

时滞不确定大纯滞后系统的神经元 非模型控制

刘稳国 周重阳 王文海 孙优贤

(浙江大学工业控制技术研究所 浙江大学工业控制技术国家重点实验室 中国杭州 310027)

摘要 本文利用文[1]给出的神经元模型, 提出了一种针对存在不确定时滞的大纯滞后对象的非模型控制策略。该方法完全不依赖于被控对象的数学模型, 又克服了大滞后对象控制后果不能及时反馈的不足。应用该方法对大纯滞后一阶和二阶对象的仿真研究表明, 该方法对大纯滞后系统的不确定时滞具有很强的适应性, 各种控制性能明显优于传统的 PID 控制。

关键词 神经元 非模型控制 纯滞后 PID 控制

1 引言

工业过程中普遍存在着具有大纯滞后和参数不确定的被控对象, 这是控制器设计难以解决的问题, 特别是当滞后时间远大于对象的时间常数时, 由于控制作用的迟延, 极易引起系统闭环的不稳定或根本无法对系统进行有效的控制。同时由于对象时滞的不确定性, 难以建立精确的数学模型, 基于对象模型的纯滞后补偿施密斯预估器或采用数字控制器的达林算法很难在实际过程中实现。人工神经网络具有很强的自学习和自适应那能力, 可以处理那些难以用数学模型描述的, 不确定的对象, 但基于多层前向网络的神经控制方法存在着算法复杂, 参数收敛慢, 存在局部最小点, 在线学习困难等缺点, 使其在工业控制中的应用遇到了很大的困难。为此, 本文作者之一提出了一种面向控制的神经元非模型控制方法, 并相继在水轮机和电渣重熔等工业过程中获得成功, 本文针对时滞不确定大纯滞后对象, 将文[1]的控制方法作了改进, 取得令人满意的效果。

2 神经元非模型控制

文[1]针对将现有多层前向神经网络直观套用控制中存在的缺陷, 提出了一种适用于控制的神经元模型, 并建立了相应的神经元非模型控制系统(如图 1 所示), 图中转换器将来自环境 E 的信号转换为神经元的输入状态 $x_i(t)$, 神经元的输出 $s(t)$ 可表示为:

$$s(t) = k \cdot \sum_{i=1}^n w_i(t)x_i(t) \quad (1)$$

其中, $k > 0$ 是神经元的增益, $w_i(t)$ 是相应于神经元输入 $x_i(t)$ ($i = 1, 2, \dots, n$) 的权值, 其值由相应的神经元算法确定.

一般认为神经元通过改变自身的突触加权值进行自组织. 根据 D.O.Hebb 提出的著名假设, 可以得到以下学习规则:

$$w_i(t+1) = w_i(t) + d \cdot p_i(t) \quad (2)$$

式中, $d > 0$ 是学习速率, $p_i(t)$ 是学习策略. 为适应控制的要求, 文[1]提出了如下联想式学习策略:

$$p_i(t) = z(t)s(t)x_i(t) \quad (3)$$

该学习策略表示神经元采用 Hebb 学习 ($p_i(t) = s(t)x_i(t)$) 和监督学习 ($p_i(t) = z(t)x_i(t)$) 相结合的方式, 通过关联搜索对未知的外界作出反应和作用. 这意味着神经元在教师信号 $z(t)$ 的指导下对环境信息进行自组织来产生控制作用, 并隐含着对神经元作用信号的评价.

由上述的神经元模型及学习策略, 文[1]提出了如下的神经元控制器学习算法:

$$\begin{cases} u(t) = [k \sum_{i=1}^n w_i(t)x_i(t)] / \sum_{i=1}^n |w_i(t)| \\ w_i(t+1) = w_i(t) + d[r(t) - y(t)]u(t)x_i(t) \end{cases} \quad (4)$$

式中, $r(t)$ 为给定信号, $y(t)$ 为对象的实际输出, $w_i(t)$ 为对应于输入 $x_i(t)$ 的权值, $x_i(t)$ 为神经元的输入状态, 可在进行控制系统设计时根据需要来选取.

3 控制系统设计

纯滞后系统的当前输入需要经过滞后时间 τ_0 后才能在输出中表现出来, 因而在常规 PID 控制或文[1]中的神经元控制中采用设定值与当前输出比较获得控制量的方法没有考虑这一滞后时间 τ_0 , 系统的阶跃响应超调大, 不易稳定. 对于存在滞后的对象, 只有考虑了滞后时间的控制器才能获得较好的控制作用. 为提高系统的稳定性, 将设定值输入进行滤波处理, 以减小过量的控制作用. 方法如下:

1. 设定值的滤波处理: 能减小过量的控制作用, 从而减小甚至消除超调, 使系统能平滑地达到设定值. 滤波器采用一阶形式即可, 即:

$$y_r(t+1) = (1 - \alpha) \cdot r(t) + \alpha \cdot y_r(t) \quad (5)$$

其中, r 为设定值, y_r 为滤波处理后的设定值, $0 < \alpha < 1$, 可调节系统鲁棒性的强弱.

