

doi: 10.11918/j.issn.0367-6234.2015.07.003

GA 优化的 RBF 神经网络外骨骼灵敏度放大控制

龙 亿, 杜志江, 王伟东

(机器人技术与系统国家重点实验室(哈尔滨工业大学), 150001 哈尔滨)

摘要: 为改善外骨骼机器人灵敏度放大控制(SAC)性能,结合遗传算法(GA)与径向基函数(RBF)神经网络建立在线计算外骨骼机器人的精确动力学模型.用GA优化RBF神经网络的中心矢量与基宽度,并对RBF网络的权值实时更新,在线学习外骨骼机器人动力学模型中的参数矩阵,进一步推导出SAC控制律.仿真结果表明:GA优化后的RBF网络,可以在线学习外骨骼的动力学模型,基于该模型的SAC能够实现精确的人体轨迹跟踪,相比于优化前,人体轨迹跟踪误差以及人机交互信息会快速减小并收敛到0的微小邻域内,可实现人机协调运动.

关键词: 遗传算法;RBF神经网络;灵敏度放大控制;外骨骼机器人;轨迹跟踪

中图分类号: TH133; TP183

文献标志码: A

文章编号: 0367-6234(2015)07-0026-05

RBF neural network with genetic algorithm optimization based sensitivity amplification control for exoskeleton

LONG Yi, DU Zhijiang, WANG Weidong

(State Key Laboratory of Robotics and System(Harbin Institute of Technology), 150001 Harbin, China)

Abstract: To improve performance of sensitivity amplification control(SAC) for exoskeleton robot, genetic algorithm(GA) and RBF neural network was combined to obtain accurate dynamic model of exoskeleton robot online. Parameters of center vector and base width of RBF neural network were obtained by GA optimization, and online RBF weights learning process was constructed to obtain estimation matrix parameters of dynamics system, finally, SAC control law was deduced. Simulation results showed that the RBF network optimized by GA could learn exoskeleton dynamics model parameters online. Based on the learned model, the SAC could achieve more precise human trajectory tracking where tracking error and human-robot interaction force converged to the small neighborhood of zero simultaneously compared with those without optimization. The proposed RBF neural network with GA optimization which learned dynamics model parameters online for exoskeleton robot dynamics model could achieve highly accurate trajectory following for SAC, ultimately realize cooperative movement between human and exoskeleton.

Keywords: genetic algorithm; RBF neural network; sensitivity amplification control; exoskeleton robot; trajectory tracking

穿戴式外骨骼机器人,与人体高度贴合,可增强人体的力量与耐力,缓解人体疲劳.BLEEX 下肢外骨骼机器人是由美国加利福尼亚 Berkeley 分校研制的,于2004年进行了样机试验.BLEEX 采用液压驱动系统,所有传感器安装在外骨骼机器人上,

包括力/力矩传感器、位置码盘等,所提出的控制方法称为灵敏度放大控制(sensitivity amplification control, SAC)^[1-2].在SAC中,灵敏度被定义为外骨骼的输出运动信息与人机交互信息之间的关系,所以如果控制灵敏度在合适范围内,就可以减小人机交互作用,使外骨骼实现高度跟随人体运动轨迹.SAC方法是基于模型的控制,其控制效果取决于系统动态模型的精确程度,而外骨骼机器人是多自由度的非线性系统,要建立其精确的数学模型非常困

收稿日期: 2014-07-11.

基金项目: 国家自然科学基金(61105088).

作者简介: 龙 亿(1988—),男,博士研究生;

杜志江(1972—),男,教授,博士生导师.

通信作者: 王伟东, weidongwang@hit.edu.cn.

难^[3]. 神经网络在机器人系统的动力学辨识方面得到了广泛的应用^[4-5]. 如下肢外骨骼的动力学精确模型的建立, 一是离线的 BP 网络训练; 二是系统的模式识别. 运用 BP 网络来学习外骨骼的逆模型, 网络的输入层为外骨骼关节的运动参数(角度、角速度、角加速度), 输出为力矩, 采用正模型来获取实验数据, 离线学习得到 BP 网络^[6]. 然而, BP 网络每一次学习都需要重新调整权值, 收敛速度慢, 离线学习得到的 BP 网络的泛化能力难以得到保证. 基于外骨骼单腿的三连杆模型, 使用最小二乘法, 运用实验手段对外骨骼模型中的参数(如刚度力矩、摩擦力等)进行了辨识^[7], 但是全部过程需要大量的实验数据, 耗时长.

针对外骨骼机器人系统有效地在线学习方法报道很少, 本文设计了一种基于遗传算子(GA)优化的径向基函数(RBF)网络在线学习方法, 获取外骨骼机器人的动力学模型, 并将模型用于 SAC 中.

1 灵敏度放大控制原理

1.1 灵敏度放大控制的定义

灵敏度放大控制(SAC)是美国 Berkley 外骨骼系统(BLEEX)采用的控制方法, 其控制原理如图 1. 其中, G_{hm} 是人机交互模型, G_{exo} 是外骨骼的动力学模型, T_d 是外部干扰力矩, 包括人施加的人机作用力以及环境的干扰力, T_a 是外骨骼驱动器施加的力矩, $q = [q, \dot{q}, \ddot{q}]$ 为外骨骼的输出轨迹参数.

由图 1 可得

$$q = T_d G_{hm} + T_a G_{exo}.$$

定义系统的灵敏度为

$$S = q/T_d.$$

S 表示外骨骼的输出轨迹对外在力的感应程度, S 越大, 表示 T_d 对 q 的影响越大.

