

文章编号: 1001-0920(2003)05-0550-05

## 基于神经网络的机器人运动模型辨识及其实验研究

姜春福, 余跃庆, 刘迎春

(北京工业大学 机械工程与应用电子技术学院, 北京 100022)

**摘要:** 针对机器人建模中不确定因素的影响, 采用神经网络辨识机器人输入输出间的非线性关系, 建立机器人的运动学模型。为了提高神经网络的辨识速度, 基于 E-man 动态递归网络, 通过增加网络输入输出的部分信息, 提出一种新的动态神经网络结构——状态延迟输入动态递归神经网络(SD DRNN), 提高了网络的学习速度和稳态精度。以 PowerCube™ 模块化机器人为研究对象, 把根据机器人返回的关节位置信息和利用 OPTO TRAK 3020 三维运动测量系统测得的机器人末端位置信息作为 SD DRNN 的学习样本, 对包含各种影响因素的机器人运动模型进行辨识, 得到了满意的结果, 说明了该神经网络的优越性。

**关键词:** 机器人; 神经网络; 辨识

**中图分类号:** TP24      **文献标识码:** A

## Theoretical and experimental study on kinematic model identification of robots based on neural networks

J I A N G Chun-fu, Y U Yue-qing, L I U Ying-chun

(College of Mechanical Engineering and Applied Electronics Technology,  
Beijing University of Technology, Beijing 100022, China)

**Abstract:** Neural network is used to identify kinematic model of robot systems with unpredictable disturbances. By using neural networks, the nonlinear mapping between inputs and outputs of a robot is obtained for kinematic modeling. In order to increase computational efficiency, a new neural network model named state delay input dynamical recurrent neural network (SD DRNN) is presented based on E-man network. The prior input-output knowledge to the hidden layer nodes, improves the learning rate. Then SD DRNN is applied to the kinematic model identification of PowerCube™ modular robot system. Data of joint position retrieved from the robot and those of end-manipulator position obtained by OPTO TRAK 3020 are used as learning sets for SD DRNN. Results are satisfactory and show the learning superiority of the new neural network.

**Key words:** Robot; Neural networks; Identification

### 1 引言

工业机器人是一个高非线性、强耦合的多输入多输出系统。由于其存在惯性负载和关节间耦合, 使得机器人机械构件尺寸和关节转轴方向等存在不可

避免的几何误差以及齿轮传递误差、齿轮间隙、基座的不稳定和连杆刚度等非几何因素的影响, 致使机器人在工作中的定位和运动轨迹可能与理论值存在较大出入, 影响到机器人的工作性能。为了提高机器

收稿日期: 2002-07-04; 修回日期: 2002-12-30。

基金项目: 国家自然科学基金资助项目(59975001); 北京市自然科学基金资助项目(3012003)。

作者简介: 姜春福(1974—), 男, 山东招远人, 博士生, 从事神经网络、机器人控制等研究; 余跃庆(1958—), 男, 北京人, 教授, 博士生导师, 从事机器人机构、机器人控制等研究。

人的运动及控制精度, 建立一个能正确反映机器人运动关系的模型, 目前的研究大体上从两方面进行: 一是柔性机器人研究, 基于关节柔性和连杆柔性, 建立机器人的运动学和动力学模型; 二是仍将机器人看作刚性系统, 采用误差补偿策略<sup>[1,2]</sup>, 将机器人的误差影响考虑到机器人的数学表达式中。但这种策略的困难在于<sup>[1]</sup>: 1) 难以考虑非几何因素的影响; 2) 待辨识参数随机器人关节数的增加而增加; 3) 修正方程过于复杂, 难以计算, 或计算耗时过多, 降低了实用意义。