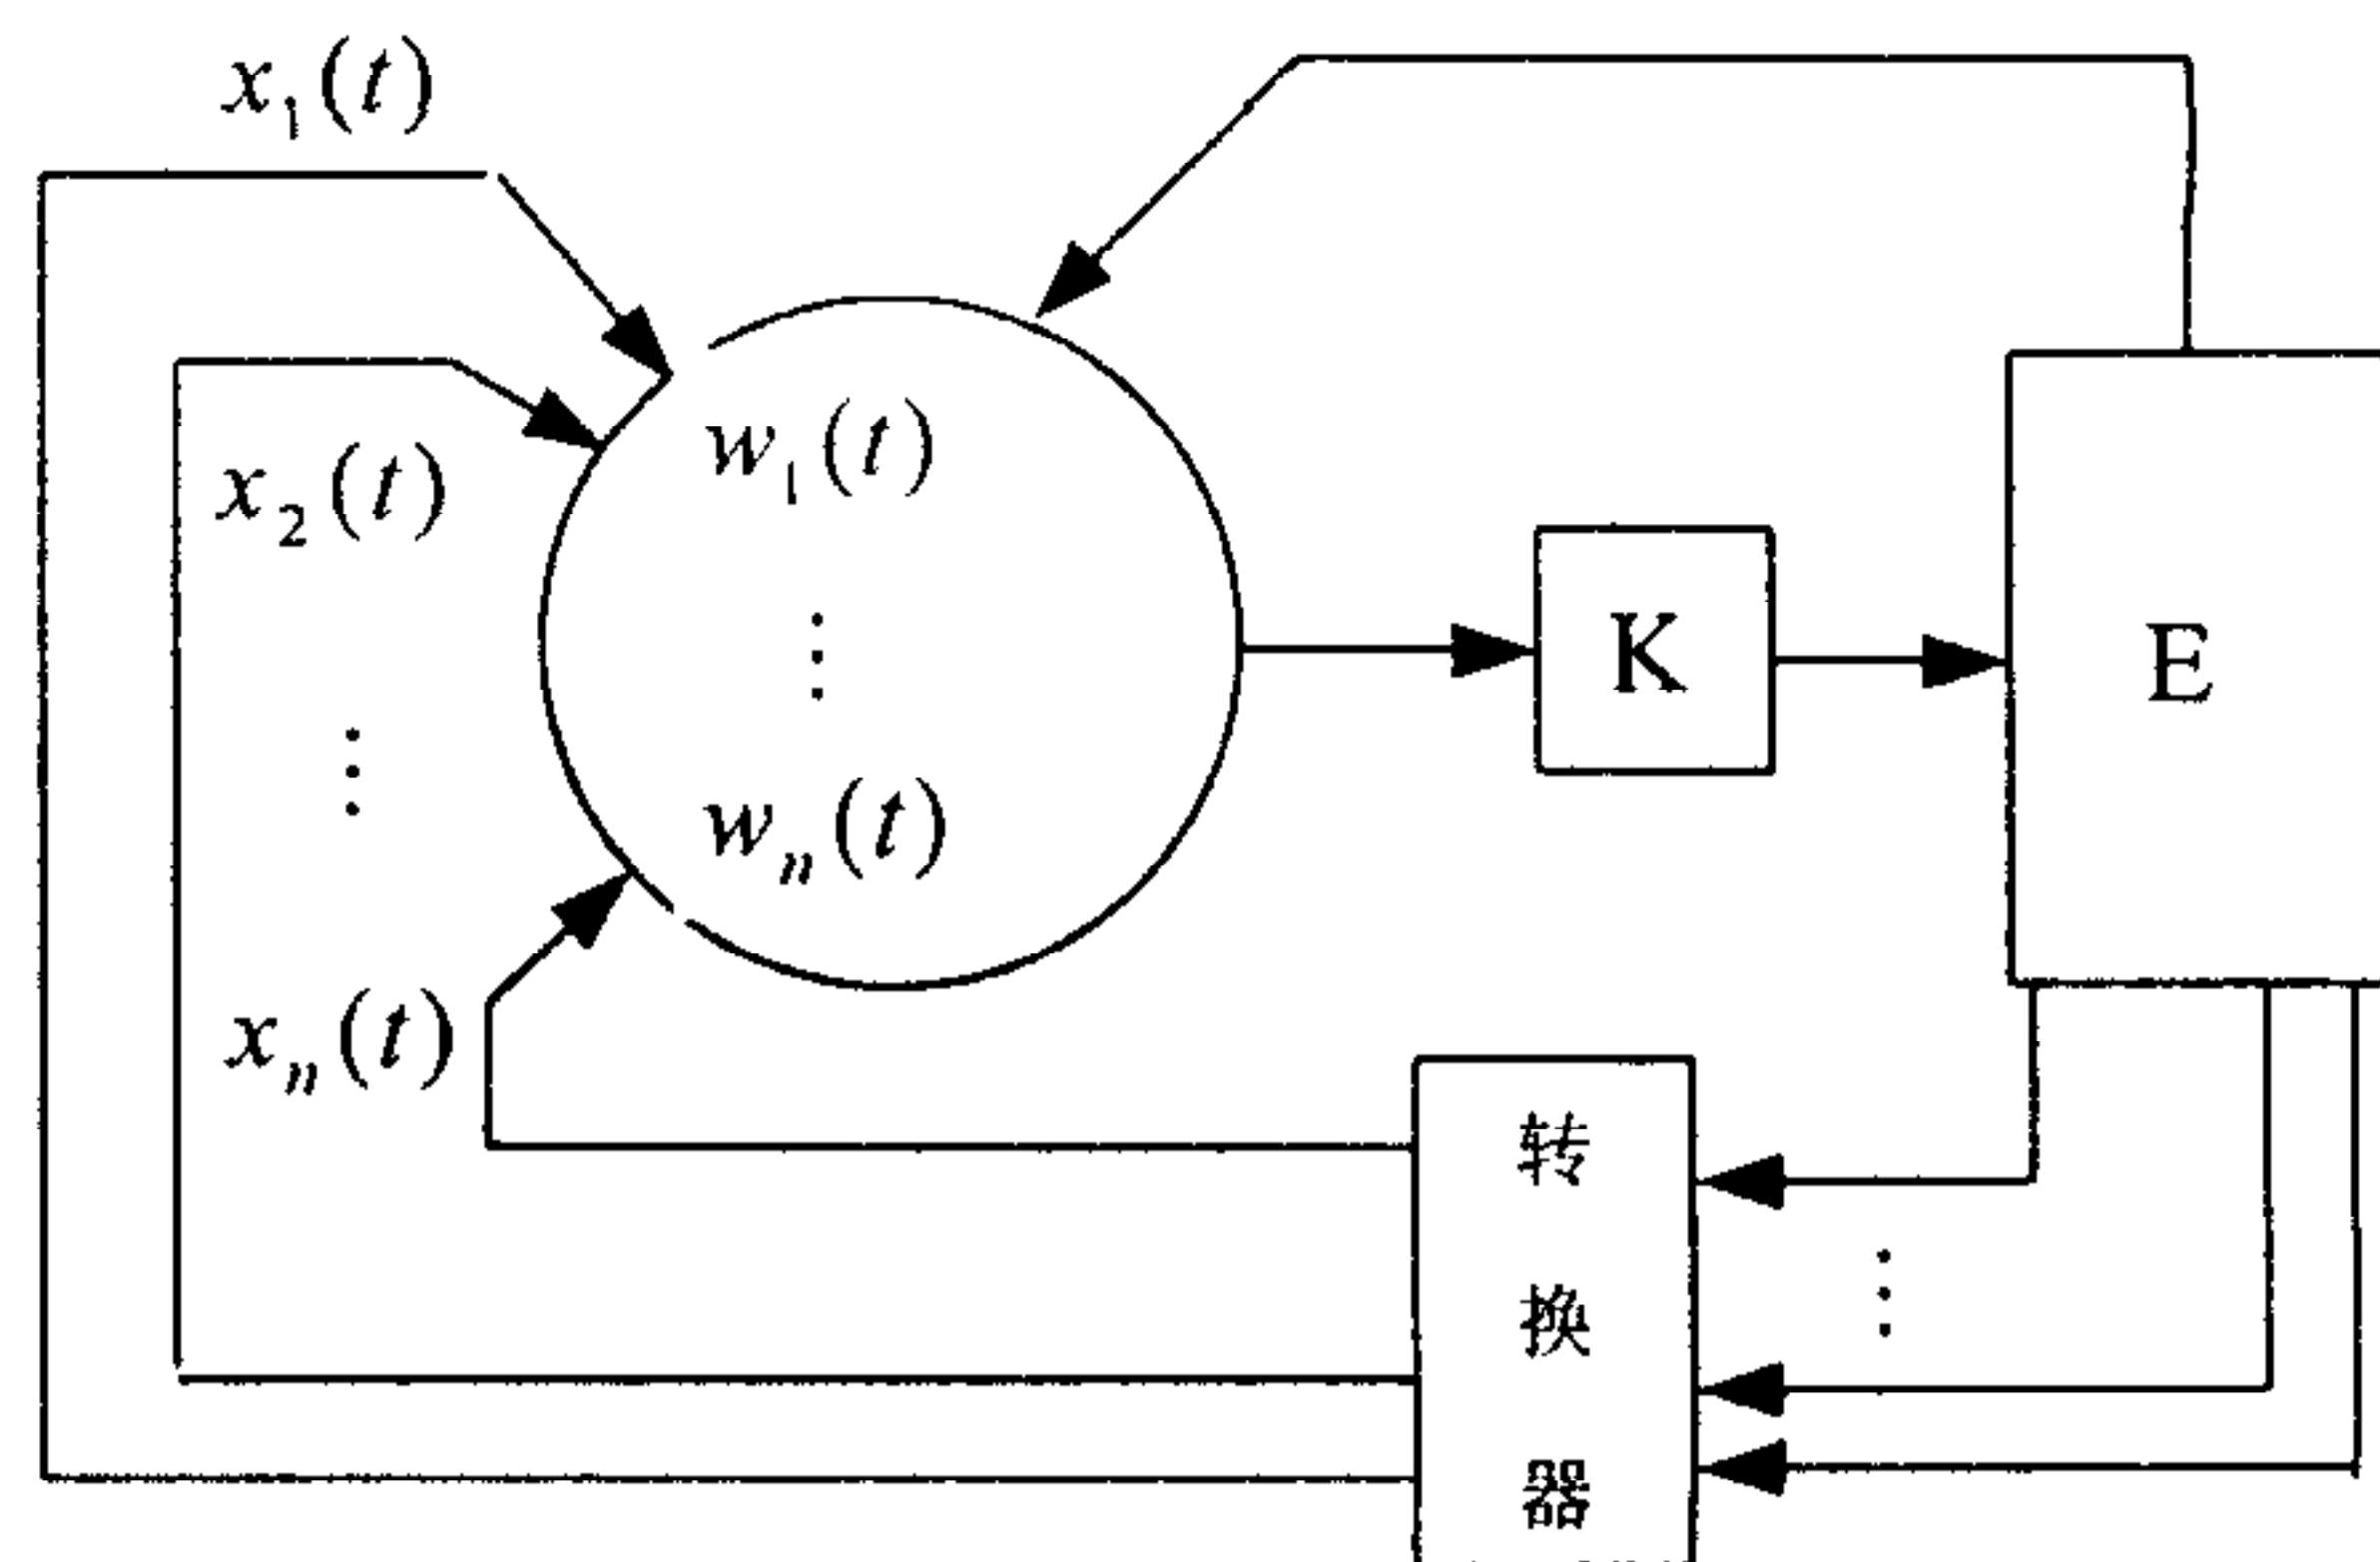


图 1 面向控制的神经元模型

2. 神经元输入状态 $x_i(t)$ 的选择: 若系统的滞后步数为 N , 则利用文[1]的神经元模型, 选取如下输入状态:

$$\begin{cases} x_1(t) = y_r(t) \\ x_2(t) = y_r(t-N+1) - y(t) \\ x_3(t) = y(t) - y(t-1) \\ x_4(t) = x_4(t-1) + \beta \cdot x_2(t), x_4(0) = 0 \end{cases} \quad (6)$$

3. 权系数 $w_i(t)$ 的学习算法相应地调整为:

$$w_i(t+1) = w_i(t) + d \cdot (y_r(t-N+1) - y(t)) \cdot x_i(t) \quad (7)$$

当输入的设定值发生变化时, 对延迟步数 N 进行在线辨识, 取评价函数 $E_i(t, t_0) = \sum_{k=t_0}^t |(y(k) - y_r(k-i))|$, 其物理意义表示在时间内 (t_0, t) 内的系统输出轨迹与设定值输入轨迹的吻合程度, 其辨识算法如下:

- ①确定延迟步数的搜索范围 $[M_1 \sim M_2]$, $M_2 > N > M_1$, 均为正整数, 其中, M_1, M_2 根据具体情况而定, 但范围选得太大则会加大计算量; 辨识步数 $M > M_2$; N 的初值任选; 计数器初值 $c > M$;
- ② $r(t)$ 是否有变化, 若无, 转④;
- ③取计数器值 $c = 1, E_i(t, t) = 0$;
- ④判断是否 $c \leq M$, 否则转⑧;
