

# 基于RBF神经网络的机械手自适应控制研究

## Research on to the Adaptive Control Technology for Manipulator to Be Based on RBF Neural Network

■长安大学道路施工技术装备教育部重点实验室 陈兆鲁/CHEN Zhaolu 郑 贺/ZHENG He

**摘 要** 针对控制系统的不同性能要求, 现有的 PID 控制算法等对机器人轨迹跟踪控制的控制精度不高, 根据 RBF 神经网络的非线性映射能力及快速学习能力, 提出了基于 RBF 神经网络的自适应控制算法, 在机械手动力学模型的基础上利用 MATLAB 软件对该算法进行模拟仿真, 仿真结果表明了该算法具有较高的轨迹跟踪控制精度, 可以达到很好的控制效果。

**关键词** RBF 神经网络 PID 控制 自适应控制 MATLAB 仿真

DOI:10.13824/j.cnki.cmtm.2015.04.030

机械手系统是一个时变, 强耦合的复杂非线性系统。因为存在变负载、非线性摩擦力和机械损耗等不确定因素, 导致机械手的控制过程变得很复杂, 在对机械手进行测量和建模时具有很大的不确定性。在机械手的控制算法中, PID 控制算法是目前市场上使用最广泛的一种, 但 PID 算法在要求较高的场合及参数不稳定的情况下控制效果并不好。尤其是在越来越复杂的非线性控制系统中, 被控对象也越来越复杂, 人们对控制精度有了更高的要求, 常规控制器就不能得到较好的控制效果, 从而智能自适应控制应运而生且成为解决上述问题的有效方法<sup>[1]</sup>, 其中的神经网络<sup>[2]</sup>由于具有良好的自适应性和学习能力而得到广泛的应用。




图1 RBF神经网络结构图

## 1 RBF神经网络控制

### 1.1 RBF神经网络简介

径向基函数(Radial Basis Function, RBF)神经网络<sup>[3]</sup>是 20 世纪 80 年代末由 J.Moody 和 C.Darken 两人提出的, 它是一个三层前馈网络, 并且只具有一个隐含层, 多输入单输出 RBF 神经网络的结构<sup>[4]</sup>如图 1 所示。

RBF 网络的输出可表示为:

$$y_m(t) = w_1 h_1 + w_2 h_2 + \dots + w_m h_m \quad (1)$$

输入向量与隐含层通过高斯基函数非线性映射连接起来, 高斯基函数下:

$$h_j = \exp\left(-\frac{\|X - C_j\|^2}{2b_j^2}\right) \quad j = 1, 2, \dots, m \quad (2)$$

其中,  $C_j = [c_{j1}, c_{j2}, \dots, c_{jn}]^T$  表示第  $j$  个节点的中心矢量; 参数  $B = [b_1, b_2, \dots, b_m]^T$  为 RBF 网络的基宽向量;  $W = [w_1, w_2, \dots, w_m]^T$  代表网络的权向量。

### 1.2 RBF神经网络用于控制的特点

RBF 网络的高斯基函数通常被用来作隐含层的作用函数, 其值在输入空间中有限的范围内是非零值, 所以 RBF 网络被认为是具有局部逼近特性的网络。由 RBF 的结构图 1 可知它是一个三层的向前网络, 它的映射关系为: 输入层非线性映射到隐含层, 隐含层线性映射(通过权值连接)到输出层, 又因该网络具有局部逼近特性, 所以采用该网络可以加快学习的速度而且还可以有效规避局部极小问题, 满足实时控制的要求。因此采用 RBF 神经网络对机械手进行控制<sup>[5-6]</sup>可有效提高系统的精度且能实现实时控制的要求。利用 RBF 神经网络对机械手进行控制时, 选取 RBF 网络性能指标函数为:

$$J_1(t) = \frac{1}{2} (y(t) - y_m(t))^2 \quad (3)$$

为了达到节省时间和加快收敛速度的目的, 本文采

用梯度下降法<sup>[7]</sup>对网络的权值进行修正；按照  $j(t)$  对加权系数的负梯度方向进行搜索调整，同时把一个动量因子（正比于前次加权变化量）加给每个加权调节量。使用该算法去求解各参数的迭代过程可表示为：

