

冗余度机器人运动模型的神经网络辨识及实现

姜春福¹, 余跃庆², 刘迎春²

(1. 北京信息高技术研究所 北京 100085; 2. 北京工业大学 机电学院, 北京 100022)

摘要: 为提高网络学习速度, 提出了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. 以德国 PowerCube™ 模块化机器人为研究对象, 将机器人系统返回的关节位置信息和 OPTOTRAK 3020 3 维运动测量系统测得的机器人末端位置信息作为神经网络的学习样本, 对包含各种影响因素的机器人运动模型进行了辨识, 所得结果及误差分析, 说明了 SDIDRNN 在学习能力上的优越性.

关键词: 冗余机器人; 神经网络; 辨识

中图分类号: TP24 **文献标识码:** A

Kinematic model identification and implementation of redundant robot based on neural networks

JIANG Chun-fu¹, YU Yue-qing², LIU Ying-chun²

(1. Beijing Institute of Advanced Information Technology, Beijing 100085, China;

2. College of Mechanics and Applied Electronics, Beijing University of Technology, Beijing 100022, China)

Abstract: In order to increase the computational efficiency of neural networks, a new network model named state delay input dynamical recurrent neural network is presented in this study. This new neural network is also applied to the model identification of PowerCube™ modular robot system. The data of joint positions retrieved from the robot and the position of the end-effector measured by the OPTOTRAK 3020 are used as learning sets for neural network. The learning superiority of the new neural network is illustrated.

Key words: redundant robot; neural networks; identification

1 引言(Introduction)

冗余度机器人在工业生产和航天航空领域都有着独特而重要的作用. 更多的自由度可以改善机器人的运动特性, 如提高灵活性、改善动力学性能、增大工作空间等. 工业机器人是一个高非线性、强耦合的多输入多输出系统, 存在许多未知因素, 同时机器人本身的复杂性, 如惯性负载、关节间耦合、重力效应与机器人位姿位置相关等, 使自由度较多的冗余机器人在工作过程中的定位及运动轨迹可能与理论值有较大的出入. 为了提高机器人的工作性能, 建立一个能正确反映机器人运动关系的模型是机器人研究中首要任务. 在这一问题上, 很多学者一般都采用误差补偿策略^[1], 对运动学方程作适当的修正, 将机

器人的误差影响考虑到机器人的数学表达式中. 但这种策略的困难之处在于: 一是难以考虑非几何因素的影响, 二是待辨识参数随机器人关节数的增加而增加, 三是修正方程过于复杂, 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、分布式信息存储与处理结构所具有的独特的容错性以及可方便地应用于多变量系统的能力, 使其在现代控制中引起越来越多学者的关注, 逐渐成为非线性系统辨识与解决冗余机器人运动学问题的有力工具^[2,3]. 尽管估计机械关节之间的干扰及影响机器人运动的不可测扰动十分困难, 实时得到这样的干扰和扰动的定量估计实际上不可能, 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,期望运动可利用机器人运动的再现得到改进,这也为采用神经网络辨识机器人这些不可测扰动提供了可能.本文可以通过实验测得数据,利用神经网络建立起关节空间和笛卡尔空间之间的映射关系,实现机器人的模型辨识.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.相比于静态网络、动态神经网络在系统辨识问题上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^[4].本文在动态递归 Elman 网络的基础上,采用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,在实验数据的基础上,将该网络应用到德国 PowerCube™ 模块化平面冗余机器人运动模型辨识的问题中,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 (State delay input dynamical recurrent neural network)

状态延迟输入动态递归神经网络 (简称 SDIDRNN) 拓扑结构如图 1 所示. SDIDRNN 将输入输出状态向量作为单独一组输入,称其为状态结构单元 (state context). 若网络只取 3 层结构,则这一组输入在结构上与 Elman 网络的输入层相同,但为一般性,并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有自己的含义,称为前向滤波权矩阵^[5]. 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. 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,可作预处理以获得满意的收敛速度,即每一单元输入值都乘以一个滤波因子 λ . λ 作为经验值,其取值范围与网络的学习速率 η 和惯性系数 α 有所不同,根据任务的具体情况, λ 可以小于 1,也可以不小于 1. λ 小于 1 时,削弱前一步输入输出信息在网络中的作用,反之, λ 大于 1 时,增强状态结构单元输入对隐含层输出的影响. Elman 网络可以看作 SDIDRNN 的特例,如果 $\lambda = 0$,图 1 所示即 Elman 网络的拓扑结构. 算法过程参阅文献^[6]. 经过改进,网络的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,下面以一非线性系统为对象说明.