- ⑤采入数据 $y(t), y_r(t)$, 计算 $E_i(t, t+c) = E_i(t, t+c-1) + |y_r(t-i) - y(t)|$, 当 $E_{i_0}(t, t+c) = \min E_i(t, t+c)$ 时 $N = i_0$; ($i_0, i \in [M_1 \sim M_2]$)
- ⑥ $c = c + 1$;
- ⑦将 N 送入神经元控制器;
- ⑧若继续, 转②, 否则转⑨;
- ⑨停止.

4 仿真研究

系统给定输入函数为阶跃函数, 被控对象分别为有纯滞后的一阶环节和二阶环节, 纯滞后时间为对象时间常数的 5 倍以上, 且有不确定性.

4.1 被控对象为纯滞后一阶环节

考虑到采样保持器, 纯滞后一阶环节的传递函数为

$$G(S) = \frac{K}{T_m S + 1} e^{-TS} \quad (8)$$

上式中, T 为系统的采样周期, T_m 为对象的时间常数, K 为对象的放大系数, τ 为纯滞后时间, 如 $K = 1, T = T_m = 1.5$ 秒, $\tau = 15$ 秒. 考虑零阶保持器, 则被控对象

的离散化仿真算式为:

$$y(k+1) = 0.368y(k) + 0.632u(k-10)$$

仿真时间为 200 个采样周期, 共 5min.

式(8)对象的常规 PID 控制器参数为: $K_p = 1.15T_m/(K\tau) = 0.115$, $T_I = 0.3 \text{ min}$, $T_D = 0.45\tau = 0.1125 \text{ min}$.

采用此常规 PID 控制器对式(8)对象控制后的阶跃响应曲线如图 2 所示, 有图 2 可知, 采用常规 PID 控制器控制大纯滞后一阶环节是, 系统的动态性能并不令人满意, 超调量比较大.