$$w_j(t) = w_j(t-1) + \eta(y(t) - y_m(t))h_j + \alpha(w_j(t-1) - w_j(t-2)) \quad (4)$$

$$\Delta b_j = (y(t) - y_m(t))w_j h_j \frac{\|X - C_j\|^2}{b_j^2} \quad (5)$$

$$b_j(t) = b_j(t-1) + \eta \Delta b_j + \alpha(b_j(t-1) - b_j(t-2)) \quad (6)$$

$$\Delta c_{ji} = (y(t) - y_m(t))w_j \frac{x_i - c_{ji}}{b_j} \quad (7)$$

$$c_{ji}(t) = c_{ji}(t-1) + \eta \Delta c_{ji} + \alpha(c_{ji}(t-1) - c_{ji}(t-2)) \quad (8)$$

上述几式中的学习速率用  $\eta$  来表示，动量因子由  $\alpha$  来表示。

### 1.3 高斯基函数对逼近效果的影响

由高斯基函数的表达式(2)可知，高斯基函数的有效性与中心矢量  $c_j$  和基宽参数  $b_j$  的取值有关。高斯基函数对逼近效果的影响主要表现为  $c_j$  和  $b_j$  对逼近效果的影响。高斯基函数形状的宽度由基宽参数  $b_j$  的取值决定， $b_j$  值越大，高斯基函数越宽，反之越窄。高斯基函数中心点的坐标由中心矢量  $c_j$  来表示。需要指出的是倘若高斯基函数越宽，则意味着网络输入的覆盖范围愈大，但与此同时网络的敏感性会变差；倘若高斯基函数的  $b_j$  值越小则说明函数越窄也就预示着网络输入覆盖范围愈小，同时网络的敏感性会变强。若网络输入值与  $c_j$  接近程度越高，就可以说明以  $c_j$  为中心点的高斯基函数对网络输入的敏感性就愈好。在仿真中，可依照 RBF 网络输入值的范围对中心矢量  $c_j$  和基宽参数  $b_j$  的值进行设定，目的是确保 RBF 网络输入值在映射高斯基函数的有效范围内。

## 2 机械手RBF网络自适应控制算法

$n$  关节机械手方程可以表示为：

$$D(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = \tau \quad (9)$$

其中， $D(q) \in R^{n \times n}$  表示机械手的正定惯性矩阵， $C(q, \dot{q})$  代表  $n \times n$  阶哥氏力与离心力， $G(q)$  指的是  $n \times 1$  维的重力项。在实际控制中， $D(q)$ 、 $C(q, \dot{q})$  和  $G(q)$  是不知道的，为容易实现控制，本文采用三个 RBF 网络分别对  $D(q)$ 、 $C(q, \dot{q})$  和  $G(q)$  三项进行建模，三个网

络的输出分别用来  $D_{SNN}(q)$ 、 $C_{DNN}(q, \dot{q})$  和  $G_{SNN}(q)$  表示。

$$D(q) = D_{SNN}(q) + E_D \quad (10)$$

$$C(q, \dot{q}) = C_{DNN}(q, \dot{q}) + E_C \quad (11)$$

$$G(q) = G_{SNN}(q) + E_G \quad (12)$$

其中， $E_D$ 、 $E_C$  和  $E_G$  分别是神经网络对  $D(q)$ 、 $C(q, \dot{q})$  和  $G(q)$  的建模误差，于是有：

$$D(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = D_{SNN}(q)\ddot{q} + C_{DNN}(q, \dot{q})\dot{q} + G(q) + E = [\{W_D\}^T \cdot \{\Theta_D(\ddot{q})\}]q_r + [\{W_C\}^T \cdot \{\Theta_C(z)\}]q_r + [\{W_G\}^T \cdot \{\Theta_G(q)\}] + E \quad (13)$$

式(13)中， $W_D$ 、 $W_C$  和  $W_G$  代表的是神经网络建模的权值， $\Theta_D$ 、 $\Theta_C$  和  $\Theta_G$  分别代表隐含层的输出， $E = E_D\ddot{q} + E_C\dot{q} + E_G$ 。