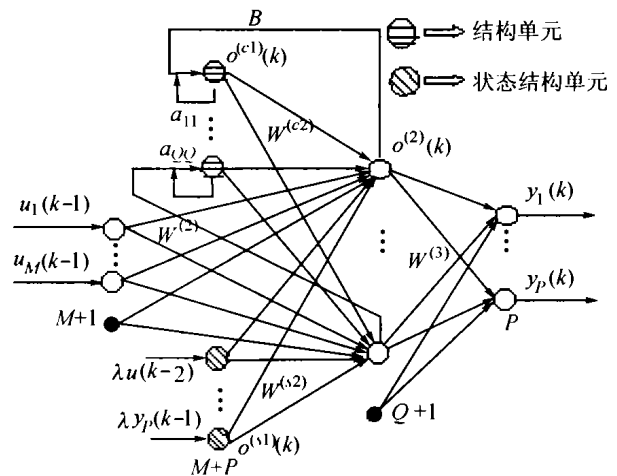


图 1 状态延迟输入动态递归神经网络的拓扑结构
Fig. 1 Topology of state delay input dynamical recurrent neural network

考虑参数慢时变非线性系统

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

以其在区间 $[-0.5, 0.5]$ 上随机产生 800 个数据样本作为训练样本集;训练准则为输出的均方根 (r. m. s) 误差,本文对 BP 网络、改进的 Elman 网络以及 SDIDRNN 作一比较. 在 3 种网络训练过程中,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 $W^{(2)}$, 隐含层与输出层之间的权值矩阵 $W^{(3)}$, 自反馈系数矩阵 A , 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 1000 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. 可以发现, BP 网络在 1000 次的训练过程中,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 SDIDRNN 的学习速度和收敛精度明显高于静态 BP 网络和 Elman 动态递归网络. 其中在前 300 次的学习过程中, SDIDRNN 收敛速度快特点尤为突出.

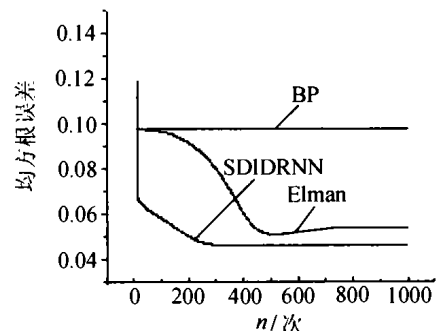


图 2 均方根误差曲线
Fig. 2 Comparison curves of r. m. s. error

3 实验设备(Experiment setup)

实验装置如图3(a)和图3(b)所示.其中,图3(a)为德国AMTEC公司生产的PowerCube™模块化机器人.它具有制造精度高、运行平稳、噪声低等优点.每个模块内部都设有增量编码器,对关节位置和速度进行实时监控和测量,可根据实验需要提取所需数据实时处理,也可存成数据文件备用.图3(b)为OPTOTRAK 3020的3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、逆向工程等方面的研究.它包含一个由3个CCD组成的位置传感器(图中镜头部分)、一套控制系统及若干红外MARKER.该系统具有自动定标、实时测量物体的3维运动参数、数据分析处理以及反馈控制等功能.




图3(a) PowerCube™模块化机器人
Fig. 3(a) PowerCube™ modular robot




图3(b) 3维动态测试系统
Fig. 3(b) 3D motion measurement system

4 实验结果及分析(Experimental results and analysis)

实验设定机器人末端执行从点(0,0.717)到点(0,0.4),点(-0.1,0.6)到点(0.2,0.6)的两项直线型任务.将机器人设定成平面3杆机器人,不考虑末端连杆的方向,机器人具有一个冗余自由度.每一任务的总执行时间为4s,在采样间隔分别取0.005s,0.01s,0.02s,0.04s的情况下对机器人末端运动轨

迹进行测量,共测得16组数据.辨识时采用批处理方式,对机器人末端轨迹 X, Y 分量采用独立的辨识器.神经网络各项参数为:学习速率 $\eta = 0.02$,惯性系数 $\alpha = 0.2$,滤波因子 $\lambda = 1.5$,训练次数根据辨识分量不同而分别取为1500次和5000次.在此以采样间隔为0.02s时的实验数据为例,对结果进行分析.

图4~图7是SDIDRNN辨识器对机器人末端运动轨迹 X, 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是采用最小范数法求得机器人关节位置后,在假设机器人为完全刚性的情况下再直接反算所得到的机器人末端轨迹;曲线3为根据返回的机器人实际关节角求得的刚性机器人的末端运动轨迹;曲线4,5为机器人的实际末端轨迹和SDIDRNN辨识器的辨识输出.