神经网络由于其逼近任意非线性系统的能力、独特的容错性以及可方便地应用于多变量系统的能力, 逐渐成为非线性系统辨识与自适应控制的重要工具之一<sup>[3,4]</sup>。对于结构已知的机器人, 在任何时刻, 一组关节角度对应于机器人末端在笛卡尔坐标系中唯一的位置和方向, 二者之间映射关系的确定是控制过程中的重要环节。通常机器人运动学控制主要基于正、逆运动学的计算。这种计算不仅需要有效的算法, 而且需要经常进行校准才能保持精度。另外, 机器人本身的几何误差、传动误差以及其他不可预测的扰动等, 都会影响到控制过程中运动学的计算精度。当然, 估计机械关节之间的干扰和影响机器人运动的不可测扰动十分困难, 实际上也不可能实时得到这样的干扰和扰动的定量估计数据。然而整个机器人的运动学, 包括那些未知的干扰和扰动, 当机器人重复相同运动时却是可以再现的。因此, 期望运动可通过利用机器人运动的再现得到改进, 这便为利用神经网络辨识机器人的这些不可测扰动提供了可能。人们可以通过实验测得数据, 利用神经网络建立关节空间与笛卡尔空间之间的映射关系, 实现机器人的运动模型辨识; 然后利用这一模型对机器人实施控制。这样做的好处是可以避免直接求解机器人的正、逆运动学方程, 不必知道机器人的运动学参数, 故而成为确定机器人运动模型的颇具吸引力的一种方法。

BP 网络是机器人建模与辨识中应用最广泛的网络之一<sup>[5]</sup>。作为一种静态网络, BP 网络在对动态系统进行辨识时, 学习速度缓慢是其难以克服的缺点。相比之下, 动态神经网络提供了一种极具潜力的选择, 代表了神经网络建模、辨识与控制的发展方向<sup>[6]</sup>。本文基于动态 Elnan 网络, 提出一种新的动态递归神经网络结构, 称为状态延迟输入动态递归神经网络 (SD DRNN), 既保证了收敛速度提高的优点, 又使学习规则得到简化。本文将在实验数据的

基础上, 将该网络应用于模块化机器人运动模型辨识问题, 以获得机器人的非线性运动学模型。

## 2 状态延迟输入动态递归神经网络

SD DRNN 的拓扑结构如图 1 所示。图中: 输入输出状态向量作为单独一组输入, 称为状态结构单元。特殊地, 若网络只取 3 层结构, 则这一组输入在结构上与 Elnan 网络的输入层相同。考虑一般性, 这里不将其作为输入层单元, 而是作为结构单元的平行结构, 它与隐含层的连接权矩阵具有自己的含义, 称为前向滤波权矩阵<sup>[7]</sup>。这样, 可使各权值矩阵含义更为明确, 权值的训练过程更为简洁。状态结构单元的个数是网络输入输出神经元数目之和, 分别对应输入输出前一时刻状态的值。需要指出的是, 前面提到, 状态结构单元的输入是网络输入输出层神经元前一时刻的状态信息, 这一状态信息在输入到状态结构单元时, 为了获得满意的收敛速度, 可以对此信息作预处理, 即使每一单元输入值都乘以一个滤波因子  $\lambda$ 。  $\lambda$  作为经验值, 可以小于 1, 也可以不小于 1。  $\lambda < 1$  时, 降低前一步输入输出信息在网络中的作用; 反之, 增强输入状态结构单元对隐含层输出的影响。 Elnan 网络可以看作 SD DRNN 的特例, 若  $\lambda = 0$ , 图 1 即为 Elnan 网络的拓扑结构。

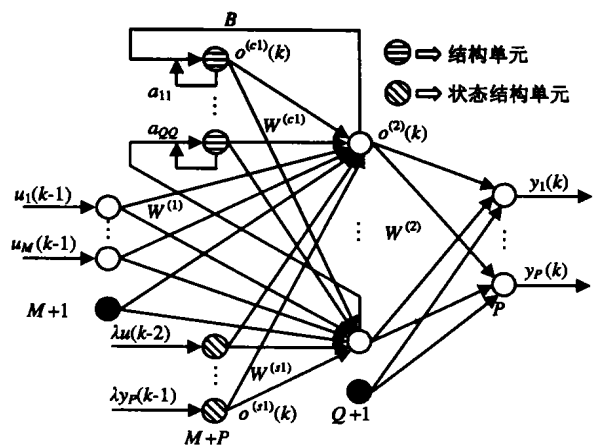


图 1 SD DRNN 的拓扑结构

SD DRNN 非线性映射关系的计算与改进的 Elnan 网络基本相同, 只是在隐含层各神经元的输入组成中, 加上状态结构单元经连接权矩阵  $W^{(s1)}$  传递后对应的各项值。因此, 与 Elnan 网络的不同之处是 SD DRNN 隐含层的净输入包含 3 部分, 分别是由输入层、结构单元、状态结构单元经各自的传递矩阵计算而来。这 3 部分之间没有耦合, 前向计算过程与相应连接权的调整都可以分别进行。

