{PEAK-ST}(k, t_0)), \\ f^{(2)} &\triangleq \text{UPTIME}(k, t_0). \end{aligned} \right\} \quad (2)$$

$$\left. \begin{aligned} Z^{(1)} &= f^{(1)} - f_d^{(1)}, \\ Z^{(2)} &= f_d^{(2)}/f^{(2)} - 1. \end{aligned} \right\} \quad (3)$$

式中 $U(x)$: 当 $x > 0$ 时等于 x , 否则等于 0; f_d 为期望性能.

假设性能评价与控制参数之间复杂的非线性代数关系为

$$Z = F(\theta), \quad (4)$$

式中 θ 表示 μ 维控制参数向量, $F(\cdot)$ 表示二维向量非线性函数.

$F(\cdot)$ 的具体形式或大致构成形式一般都是难于获得的. 为此考虑一种间接方法.

在与固定的 $F(\cdot)$ 对应的非线性流形上一个足够小的划分区域上, 任意两点 (θ_1, Z_1) 和 (θ_2, Z_2) 之间可以相应的控制参数差距的级数来相互表达

$$Z_2 = I \cdot Z_1 + \frac{\partial F(\theta_1)}{\partial \theta_1} \Delta\theta_1 + H.O.T.(\|\Delta\theta_1\|), \quad (5)$$

式中 I 表示 2×2 维单位矩阵, $\Delta\theta_1 \triangleq \theta_2 - \theta_1$, $\|\cdot\|$ 表示某种向量范数, $H.O.T.(\cdot)$ 表示高阶项向量.

现用模型

$$Z_2 = A \cdot Z_1 + B \cdot \Delta\theta_1 \quad (6)$$

来近似上述两点间相互表达关系式 (5). 其中 A, B 是两个相当维数的数值矩阵, 它们在相应的数值矩阵空间中被最佳地拟合以使 (5) 式与 (6) 式间的误差沿整个划分区域上的积分总和为最小. 所得最优相互表达关系式称为互表模型, 它近似地表示了在与固定的 $F(\cdot)$ 对应的非线性流形上一个足够小的划分上普遍适用的控制参数变化对性能评价演变的影响规律.

不妨用 $Z(k+1)$, $Z(k)$ 和 $\Delta\theta(k) \triangleq \theta(k+1) - \theta(k)$ 分别代替互表模型中的 Z_2, Z_1 和 $\Delta\theta_1$, 得到一种便于递推辨识和利用的特殊互表模型

$$Z(k+1) = A \cdot Z(k) + B \cdot \Delta\theta(k), \quad (7)$$

(7) 式称为性能评价的演变模型. 该模型用带遗忘因子的递推最小二乘法在线实时辨识 (利用至今为止所有 (控制参数, 性能评价) 数据对辨识出的 A 和 B 分别记为 $A(k)$ 和 $B(k)$), 遗忘因子必须 $\epsilon(0, 1)$ 以使递推辨识出的模型具有足够的适应与固定的 $F(\cdot)$ 对应的非线性流形上划分的不同或 $F(\cdot)$ 的变化的能力.

鉴于互表模型只适用于与固定 $F(\cdot)$ 对应的非线性流形上一个足够小的划分上, (控制参数, 性能评价) 数据在学习控制参数的初期不充分, 实时自整定对控制参数学习过程要求十分苛刻, 因此结合专家的启发式知识和滚动最优预估原理, 编制了一组产生式规则来确定控制参数的修正值如下 (假定被学习参数的控制器的参数均是增益型的):

规则 I. 如果 $Z^{(1)} \geq 1.5f_d^{(1)}$, $\exists s \in \{1, \dots, \mu\}$, $b_{1s} > 0$, 则 $\Delta\theta(k)^{(i)} = -40\% \theta(k)^{(i)} \text{sgn}(b_{1j}(k))$, $j = 1, \dots, \mu$.

规则 II. 如果 $Z^{(1)} \geq 1.5f_d^{(1)}$, $\forall s \in \{1, \dots, \mu\}$, $b_{1s}(k) \leq 0$, 则 $\Delta\theta(k) = -40\% \theta(k)$.

规则 III. 如果 $Z^{(2)} \leq -0.6f_a^{(2)}$, 则 $\Delta\theta(k) = 40\% \theta(k)$.