分析各图(a)中的曲线1与曲线2.从理论上说,曲线2与曲线1应该是重合的,因为二者只是数学上的变换关系,还没有经过机器人环节,因此不可能有机器人系统中各种因素的影响.但实际上两条曲线并没有重合,这种误差,只能产生在由笛卡尔空间向关节空间的求解过程中.当然,可能导致误差的另一原因是机器人连杆长度的测量误差,但这种测量误差可以通过多次测量取平均值的方法来减小其影响,产生的误差属于静态误差.所以,曲线2出现误差的主要原因在于求最小范数解及求曲线2时 \dot{q}_0 的积分过程.可以观察到曲线2随着时间的变化而呈线性增大趋势,这是由于算法误差,导致所求的输入到机器人中的关节位置并非理想的关节角,这一误差是累积的,导致曲线2与曲线1间的线性增大误差.针对这一问题,本文也做过平面非冗余三杆机器人的相关实验进行比较,结果表明,在非冗余机器人实验中,由于没有求最小范数解和积分过程,曲线2与曲线1是能够重合的,其中理想轨迹由于计算精度的影响,其变化范围的数量级为 10^{-7} m,远远小于本实验 10^{-3} m的算法误差.因此,曲线2与曲线1间的误差说明了影响冗余机器人末端运动精度的原因之一是算法误差.

再来分析曲线3.曲线3也是将机器人看作完全刚性的机器人所得到的末端轨迹.不同的是,此时的关节角为每一时刻由增量编码器返回的机器人关节角的实际值.由于关节电机的实际输出角不能理想地实现关节期望值,故它与输入值间的误差反映了关节电机对输入信号的响应能力.观察图4、图7

中的(a)图,可以发现曲线3的变化趋势与曲线2基本相同,也说明前述算法误差对机器人运动精度的影响.如果关节电机完全刚性,能够完全实现每一时刻的关节角信号,那么曲线3与曲线2应该是重合的.因此,曲线3与曲线2间的误差说明,影响机器人末端运动精度的原因之二是关节电机的电机特性,即柔性机器人中考虑的关节柔性问题.

曲线4、曲线5分别为机器人末端的实际运动轨迹及神经网络辨识器的辨识结果.可以发现,随着机器人的运动,机器人末端实际运动轨迹与理想的期望轨迹有比较大的偏离.各图(a)中的机器人实际运动曲线(曲线4)说明了这一现象.这种偏离产生的原因是多方面的.除了机器人本身运动学、动力学所包含的复杂性及连杆刚性等因素的影响外,还有其他因素的影响,这其中既有能够公式化表示的因素,如机器人构件的几何误差、摩擦、外部干扰等;也有难以用确定表达式表示的因素,如伺服电机的磁场、空气阻尼、齿轮间隙、基座稳定性以及其他不可预测的扰动等等,都可能导致机器人末端轨迹误差的发生.前面曾提到过,如果按传统的误差补偿思想,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如何表达影响因素中难以公式化表示的部分;同时,将误差影响通过参数补偿到机器人运动方程中,参数个数要随着机器人关节数的增加而增加,导致计算过程复杂,计算耗时延长,对于自由度较多的冗余机器人来说更是如此.因此在实用中,这种策略的实现存在着本质上的局限性.另外,在考虑包括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,为了处理问题的方便,都要对方程进行合理的线性化,不可避免地引起建模误差.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.由图4~图7可以发现,经过学习,神经网络的辨识输出(曲线5)更接近于机器人末端的实际运动轨迹.

图4(b)~图7(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.可以发现,在完成设定任务的整个过程中,除了少数几点外,大部分样本点的辨识误差可保持小于2 mm,相对于行程来说,该辨识结果具有相当的精度.值得一提的是,这里神

经网络辨识器只经过1500次或5000次训练,与采用BP网络动辄就需上万次、甚至十几万次的训练次数相比具有相当高的学习效率^[3].如果有更高的精度要求,可以通过调整SDIDRNN的各项学习参数,增加其训练次数,使这一误差值进一步减小,从而实现机器人运动模型的建立.另外需要解释的是,虽然直观上看来,图4(b)~图7(b)的误差曲线没有明显的收敛,图7(b)甚至有发散的趋势,但这并不说明辨识网络和辨识策略的失效.出现这一结果的原因之一,是在训练过程中,所有训练样本以批处理方式输入网络,权值的每一次调整过程都是针对所有训练样本进行的,其评价函数,即网络输出与期望输出的均方根误差是关于整个训练样本的性能指标,因此,在保证整体均方根误差下降的情况下,不排除个体样本误差存在类似的现象.原因之二,由于机器人实际运动过程中,机器人关节间存在耦合,每一模块的重力效应与位置相关,关节电机在运行过程中的负载变化很大,使机器人成为一个时变系统.又由于关节电机不是理想的刚性电机,对输入关节位置信号的响应存在滞后,不能及时响应输入信号,机器人末端要发生振动,导致运动轨迹产生“锯齿”,而神经网络输出的逼近曲线是对整体数据样本的拟合,相对来说较平滑,如果机器人运动中某一时段振幅较大,则二者之差会在这些点处出现增大现象,如图4(b)中的初始阶段和图7(b)中的结束阶段.观察各图(b)曲线,可以发现误差曲线的变化并无明显的规律可循,因此,对误差的分析也无法用传统观点进行分析.在建立机器人运动模型时,作者只需关心辨识结果的全局特性,如果全程辨识误差在设定精度以内,就可以停止学习,导出神经网络的各项参数和权值矩阵,以此构成机器人运动的神经网络模型,为对机器人实施控制作准备.