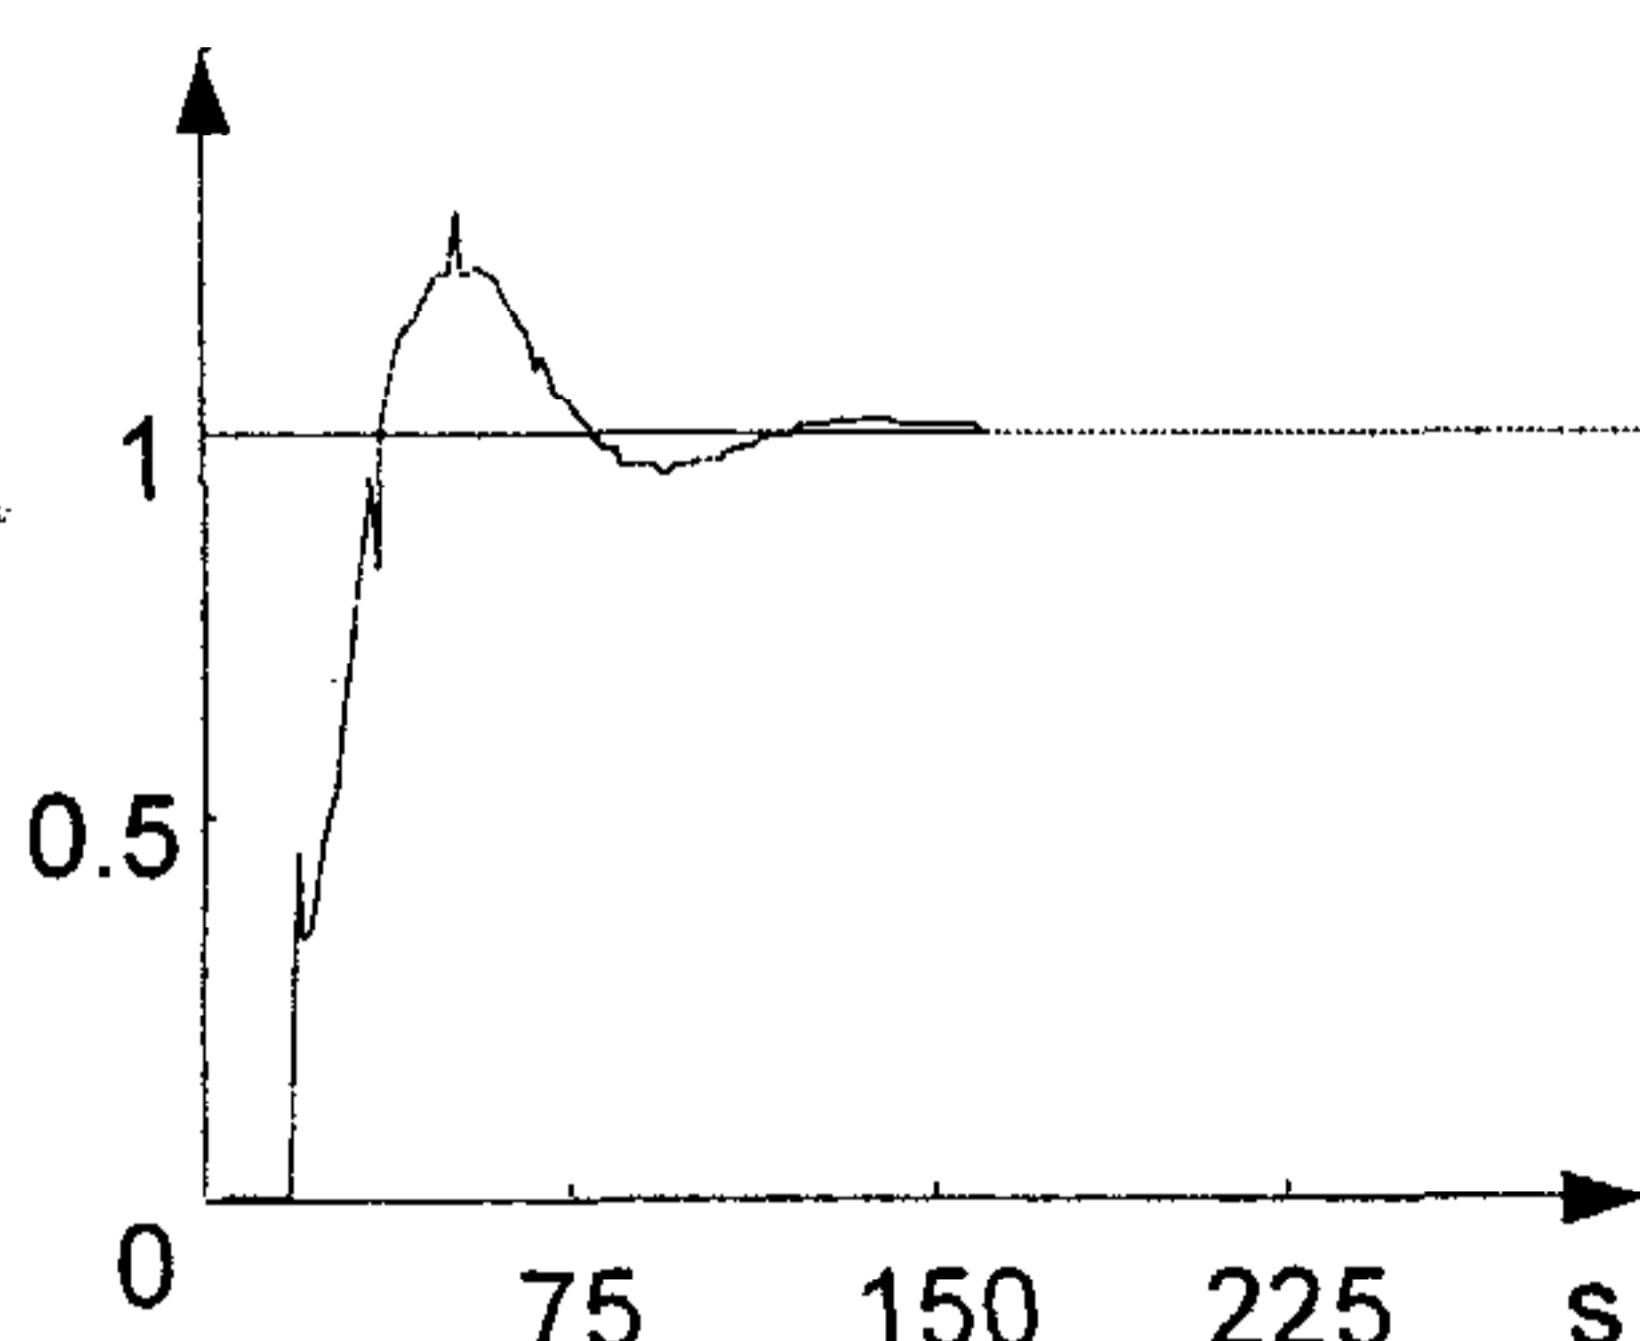


图 2 PID 控制的阶跃响应

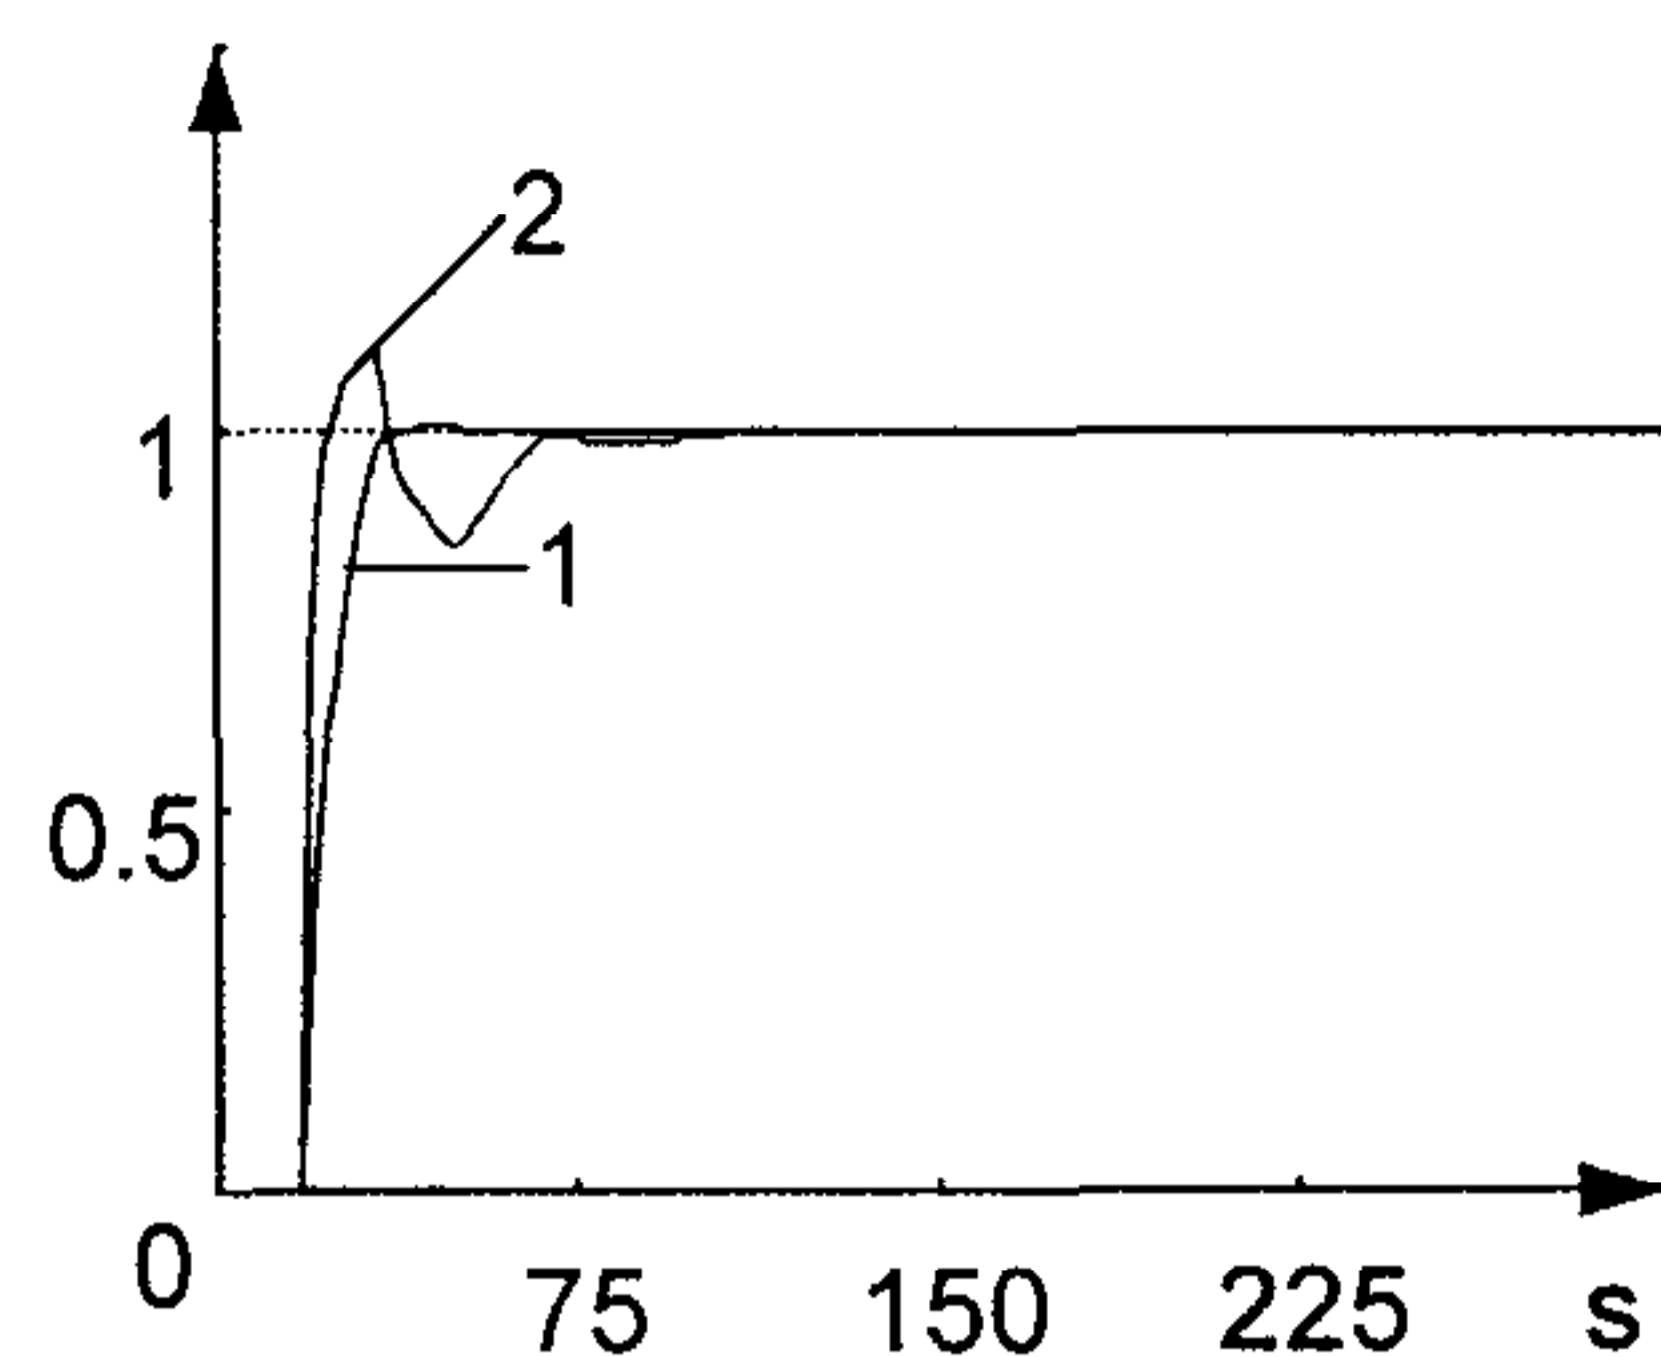


图 3 纯滞后一阶对象阶跃响应

图中曲线 1 为滤波系数 $\alpha = 0.2$ 时的情况, 曲线 2 为 $\alpha = 0.5$ 时的情况

仅采用文[1]控制算法, 控制效果同样不令人满意, 但本文将控制策略修改后, 取得了较好的效果. 采用本文的控制策略, 神经元比例系数取为: $K = 1.42$, 积分项系数 $\beta = 0.1$, 学习率取为 $d = 2$, 神经元的初始权重随机选取. 滞后步长范围选取为 $N \in \{k \mid 5 \leq k \leq 30\}$. 滤波器系数的选取根据具体情况而定, 若 α 取得较小, 则系统鲁棒性较强而快速性较差, 反之, 则快速性较好而鲁棒性较差, 分别取 $\alpha = 0.2$ 和 $\alpha = 0.5$ 进行仿真, 系统阶跃响应如图 3 所示, 当 $\alpha = 0.2$ 时, 系统能平滑地到达设定值, 但上升时间稍长, 约为 10 个采样周期(15 秒), 当 $\alpha = 0.5$ 时, 系统的上升时间约为 3 个采样周期(4.5 秒), 但稳定性变差. 当对象纯滞后时间为 $\tau = 30$ 秒时, 系统阶跃响应如图 4 所示.