规则 IV. 如果 $Z^{(1)} < 1.5f_a^{(1)}$, $Z^{(2)} > -0.6f_a^{(2)}$, $|\Delta\theta^*(k)^{(j)}| \leq 40\% \theta(k)^{(j)}$, 则 $\Delta\theta(k)^{(j)} = \Delta\theta^*(k)^{(j)}$, $j = 1, \dots, \mu$.

规则 V. 如果 $Z^{(1)} < 1.5f_a^{(1)}$, $Z^{(2)} > -0.6f_a^{(2)}$, $|\Delta\theta^*(k)^{(j)}| > 40\% \theta(k)^{(j)}$, 则 $\Delta\theta(k)^{(j)} = 40\% \theta(k)^{(j)} \operatorname{sgn}(\Delta\theta^*(k)^{(j)})$, $j = 1, \dots, \mu$. 其中 $b_{ij}(k)$ 是 $B(k)$ 的 $(1, i)$ 元, $\operatorname{sgn}(\cdot)$ 是符号函数. $\Delta\theta^*(k)$ 是

$$\min_{\Delta\theta(i)} 1/2 \sum_{i=k}^{\infty} [Z'(i)QZ(i) + \Delta\theta'(i)R\Delta\theta(i)]$$

$$\text{s.t. } Z(i+1) = A(k)Z(i) + B(k)\Delta\theta(i), i = k, k+1, \dots$$

的预估解序列的第一步, 式中 Q 和 R 分别是 2×2 和 $\mu \times \mu$ 维给定的正定矩阵. 显然

$$\left. \begin{aligned} \Delta\theta^*(k) &= -R^{-1}B'(k)A^{-1}(k)(M - Q)Z(k), \\ M &= Q + A'(k)[M^{-1} + B(k)R^{-1}B'(k)]^{-1}A(k). \end{aligned} \right\} \quad (8)$$

控制参数的滚动最优预估修正值是性能评价的线性反馈, 当基本反馈控制系统的实际性能已达到期望值时, 控制参数也就不再作修正了.

上述修正控制参数的五条产生式规则, 编号越小优先级越高.

四、专家式控制参数实时自学习的完整算法——LARGE

第 1 步. 向动态框架 $\text{TRAP}(k, t)$ 的各槽赋相应的缺省值.

第 2 步. 实时地采集控制偏差数据 $e(t)$.

第 3 步. 用 $e(t)$ 驱动按指数 t 的递推预处理算法向前移动一步, 得到更新后的拟合系数向量 $\alpha(t)$, $\beta(t)$ 和 $\pi(t)$.

第 4 步. 在将新学习到的控制参数馈进控制器后紧接着的 $[\text{UPTIME}(k, t_0) \bmod T_r]$ 个采样周期内, 直接转到第 2 步; 否则继续下一步.

第 5 步. 按 $\text{TRAP}(k, t)$ 中各槽被设置的相对顺序, 逐一匹配相应槽的赋值规则的前项, 并完成指定的赋值.

第 6 步. 如果 $\text{STEADY-STATE}(k, t) = \text{true}$, $\text{COMPLETE-NESS}(k, t) = \text{false}$, 则转到第 1 步; 否则继续下一步.

第 7 步. 如果 $\text{COMPLETENESS}(k, t) = \text{false}$, 则转到第 2 步; 否则继续下一步.

第 8 步. 基于识别出的完备动态框架 $\text{TRAP}(k, t_0)$ 所表达的瞬态过程的各个特征评价基本反馈控制系统的性能.

第 9 步. 利用当前数据对 $(\theta(k), Z(k))$ 驱动性能评价的演变模型 $Z(i+1) = A(k-1)Z(i) + B(k-1)\Delta\theta(i)$, $i = k-1, k-2, \dots$ 的递推辨识算法向前移动一步, 获得最新估计参数 $A(k)$ 和 $B(k)$.

第 10 步. 按照优先级别逐一匹配修正控制参数的五条产生式规则的各项, 从而确定下一步控制参数的修正值.

第11步. $\theta(k+1) = \theta(k) + \Delta\theta(k)$, 将此最新学习到的控制参数馈进控制器. 转到第1步.