为了计算方便，我们规定：

$$e(t) = q_d(t) - q(t) \quad (14)$$

$$\dot{q}_r = \dot{r}(t) + \dot{q}(t) \quad (15)$$

$$\ddot{q}_r = \ddot{r}(t) + \ddot{q}(t) \quad (16)$$

上式中， $q_d(t)$  为理想位置指令， $q(t)$  为实际的位置。

设神经网络建模项  $D_{SNN}(q)$ 、 $C_{DNN}(q, \dot{q})$  和  $G_{SNN}(q)$  的估计为：

$$D_{SNN}(q) = [\{W_D\}^T \cdot \{\Theta_D(q)\}] \quad (17)$$

$$C_{DNN}(q, \dot{q}) = [\{W_C\}^T \cdot \{\Theta_C(z)\}] \quad (18)$$

$$G_{SNN}(q) = [\{W_G\}^T \cdot \{\Theta_G(q)\}] \quad (19)$$

上式中， $W_D$ 、 $W_C$  和  $W_G$  分别为  $W_D$ 、 $W_C$  和  $W_G$  的估计权值， $z = [q^T \dot{q}^T]^T$ 。

将(15)和(16)代入  $D(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = \tau$  中整理得：

$$\begin{aligned} \tau &= D(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) \\ &= D(q)\ddot{q}_r + C(q, \dot{q})\dot{q}_r + G(q) - D(q)\ddot{r} + C(q, \dot{q})\dot{r} \\ &= [\{W_D\}^T \cdot \{\Theta_D(q)\}]\ddot{q}_r + [\{W_C\}^T \cdot \{\Theta_C(z)\}]\dot{q}_r + [\{W_G\}^T \cdot \{\Theta_G(q)\}] - D(q)\ddot{r} + C(q, \dot{q})\dot{r} + E \end{aligned} \quad (20)$$

控制律设计为：

$$\begin{aligned} \tau &= \tau_m + K_p r + K_d \int r dt + \tau_m \\ &= D_{SNN}(q)\ddot{q}_r + C_{DNN}(q, \dot{q})\dot{q}_r + G_{SNN}(q) + K_p r + K_d \int r dt + \tau_r \\ &= [\{W_D\}^T \cdot \{\Theta_D(q)\}]\ddot{q}_r + [\{W_C\}^T \cdot \{\Theta_C(z)\}]\dot{q}_r + [\{W_G\}^T \cdot \{\Theta_G(q)\}] + K_p r + K_d \int r dt + \tau_r \quad (K_p > 0 + K_d > 0) \end{aligned} \quad (21)$$

式中，基于模型估计的控制律  $\tau_m$  和用于克服神经网络建模误差项  $\tau_r$  分别为：

$$\tau_m = D_{SNN}(q)\ddot{q}_r + C_{DNN}(q, \dot{q})\dot{q}_r + G_{SNN}(q) \quad (22)$$

$$\tau_r = K_r \operatorname{sgn}(r) \quad (23)$$

其中  $K_r = \text{diag}[k_{rit}]$ ,  $k_{rit} \geq [E_i]$ 。

由式 (20) 和 (21) 的右边整理可得：

$$D(q)\ddot{r} - C(q, \dot{q})r + K_p r + K_i \int r dt + \tau_r = [\{\bar{W}_D\}^T \cdot \{\Theta_D(q)\}] \ddot{q}_r + [\{\bar{W}_C\}^T \cdot \{\Theta_C(z)\}] \dot{q}_r + [\{\bar{W}_G\}^T \cdot \{\Theta_G(q)\}] + E \quad (24)$$