在介绍SDIDRNN时,本文曾对其与Elman网络的学习性能作了比较.为进一步说明问题,在机器人运动模型辨识时,本文也分别采用了两种结构的神经网络辨识器.对X、Y方向进行模型辨识时,SDIDRNN和Elman网络所需的初始矩阵、学习参数及训练次数等共用参数取值都相同,以任务2为例,最后得到的X、Y方向辨识均方根误差为:Elman网络分别为 0.628×10^{-2} m, 6.151×10^{-2} m; SDIDRNN分别为 0.332×10^{-2} m, 6.145×10^{-2} m,均表明SDIDRNN的学习能力要优于Elman网络.




图 4(a) X 方向位移比较曲线(任务 1)
Fig. 4(a) Comparison curves of the displacement in the X-axis direction (task 1)




图 4(b) X 方向位移辨识误差(任务 1)
Fig. 4(b) Identification error curve of the displacement in the X-axis direction (task 1)




图 5(a) Y 方向位移比较曲线(任务 1)
Fig. 5(a) Comparison curves of the displacement in the Y-axis direction (task 1)




图 5(b) Y 方向位移辨识误差(任务 1)
Fig. 5(b) Identification error curve of the displacement in the Y-axis direction (task 1)




图 6(a) X 方向位移比较曲线(任务 2)
Fig. 6(a) Comparison curves of the displacement in the X-axis direction (task 2)




图 6(b) X 方向位移辨识误差(任务 2)
Fig. 6(b) Identification error curve of the displacement in the X-axis direction (task 2)




图 7(a) Y 方向位移比较曲线(任务 2)
Fig. 7(a) Comparison curves of the displacement in the Y-axis direction (task 2)




图 7(b) Y 方向位移辨识误差(任务 2)
Fig. 7(b) Identification error curve of the displacement in the Y-axis direction (task 2)

5 结论(Conclusion)

文中对神经网络的拓扑结构作了研究,提出了一种新的动态神经网络结构 SDIDRNN,提高了神经网络的学习速度.利用 PowerCube™ 模块化机器人及 OPTOTRAK 3020 获得实验数据作为神经网络辨识器的学习样本,针对冗余机器人建模时有许多不确定性因素影响的问题,利用 SDIDRNN 对机器人的输入输出关系进行辨识,建立起了机器人的运动学模型,得到了满意的结果.对辨识结果及误差的分析说明了该神经网络的有效性.

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 Kai, CHEN Chongduan, HONG Tao, et al. Neural networks for position error compensation of robot [J]. *Robot*, 1995, 17(3): 171-176.)
- [2] NARENDRA K S. Identification and control for dynamic systems using neural networks [J]. *IEEE Trans on Neural Networks*, 1990, 1(1):4-27.
- [3] WU Chiaju, HUANG Chinghuo. Back-propagation neural networks for

identification and control of a direct drive robot [J]. *J of Intelligent and Robotic Systems*, 1996, 16(1):45-64.

- [4] 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.
(SUN Zengqi, ZHANG Zaixing, DENG Zhidong. *Theory and Technology of Intelligent Control* [M]. Beijing: Tsinghua University Press, 1997.)
- [5] 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.
(HE Yubin, LI Xinzong. *Technology and Application of Neural Network Control* [M]. Beijing: Science Press, 2000.)
- [6] 姜春福,余跃庆.状态延迟输入神经网络及其在机器人定位监督控制中的应用[J].机械科学与技术,2003,22(2):229-232.
(JIANG Chunfu, YU Yueqing. SDIDRNN and its application to the position supervisory control of robots [J]. *Mechanical Science and Technology*, 2003, 22(2): 229-232.)

作者简介:

姜春福 (1974—),男,博士,已发表论文10余篇,研究领域为神经网络在机器人中的应用, E-mail: jiangchf@sohu.com;

余跃庆 (1958—),男,教授,博士生导师,研究领域为机器人机械学,双臂机器人协调操作;

刘迎春 (1975—),女,博士研究生,已发表论文10余篇,研究领域为双臂柔性机器人协调操作.