值得注意的是, LARGE 的输入端控制偏差 $e(t)$ 的时间指数与输出端控制参数 $\theta(k+1)$ 的时间指数有本质区别. t 是采集控制偏差数据的采样时刻指数, 随时间变化确定性地增加; 而 k 是与完备的(见 COMPLETENESS (k, t) 槽)动态框架对应的瞬态过程出现的次数, 亦即控制参数的学习次数, 由于一个(完备的)瞬态过程是由各种随机噪声以及正常的或(和)不期望的扰动激励起来的, 因此指数 k 是随时间变化随机性地增加的, 进而控制参数的修正也是随机进行的.

五、LARGE 的性能的串行仿真验证

LARGE 能够在不影响基本反馈控制系统正常运行的情况下解决三类问题: 1) 为完全未整定的控制器学习到满意的控制参数; 2) 修正控制参数以适应控制器或(和)被控过程的变化; 3) 为控制参数的手工整定或修正提供开“环”指导.

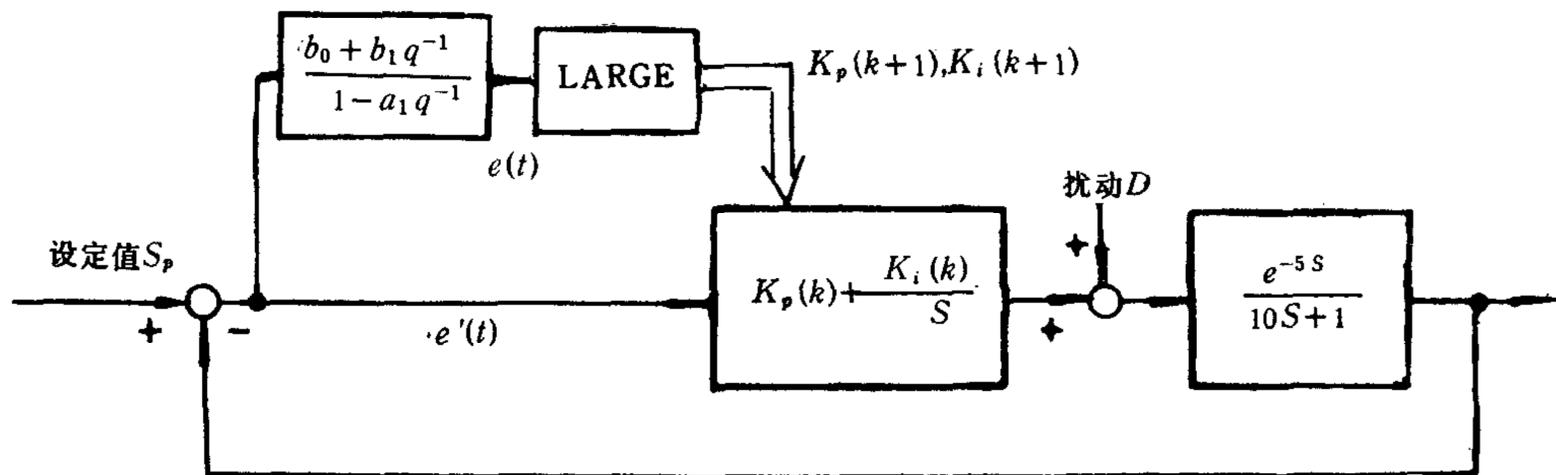


图 1 LARGE 为增益型 PI 控制器学习参数

表 1 学习 PI 控制器参数的过程

k	$K_p(k)$	$K_i(k)$	$Z(k)^{(1)}$	$Z(k)^{(2)}$	
0	.01	.01	-.20	-.75851	$S_p = 1(t)$ $D = 0$
⋮	⋮	⋮	⋮	⋮	
13	.19138	.03759	.01423	-.15728	
14	.26793	.04036	.00008	-.05587	
0	.07	.07	.89954	.19134	$S_p = 0$ $D = 1(t)$
⋮	⋮	⋮	⋮	⋮	
17	.43328	.05328	.10109	-.00415	
18	.45333	.0531	.03184	-.00659	

下面仅对最困难的第一类问题在计算机上将 LARGE 和控制器串行地仿真来验证其性能. 仿真系统构成如图 1. 各种仿真参数为 $T_s = 0.5$ 秒, $\epsilon = 1E - 3$, $\Delta = 1E - 2$, $L = 20$, $\lambda = 0.97$, $\mu = 2$, $Q = R = I$, $A(0) = B(0) = 0$, $P(0) = 1E + 10$, $f_a^{(1)} = 0.20$, $f_a^{(2)} = 16$, $\theta(0)$ 给定, $a_1 = b_0 = 0.36788$, $b_1 = 0.26424$. 结果如表 1.