对网络进行训练时可采用标准的 BP 算法, 取

性能指标函数为

$$J = \frac{1}{2} \sum_{n=1}^V E_n = \frac{1}{2} \sum_{n=1}^V \sum_{l=1}^P [y_{dl}(k) - y_l(k)]^2 \quad (1)$$

式中:  $V$  为训练样本个数,  $P$  为输出层神经元个数,  $y_{dl}(k)$  和  $y_l(k)$  为  $k$  时刻输出层第  $l$  个神经元的期望输出值和实际输出值。

增加惯性项的 BP 算法可以写成通式, 即

$$\Delta w_{li}^{(n)}(k+1) = \eta \delta_l^{(n)}(k) \sigma(\text{net}_l^{(n)}(k)) o_i^{(n-1)}(k) + \alpha \Delta w_{li}^{(n)}(k) \quad (2)$$

式中:  $w_{li}^{(n)}(k+1)$  为连接  $n-1$  层第  $i$  个神经元与  $n$  层第  $l$  个神经元的权值,  $\delta_l^{(n)}(k)$  为  $n$  层第  $l$  个神经元的反向传播误差信号,  $\text{net}_l^{(n)}(k)$  为  $n$  层第  $l$  个神经元的净输入,  $o_i^{(n-1)}(k)$  为  $n-1$  层第  $i$  个神经元的输出,  $\sigma[\cdot]$  为神经元的输出变换函数,  $\eta \in (0, 1)$  为学习速率,  $\alpha \in [0, 1)$  为惯性系数。

式(2)中

$$\delta_l^{(n-1)}(k) = \sum_{j=1}^{N_n} \delta_j^{(n)}(k) \sigma(\text{net}_j^{(n)}(k)) w_{jl}^{(n)}(k) \quad n = 2, 3, \dots, N \quad (3)$$

对输出层, 有

$$\delta_l^{(N)}(k) = o_{dl}^{(N)}(k) - o_l^{(N)}(k) = y_{dl}(k) - y_l(k) \quad (4)$$

经过改进, 网络收敛速度及稳态精度与其他常用网络结构相比, 均有明显提高, 从而提高了系统的学习与控制性能。为了验证这种改进的有效性, 下面以一非线性系统为对象进行说明。

考虑如下参数慢时变非线性系统

$$y(k+1) = \frac{5(1 - 0.8e^{-0.1k})y(k)}{1 + y(k)^2} + u(k)$$

在区间  $[-0.5, 0.5]$  上随机产生 800 个数据样本作为训练样本集。训练准则定为输出的均方根误差。下面对 BP 网络, Elman 网络及 SD DRNN 作比较。训练过程中, 所需的相同参数都取相同值, 如输入层与隐含层之间的权值矩阵  $W^{(1)}$ , 隐含层与输出层之间的权值矩阵  $W^{(2)}$ , 自反馈系数矩阵  $A$  和反馈系数矩阵  $B$  等。其中:  $A = 0.6I, B = I, I$  为单位矩阵。3 种网络的训练均采用带惯性项的 BP 算法, 学习速率  $\eta = 0.15$ , 惯性系数  $\alpha = 0.3$ , 滤波因子  $\lambda = 1.5$ , 训练次数取 1 000 次。各网络经训练后, 得到的均方根误差变化曲线如图 2 所示。

由图 2 可以发现, BP 网络在整个训练过程中, 均方根误差变化很小, 与其他两种动态网络相比几乎不变, 暴露出 BP 网络学习速度缓慢的缺点; 而 SD DRNN 的学习速度和收敛精度明显高于 BP 网




图 2 均方根误差曲线

络和 Elman 网络, 在前 300 次的学习过程中, SD DRNN 收敛速度快特点尤为突出。

下面将 SD DRNN 应用到实际机器人运动模型的辨识中, 通过实际应用来验证该网络的有效性。

### 3 实验研究

#### 3.1 实验装置

实验采用德国 AMTEC 公司生产的 Power-Cube™ 模块化机器人, 其模块包括旋转模块、手腕模块、夹持模块和移动模块等。每个模块都包含一些相同的标准元件和专用元件。这些元件都集成在有限的模块空间内, 使整个机器人的结构非常紧凑。数据采集系统为 OPTOTRAK 3020 三维运动测量系统。该系统广泛应用于机器人学、运动控制、3D 数字化和逆向工程等方面的研究。