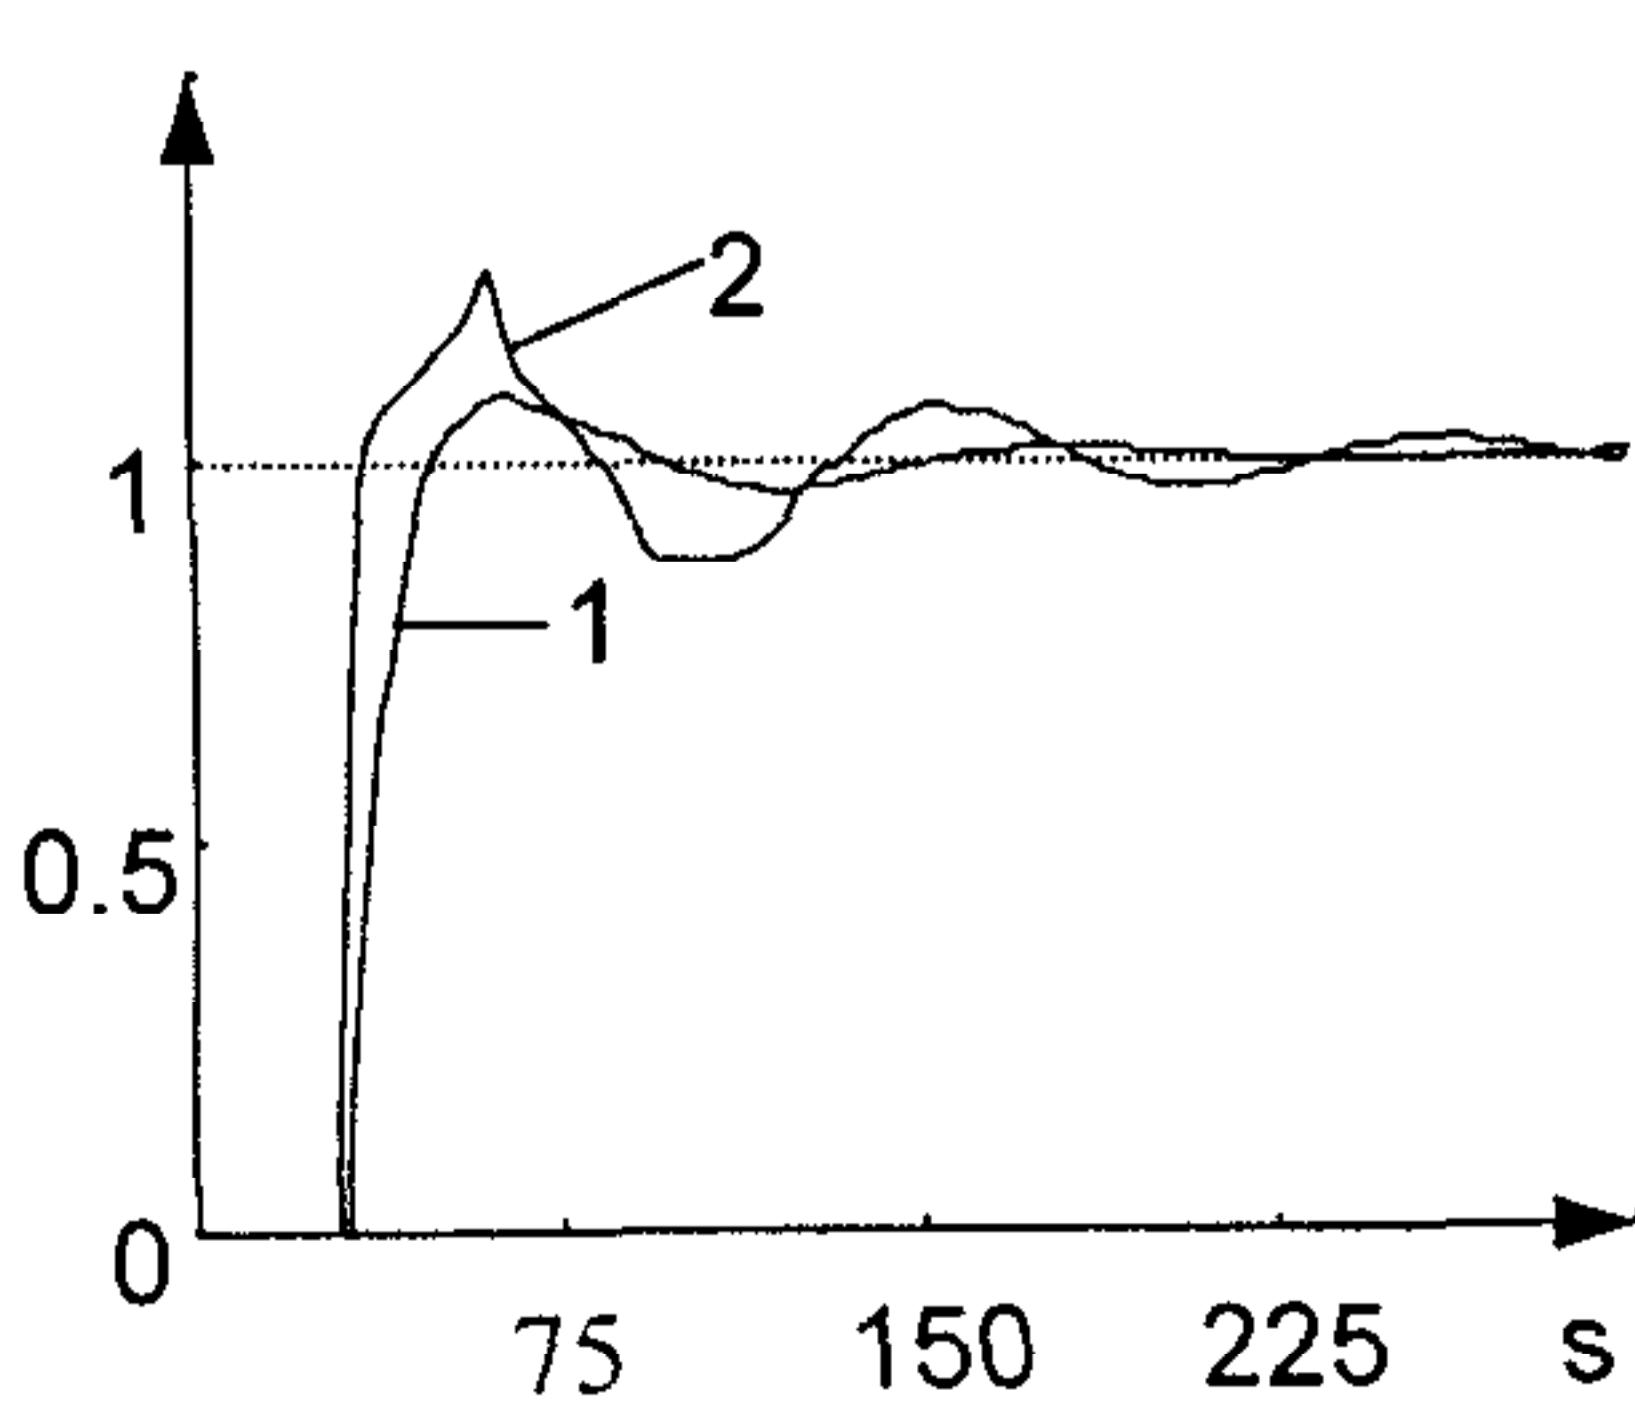


图 4 对象时滞增大后的阶跃响应

图中曲线 1 为滤波系数 $\alpha = 0.2$ 时的情况, 曲线 2 为 $\alpha = 0.5$ 时的情况

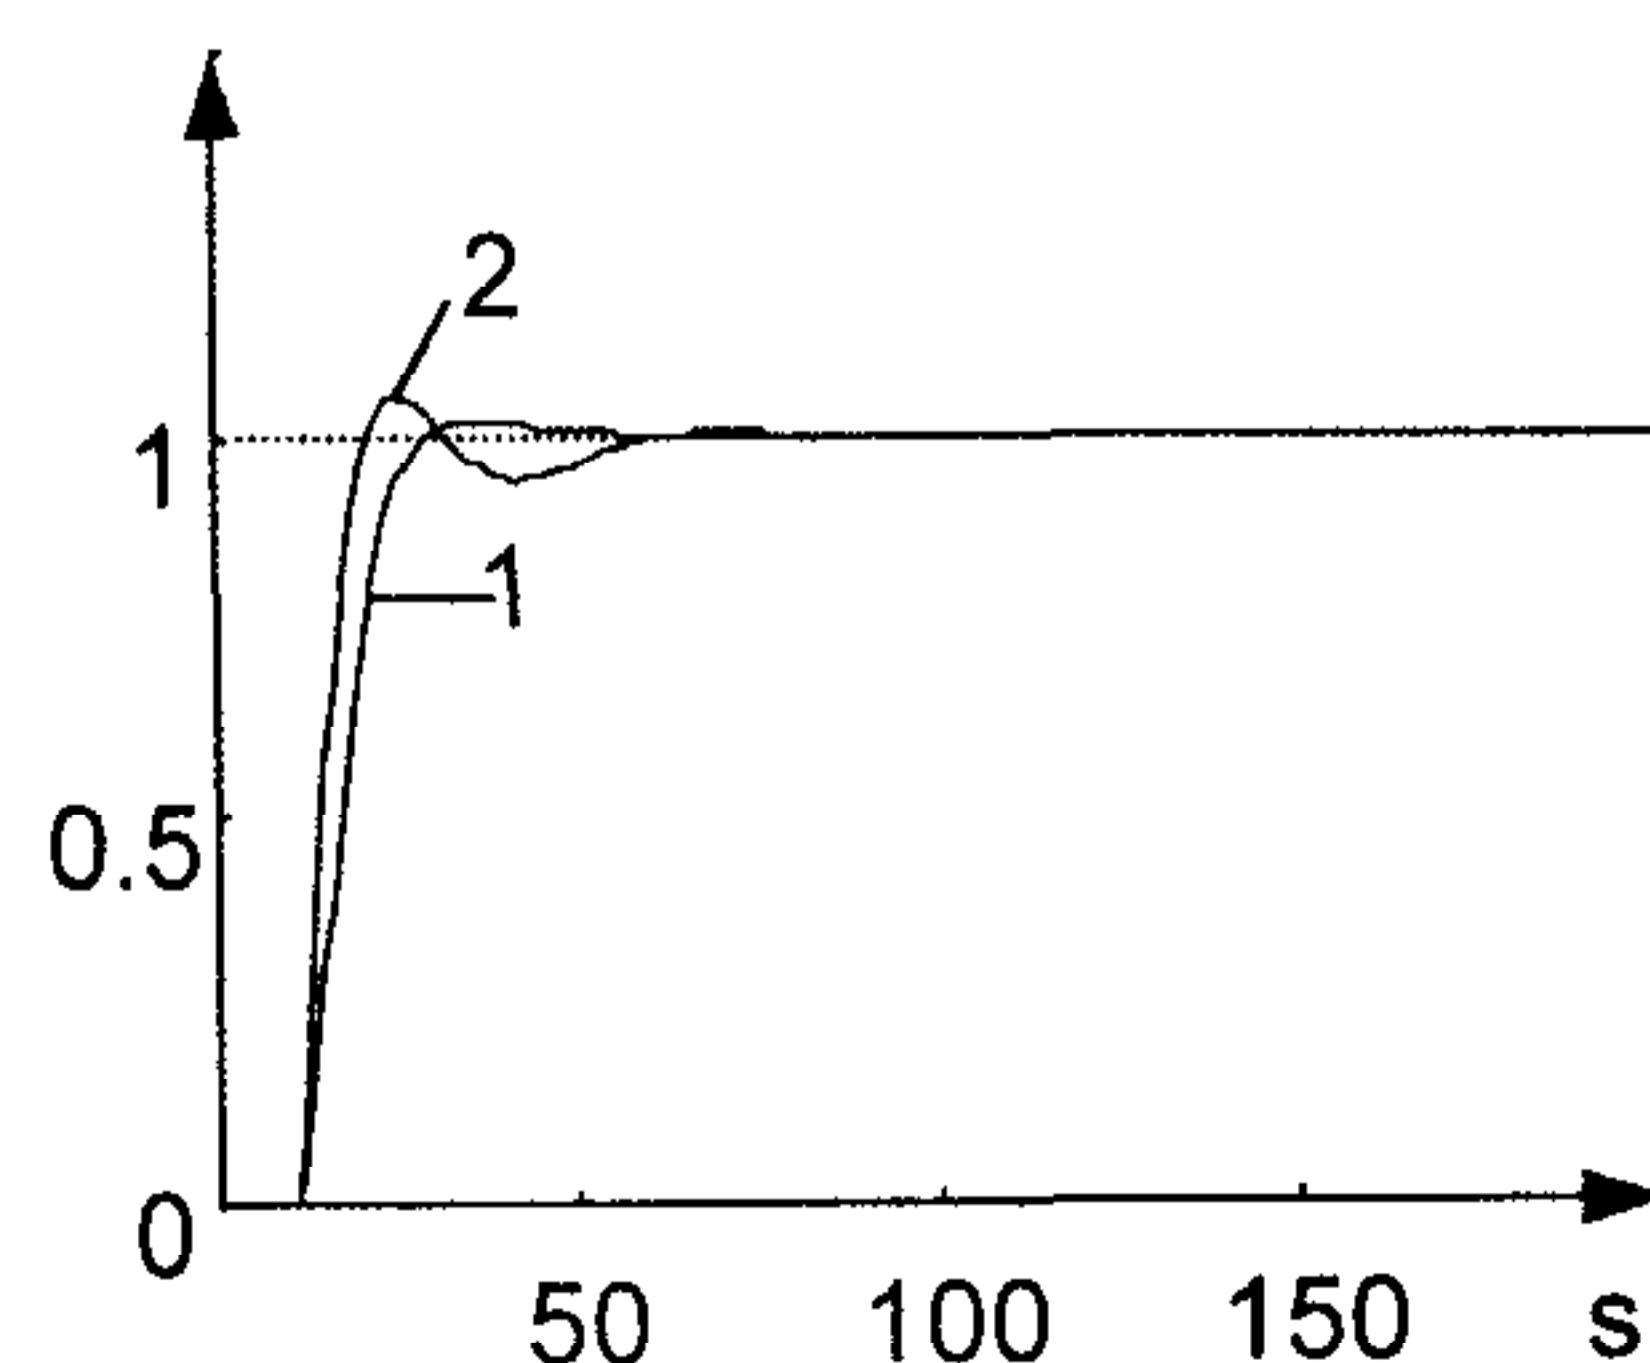


图 5 纯滞后二阶对象的阶跃响应

图中曲线 1 为滤波系数 $\alpha = 0.2$ 时的情况, 曲线 2 为 $\alpha = 0.5$ 时的情况

4.2 被控对象为纯滞后二阶环节

设对象的传递函数为 $G(S) = \frac{Y(S)}{U(S)} = \frac{e^{-15S}}{(S+1)(2S+1)}$, 采样周期为 1 秒, 这样的大纯滞后二阶对象, 常规 PID 控制和文[1]中的神经元控制的控制效果均不理想, 采用本文的控制策略, 神经元比例系数取为: $K = 1.4$, 积分项系数 $\beta = 0.1$, 学习率取为 $d = 2$, 神经元的初始权重随机选取。滞后步长范围选取为 $N \in \{k | 5 \leq k \leq 30\}$. 系统阶跃响应如图 5 所示. 当系统时滞发生较大变化, 即

$$G(S) = \frac{Y(S)}{U(S)} = \frac{e^{-25S}}{(S+1)(2S+1)} \text{ 时, 控制}$$

器参数不变, 系统阶跃响应如图 6 所示. 以上仿真说明, 本文针对纯滞后对象提出的控制策略完全不依赖于对象的模型, 对时滞的变化具有极强的自适应能力, 能对大纯滞后的系统实现快速有效的控制, 具有较满意的动态和静态性能.

5 结论

神经元非模型控制的最突出的优点是其参数的整定完全不依赖与对象的数学模型, 控制算法简单, 易于实现. 本文针对大纯滞后系统提出的控制策略拓宽了文[1]中的神经元控制器的应用范围, 且具有很好的控制品质, 在工业过程控制中具有良好的应用前景.

参 考 文 献

1. 先进控制技术讲义, 浙江大学控制科学与工程学系, 1999
2. 舒怀林 李柱, 大纯滞后神经网络结构 PID 控制器, 中国控制与决策学术年会论文集, 1997: 714—718

刘稳国 男, 1976 年生, 1998 年毕业于浙江大学电机系电力系统及其自动化专业, 现为浙江大学控制科学与工程系硕士, 主要研究方向为非模型自适应控制理论与应用等.