六、结 束 语

LARGE 不受基本反馈控制系统中信号“持续激励条件”的限制。

LARGE 在各种恶劣情形下仍能够给出满意的控制参数修正值, 因而使控制参数学习具有良好的起动力能和过程; 结果不但能较快地将基本反馈控制系统的性能囿于期望性能的某个较小邻域内, 而且还能(由二次型性能指标的物理意义)最优地、谨慎地收敛于期望性能。

由于 LARGE 不需要控制器或被控过程的任何直接模型, 因此它原则上不受控制器和被控过程的复杂程度直接限制, 能给任何增益型控制器学习到满意的控制参数, 并为之赋予适应控制器或(和)被控过程变化的能力。此外, LARGE 本身还具有自适应能力。

参 考 文 献

- [1] Ortega, R. et al., PID Self-tuners: Some Theoretical and Practical Aspects, *IEEE Trans On Ind. Elec.*, **IE-31** (1984), 4, 332—338.
- [2] 李 南等, 智能调节器参数在线仿人自整定, 重庆大学学报, (1985), No. 1, 135—145.
- [3] Carmon, A., Intelligent Knowledge-based System for Adaptive PID Controller Tuning, *Journal A.*, **27**(1986), 3, 133—138.
- [4] Myron, T. J., Self-tuning PID Control—An Expert System Approach, *Auto. Cont. in Petro., Petroch. and Desa. Ind., Proc. of the IFAC Workshop, Kuwait*, 6—8 Jan., 1986, 77—80.

REAL-TIME EXPERT SELF-LEARNING ALGORITHM FOR REGULATOR GAINS (LARGE)

TIAN HUA JIANG WEISUN

(Auto. Res. Cent., East China Inst. of Tech., Shanghai 200237)

ABSTRACT

By means of more detailed and faithful simulation of the heuristic process where the expert assign the regulator gains, an advanced real-time expert-like self-learning algorithm has been developed. The first problem solved is how to recognize the pattern of a transient process and extract its features from sequentially sampled regulation error data corrupted by various noises and disturbances. The second is how to map those features which reflect various properties of the essential feedback regulation system onto the regulator gains for further improvement of its performances.

Key words : Real-time pattern recognition; real-time production systems; frame representation; regulator self-settling; repetitive learning.



田 华 1966 年生于四川省江安县。1986 年在四川轻化工学院生产过程自动化专业获得工学学士学位, 1989 年在华东化工学院自动化研究所获得工学硕士学位, 现在该所攻读工学博士学位。从事了模糊控制、专家控制及智能控制系统等方面的研究工作, 是流加式聚合反应生产过程计算机智能控制系统工程项目的主要研制人员, 承担了两项中国科学院开放研究实验室基金资助的智能机器人动作规划方面的课题。共已发表学术论文 10 余篇。1990 年荣获全国首届“宝钢”奖学金。当前主要研究领域为智能机器人动作规划, 智能机器人系统, 机器学习与知识工程等。



蒋慰孙 教授, 博士生导师。华东化工学院自动化研究所所长, 中国自动化学会常务理事, 上海市自动化学会副理事长, IFAC 先进化工过程控制委员会委员, 在中国仪器仪表学会过程检测仪表控制专业委员会、中国化工学会化工自动化专业委员会、中国生物学会生化过程控制专业委员会担任要职。1947 年毕业于上海交通大学化学系。在上海华东化工学院创办了国内最早的化工自动化及仪表专业, 并发展成今日的电子工程与自动控制系和自动化研究所。指导的研究生已有 30 多人获得硕士学位, 10 多人获得博士学位。至今已发表了近 200 篇中外文学术论文。当前研究领域为先进生产过程建模、控制、调度、管理、决策及其计算机系统集成系统, 正交函数系及应用, 分布参数系统, 神经网络应用, 故障诊断, 容错控制, 智能控制, 智能机器人等。