实验时, 首先根据设定任务, 给机器人施加期望的关节角位置信号, 同时接收机器人关节内部的增量式编码器所测得的关节实际位置信息, 写入数据文件备用。OPTOTRAK 3020 则根据机器人抓手上的两只红外线标识器(MARKER), 采集到标识器在空间的位置信息, 与机器人关节的输入位置信号共同作为神经网络辨识器的输入输出样本数据, 由神经网络进行学习, 最后输出所得到的机器人关节角输入和末端实际位置输出的非线性映射关系。

#### 3.2 实验结果及分析


实验设定机器人执行两项任务, 如表 1 所示。

表 1 任务设定


|      | 末端运动轨迹(直线)   | 末端连杆方向                              |
|------|--|-------------------------------------|
| 任务 1 | $x \quad [-0.0225, 0.4]$<br>$y \quad [0.65, 0.65]$ | $\alpha \quad [90^\circ, 90^\circ]$ |
| 任务 2 | $x \quad [-0.0225, 0.4]$<br>$y \quad [0.55, 0.55]$ | $\alpha \quad [45^\circ, 0^\circ]$  |

根据设定任务, 将模块化机器人设定成平面三杆机器人, 其工作空间为机器人位于复位状态时所在的铅垂面。每一任务的总执行时间为 4 s, 在采样

间隔分别取 0.01 s, 0.02 s 和 0.04 s 的情况下, 对机器人末端运动轨迹进行测量, 共测得 6 组数据。所得数据经预处理后, 由神经网络辨识器进行辨识。辨识时采用批处理, 对机器人末端轨迹  $X$  和  $Y$  分量采用独立辨识器。神经网络的各项参数为: 学习速率  $\eta=0.15$ , 惯性系数  $\alpha=0.3$ , 滤波因子  $\lambda=1.5$ , 训练次数根据运动轨迹  $X$  和  $Y$  方向的分量分别取为 200 次和 1500 次。辨识结果表明, 采用本文提出的




(a) X 方向辨识曲线




(b) X 方向辨识误差曲线

图 3 任务 1 X 方向辨识结果及辨识误差曲线




(a) Y 方向辨识曲线




(b) Y 方向辨识误差曲线

图 4 任务 1 Y 方向辨识结果及辨识误差曲线




(a) X 方向辨识结果




(b) X 方向辨识误差曲线

图 5 任务 2 X 方向辨识结果及辨识误差曲线



(a) Y 方向辨识曲线



(b) Y 方向辨识误差曲线

图 6 任务 2 Y 方向辨识结果及辨识误差曲线

SD DRNN 辨识器, 可以获得满意的辨识效果。为说明问题简便, 在此只以采样间隔为 0.04 s 的实验数据为例进行说明, 其他情况类似。

图 3~ 图 6 是在完成两种任务后, SD DRNN 辨识器对机器人末端运动轨迹  $X$  和  $Y$  方向分量的辨识曲线及相应的辨识误差曲线。各图 (a) 中: 曲线 1 为期望的末端轨迹; 曲线 2 为不考虑其他因素, 只根据机器人关节增量编码器传回的关节实际位置数据所得到的刚性机器人的末端运动轨迹; 曲线 3 和 4

分别为机器人末端的实际运动和SD DRNN 辨识器的辨识输出。首先以Y方向辨识曲线为例进行分析。

分析图4(a)和图6(a)可以发现,不考虑其他影响因素,即使将机器人各连杆看作是完全刚性的,曲线2与期望的理想轨迹1仍然存在误差。产生这一误差的原因,一是由于关节电机的响应误差,导致关节角并没有完全实现期望的关节角位置,从而产生输入期望关节角信号与关节实际关节角之间的误差;另一原因是确定机器人运动学参数,如测量连杆长时所产生的误差,但这种误差是静态误差,可采用多次测量取平均值的方法减小其影响,所以连杆测量误差与关节角误差相比是次要的,多次测量取平均值后,可以不考虑其对结果的影响。因此,曲线2与期望轨迹1之间的误差,主要反映了实际关节角与期望关节角之间的误差,这一现象说明关节电机并非是理想的刚性电机,在精度要求较高时,机器人模型的建立必须考虑关节柔性的影响。