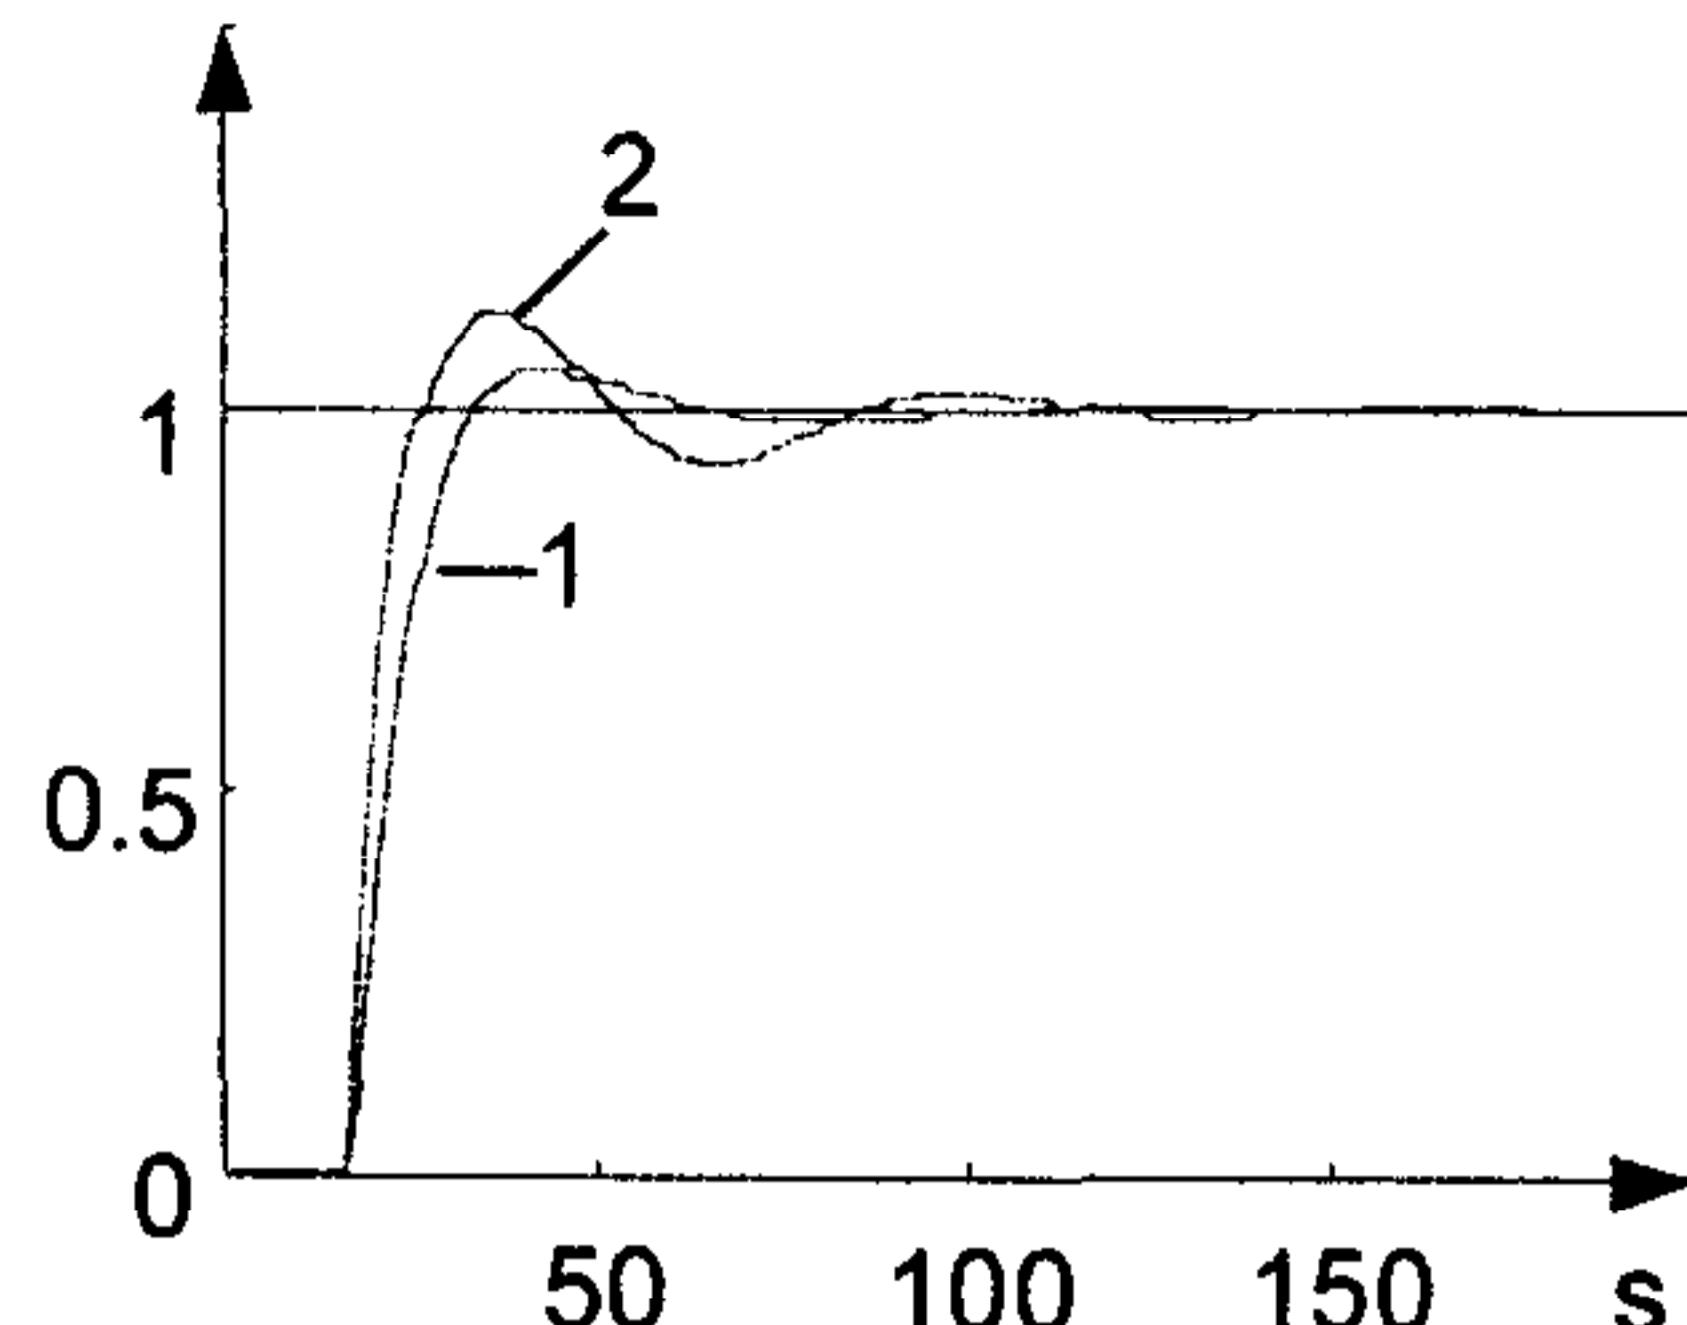


图 6 对象时滞增大后的阶跃响应

图中曲线 1 为滤波系数 $\alpha = 0.2$ 时的情况, 曲线 2 为 $\alpha = 0.5$ 时的情况