自适应律设计为：

$$\dot{\bar{W}}_{Dk} = \Gamma_{Dk} \cdot \{\zeta_{Dk}(q)\} \ddot{q}_r r_k \quad (25)$$

$$\dot{\bar{W}}_{Ck} = \Gamma_{Ck} \cdot \{\zeta_{Ck}(q)\} \dot{q}_r r_k \quad (26)$$

$$\dot{\bar{W}}_{Gk} = \Gamma_{Gk} \cdot \{\zeta_{Gk}(q)\} r_k \quad (27)$$

上述几式中的参数  $\Gamma_{Dk}$ ,  $\Gamma_{Ck}$  和  $\Gamma_{Gk}$  为神经网络权值调节矩阵。

### 3 仿真及结果分析

本文主要以 GRB400 机械手动力学模型为基础进行控制仿真，该机械手的动力学方程选为式  $D(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = \tau$ ，其中，

$$D(q) = \begin{bmatrix} m_1 \cdot r_1^2 + m_2 \cdot (l_1^2 + r_2^2 + 2l_1 \cdot r_2 \cdot c_2) + I_1 + I_2 & m_2 \cdot (r_2^2 + l_1 \cdot l_2 \cdot c_2) + I_2 \\ m_2 \cdot (r_2^2 + l_1 \cdot l_2 \cdot c_2) + I_2 & m_2 \cdot l_2^2 + I_2 \end{bmatrix}$$

$$C(q, \dot{q}) = \begin{bmatrix} (-m_2 \cdot l_1 \cdot r_2 \cdot s_2) \cdot \dot{q}_2 & (-m_2 \cdot l_1 \cdot r_2 \cdot s_2)(\dot{q}_1 + \dot{q}_2) \\ m_2 \cdot l_1 \cdot r_2 \cdot s_2 \cdot \dot{q}_1 & 0 \end{bmatrix}$$

$$G(q) = [0 \ 0]^T$$

同时，我们选取  $x_1 = \dot{q}$ ,  $x_2 = q$  则可将式  $D(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = \tau$  所示的动力学方程转化为：

$$\dot{x}_2 = D^{-1}(x_1)(\tau - C(x_1, x_2)x_2 - G(x_1)) \quad (28)$$

以 MATLAB 软件为平台进行仿真，采样时间使用 Runge-Kutta 迭代算法<sup>[8]</sup>对微分方程进行求解 (28)，可以实现连续被控对象的离散求解<sup>[9]</sup>。取采样时间为  $T_s$ ，将控制律式 (21) 和自适应律式 (25) 到 (27) 离散化，令  $q_0 = [0 \ 0]^T$ ,  $\dot{q}_0 = [0 \ 0]^T$ 。位置指令设为  $q_{d1} = 0.5 \sin(2k\pi \cdot t_s)$ ,  $q_{d2} = \sin(2k\pi \cdot t_s)$  取控制律参数为

$$K_p = \begin{bmatrix} 10 & 0 \\ 0 & 10 \end{bmatrix}, \quad K_i = \begin{bmatrix} 10 & 0 \\ 0 & 10 \end{bmatrix}, \quad \Lambda = \begin{bmatrix} 5 & 0 \\ 0 & 5 \end{bmatrix}, \quad K_r = 1.$$

自适应律中，神经网络权值调节矩阵  $D_k$ ,  $C_k$  和  $G_k$  中的元素值分别取 5 和 10。所建模网络隐层含节点数选取 5，用于逼近的  $D_{SNN}(q)$ 、 $C_{DNN}(q, \dot{q})$  和  $G_{SNN}(q)$  的参数分别取为 [-2 -1 0 1 2; -1 -0.5 0 0.5 1]; [-2 -1 0 1 2; -2 -0.5 0 1 2; -2 -1 0 1 2; -1 -0.5 0 0.5 1]; [-2 -1 0 1 2; -1 -0.5 0 0.5 1]。仿真结果曲线如图 2 和图 3 所示。

从图 2 和 3 可以看出，关节 1 在 0.5s 以前有跟踪误差过程，在 0.5s 以后就可以准确的跟踪给定曲线；关节 2 一开始就可以完全准确的跟踪给定曲线。说明了 RBF 神经网络自适应算法可以对机械手动力学模型中的不确定部分进行有效补偿，使给定曲线能被很好的跟踪，并能提高其轨迹跟踪精度。