分析图4(a)和图6(a)中的曲线3和曲线4可以发现,机器人末端实际运动轨迹与理想的期望轨迹可能有比较大的偏离。这种偏离产生的原因是多方面的。除机器人本身所具有的复杂性及关节柔性、连杆柔性等因素的影响外,还有能够公式化表示的因素,如机器人构件的几何误差、传递误差,以及难以用确定表达式表示的因素,如同步电机的磁场和空气的阻尼以及其他不可预测的扰动等,都可以导致机器人末端轨迹误差的发生。如果要在机器人运动解释表达式中考虑这些影响因素,就必须在机器人运动方程中以参数的形式表示出来,但不可避免的困难是影响因素中包括难以公式化表示的因素;同时,前面曾提到过,将误差影响通过参数补偿到机器人运动方程中时,参数个数要随机器人关节数的增加而增加,从而导致计算过程复杂,计算时间延长,削弱了这种策略的实用意义。另外,包括考虑机器人关节柔性和连杆柔性时的柔性机器人研究中,所采用的弹性关节和柔性连杆的数学模型,为了处理问题方便,都要对方程进行合理的简化,舍去大部分次要因素,从而不可避免地引发建模误差。而采用神经网络,可以不考虑这些细节问题,直接利用神经网络对非线性关系逼近的能力来对实际系统模块进行辨识,理论上可以达到所需的任意精度。从两图中可以发现,经过学习,神经网络的辨识输出更接近于机器人末端的实际运动轨迹,可以达到满意的要求。

图4(b)和图6(b)表示神经网络辨识输出与机器人实际运动轨迹的误差曲线。图4(b)中二者之间

的误差保持在0.9 mm以内,而图6(b)的最大误差小于0.8 mm。在完成设定任务的整个过程中,除少数几点外,两图中大部分辨识误差可保持小于0.4 mm,辨识结果具有相当的精度。值得一提的是,该神经网络辨识器只经过200次训练即可,与BP动辄就需几千次、几万次训练次数相比具有相当高的学习效率<sup>[5]</sup>。如果有更高的精度要求,可以适当调整神经网络的各项学习参数,增加其训练次数,这一误差值还可进一步减小。

由表1可知,机器人末端在X方向上的运动距离较长,为0.4 m,所以运动误差及辨识误差直观上不如Y方向明显。图3(a)和图5(a)中分别取部分放大,可以发现上述规律对X方向辨识结果也是适用的。观察图3(b)和图5(b),在整个运动过程中,神经网络在X方向上的辨识误差除少数几点外,大部分误差位于 $\pm 4$  mm的范围内,最大误差处也不过在6~8 mm,这相对于0.4 m的行程而言是可以接受的。同理,如果对精度有更高的要求,同样可以通过调整SD DRNN的各项参数及学习次数而达到期望的辨识精度,从而实现对机器人由关节空间到笛卡尔空间非线性映射关系的模型辨识。

为进一步说明问题,将SD DRNN与Elman网络进行比较。以任务1为例,在对X和Y方向进行模型辨识时,在SD DRNN和Elman网络所需的所有初始矩阵、学习参数及训练次数取值相同的情况下,最后得到的辨识均方根误差为:辨识X方向输入输出模型时,Elman网络的结果为 $4.42 \times 10^{-3}$ ,SD DRNN结果为 $4.26 \times 10^{-3}$ ;辨识Y方向输入输出模型时,Elman网络的结果为0.063 4,SD DRNN结果为0.057 55,均表明SD DRNN的学习能力优于改进前的Elman网络。

#### 4 结 语

本文基于Elman网络,提出一种新的动态神经网络结构SD DRNN。首先通过数值仿真,将其与静态BP网络和Elman网络进行比较,结果说明了本文SD DRNN在学习速度和收敛精度方面的优越性。同时,将其应用于实际机器人运动模型的辨识问题,把利用PowerCube™模块化机器人和OPTO-TRAK 3020三维运动测量系统获得的实验数据,作为神经网络辨识器的学习样本,对从关节空间到笛卡尔空间非线性映射关系进行辨识,得到了满意的输入输出映射模型,为实现基于神经网络的机器人补偿控制奠定了基础。

(下转第572页)

基于贝叶斯网络的故障诊断策略优化方法在加快设备故障诊断速度、降低故障诊断费用方面具有明显的优势。基于该方法的故障诊断与维修决策系统已经在空军某修理厂运行1年。应用结果表明,该系统在机载设备的维修中,有效提高了维修效率,缩短了维修周期。相信这种方法可以在故障诊断领域中得到更为广泛的应用。

#### 参考文献(References):

- [1] 刘刚, 杨世风, 马跃进, 等. 设备故障诊断步骤优化的研究[J]. 农业工程学报, 1997, 13(12): 125-129.
- [2] Stephenson T A. An introduction to Bayesian network theory and usage[R]. Switzerland: D I A P-RR 00-03, Dale M olle Institute, 2000.
- [3] Lepar V, Shenoy P P. A comparison of lauritzen and spiegelhalter, hugin and shafer and shenoy architectures for computing marginals of probability distributions[A]. *The Proc of the 14th Conf on Uncertainty in Artificial Intelligence* [C]. San Francisco: Morgan Kaufmann Publishers, 1998 328-337.
- [4] Bresnick T A, Buede D M, Tam an J A. Introduction to Bayesian networks[A]. *The 66th MORS Symposium* [C]. California: Naval Postgraduate School Monterey, 1998 23-25.
- [5] Breese J S, Heckeman D. Decision-theoretic troubleshooting: A framework for repair and experiment[A]. *Proc 12th Conf on Uncertainty in Artificial Intelligence* [C]. San Francisco: Morgan Kaufmann Publishers, 1996 124-132.
- [6] Heckeman D, Breese J, Rommelse K. Decision-theoretic troubleshooting[J]. *Communications of the ACM*, 1995, 38(3): 49-57.
- [7] Coper G F. The computational complexity of probabilistic inference using Bayesian belief networks[J]. *Artificial Intelligence*, 1990, 42(2-3): 393-405.
- [8] Poole D. A average-case analysis of a search algorithm for estimating prior and posterior probabilities in Bayesian networks with extreme probabilities [A]. *Proc 13th Int J Conf on Artificial Intelligence* [C]. France, 1993 606-612.
- [9] Skaanning C, Jensen F V, Kjaerulff U. Printer troubleshooting using Bayesian networks[A]. *Industrial and Engineering Applications of Artificial Intelligence and Expert Systems (IEA /A IE) 2000* [C]. New Orleans, 2000 101-108.

(上接第 554 页)

#### 参考文献(References):

- [1] 夏凯, 陈崇端, 洪涛, 等. 补偿机器人定位误差的神经网络[J]. 机器人, 1995, 17(3): 171-176.  
(Xia K, Chen C D, Hong T, et al. Neural networks for compensation of robot positioning errors[J]. *Robot*, 1995, 17(3): 171-176.)
- [2] Veitschegger W K, Wu Chihaur. Method for calibration and compensating robot kinematic errors [A]. *IEEE Proc of Int Conf on Robotics and Automation* [C]. New York: IEEE, 1987. 39-44.
- [3] Narendra K S, Parthasarathy K. Identification and control for dynamic systems using neural networks [J]. *IEEE Trans on Neural Networks*, 1990, 1(1): 4-27.
- [4] 陈默子. 人工神经网络在机械手动力学辨识和位置控制中的应用[J]. 机器人, 1993, 15(5): 33-38.  
(Chen M Z. Application of neural networks in kinetic identification and position control of manipulators [J]. *Robot*, 1993, 15(5): 33-38.)
- [5] Wu Chiaju, Huang Chinghuo. Back-propagation neural networks for identification and control of a direct drive robot[J]. *J of Intelligent and Robotic Systems: Theory & Applications*, 1996, 16(1): 45-64.
- [6] 孙增圻, 张再兴, 邓志东. 智能控制理论与技术[M]. 北京: 清华大学出版社, 1997.
- [7] 何玉彬, 李新忠. 神经网络控制技术及其应用[M]. 北京: 科学出版社, 2000.