图2 关节1和关节2的控制输入图




图3 关节1和关节2的位置跟踪图

### 4 结论

本文首先对 RBF 神经网络的控制特点及其作用高斯基函数进行了介绍；然后对影响逼近效果的高斯基函数的两个主要参数  $c_j$  和  $b_j$  进行了分析，采用了不同的  $c_j$  和  $b_j$  值在 MATLAB 软件中进行仿真，结果说明了  $c_j$  和  $b_j$  在不同程度上分别影响着网络输入的范围和敏感性；应用三个 RBF 网络对动力学模型中的  $D(q)$ 、 $C(q, \dot{q})$  和  $G(q)$  三项分别进行建模以及在此基础上设计了基于 RBF 神经网络自适应控制方法的控制律和自适应律；最后利用该算法对所建立的机械手模型进行仿真试验，仿真结果表明该算法能高精度的跟踪给定曲线。

# 河北邯郸HZSE240节能环保混凝土搅拌站设计

## HZS240 Energy Saving Concrete Mixing Plant of Manufacturing by Handan of Hebei Province

■辽宁海诺建设机械集团有限公司 李延飞/LI Yanfei 解俊/XIE Jun

**摘 要** 本文探讨了搅拌站现场的扬尘排放问题、污水排放问题、噪声污染问题等,在环保问题成为制约搅拌站(楼)发展的重要因素的情况下,提出了HZSE240节能环保混凝土搅拌站设计方案。

**关键词** 节能 环保 混凝土搅拌站 污水处理系统 钢构外封

DOI:10.13824/j.cnki.cmtm.2015.04.031

自我国开始禁止混凝土现场搅拌以来,混凝土搅拌站得到了空前的发展,但随之而来的混凝土生产现场环保问题也日趋明显,比如搅拌站现场的扬尘排放问题、污水排放问题、噪声污染问题等,环保问题成为制约搅拌站(楼)发展的重要因素。为更好的贯彻国家对环境的保护政策,加快预拌混凝土企业改造升级,推进绿色生产。在北京,上海,江苏,长沙,重庆,太原和石家庄等地区已经出台环保站地方标准。

### 1 主要技术参数

理论生产率 (m <sup>3</sup> /h)	240
工作循环周期 (s)	72
整机总功率 (kW)	340
进料容量 (L)	6000
出料容量 (L)	4000

骨料最大粒径(碎石/卵石)(mm)	80/100
斜皮带带速 (s/m)	2.5
平皮带带速 (s/m)	2

### 2 结构组成

HZSE240节能环保型混凝土搅拌站主要由骨料供给系统、粉料供给系统、水和液态外加剂供给系统、搅拌主机、电气控制系统及辅助系统等组成,该机整体布置如图1所示。

#### 2.1 节能

- 配料机的骨料直投在斜皮带尾部,使平皮带功率18.5 kW降低到15 kW。
- 水泥仓前置,把螺旋长度减小,同时406螺旋功率由30 kW降低到22 kW。
- 主楼采用高位水箱结构,把上水泵的功率由

#### 参考文献

- [1] 谢新民,丁锋.自适应控制系统[M].北京:清华大学出版社,2002,7.
- [2] Simon Haykin. Neural Network[M].北京:机械工业出版社,2004,256-443
- [3] Moody J, Darken C. Fast Learning in networks of locally-tuned processing units[J]. Neural Computation, 1989, 1(1): 281-294.
- [4] 魏海坤,徐嗣鑫,宋文忠.最小RBF网设计的进化优选算法及其在动力配煤过程状态预测建模中的应用[J].中国电机工程学报,2001,21(1):63-72.
- [5] 李士勇.模糊控制、神经控制和智能控制论[M].哈尔滨:哈尔滨工业大学出版社,1998.
- [6] 王顺晃,舒迪前.智能控制系统及其应用[M].北京:机械工业出版社,1995.
- [7] Mordecai Avriel (2003). Nonlinear Programming: Analysis and Methods. Dover Publishing. ISBN 0-486-43227-0.
- [8] 孙卫,樊晓光,李立.关于微分一代数系统的Runge-Kutta迭代方法的研究[J].工程数学学报,2005,06.
- [9] Ge S S, Lee T H, Harris C J. Adaptive Neural Network Control of Robotic Manipulators. World Scientific, London, 1998.

收稿日期:2015-01-12

通讯地址:陕西省西安市南二环中段长安大学本部(北院)(710064)

Cmtm