考虑人机交互力矩以及机构的阻尼、摩擦等, 将图 1 改写为闭环的形式, 如图 2 所示, 其中, T_{hm} 是人机交互力矩, T_a 是驱动器施加的力矩, α 是放大系数, G'_{exo} 是外骨骼的逆动力学模型, q_{hm} 人体运动轨迹, 即是外骨骼的目标运动轨迹. 一般地, $T_a = (1 - \alpha^{-1})G'_{exo}$, 那么可以推导出新的灵敏度为

$$S_{new} = \alpha S, \alpha > 1.$$




图 1 SAC 原理

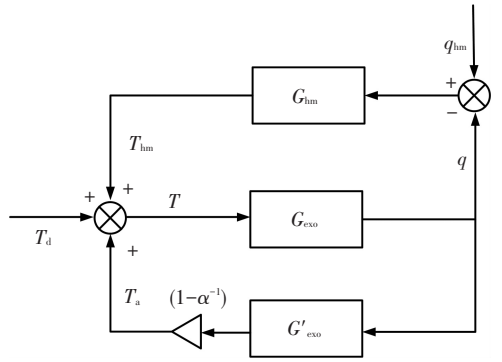


图 2 SAC 闭环控制

1.2 SAC 控制律

外骨骼实体机构如图 3 所示, 每一条腿有两个主动自由度, 踝关节不加驱动, 驱动部分由液压缸完成. 不失一般性, 外骨骼机器人的动力学方程可以表示为

$$M(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) + D = T. \quad (1)$$

其中: $M(q) \in \mathbf{R}^{2 \times 2}$ 是惯性项, $C(q, \dot{q}) \in \mathbf{R}^{2 \times 2}$ 是阻尼与摩擦项, $G(q) \in \mathbf{R}^{2 \times 1}$ 是重力项, $T \in \mathbf{R}^{2 \times 1}$ 是关节力矩, $D \in \mathbf{R}^{2 \times 1}$ 为未建模动力学以及干扰项.




图 3 外骨骼机器人模型

在 SAC 中, 设计控制律为^[8]

$$T_a = (1 - \alpha^{-1})(M(q)\ddot{q} + C(q, \dot{q})\dot{q}) + G(q). \quad (2)$$

在式(1)中, $T = T_a + T_{hm}$, 可得

$$T_{hm} = \alpha^{-1}(M(q)\ddot{q} + C(q, \dot{q})\dot{q}). \quad (3)$$

式(3)表明, α 越大, T_{hm} 越小, 即是灵敏度增大了, 人机交互力矩就会减小, 外骨骼的跟随性就会越好.

2 GA 优化 RBF

RBF 的性能很大程度上取决于中心矢量、基宽度参数以及权值, 用 GA 优化 RBF 结构能够获得较好的性能^[9-11]. 本文权值由设定的算法进行在线更新, 在已知输入值范围的条件下, 用 GA 优化出 RBF 网络最佳的中心矢量与基宽度.

GA 优化 RBF 网络流程见图 4.

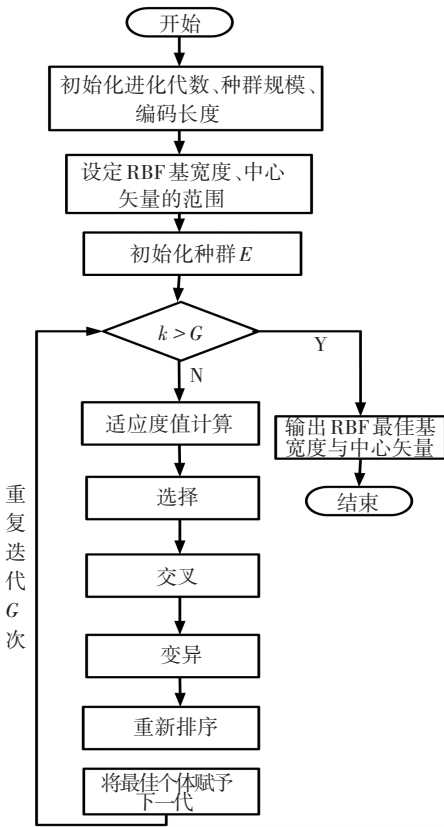


图 4 GA 优化 RBF 网络的基本流程

设定进化代数为 $G = 250$, 种群规模为 30, 编码长度为 10. 要设计的 RBF 网络是用来学习外骨骼动力学方程中的矩阵 $M(q)$ 、 $C(q, \dot{q})$ 以及 $G(q)$, 分别通过 GA 获得相应的中心矢量

$$c_M \in \mathbf{R}^{2 \times N}, c_C \in \mathbf{R}^{4 \times N}, c_G \in \mathbf{R}^{2 \times N}. \quad (4)$$

式中: c_M 、 c_C 、 c_G 为中心矢量, N 为隐含层节点数. 基宽度可以由下面的经验式获得:

$$b_M = c_{M_{\max}} / \sqrt{2 \cdot N}, b_C = c_{C_{\max}} / \sqrt{2 \cdot N}, b_G = c_{G_{\max}} / \sqrt{2 \cdot N}.$$

式中: b_M 、 b_C 、 b_G 为基宽度, $c_{M_{\max}}$ 、 $c_{C_{\max}}$ 、 $c_{G_{\max}}$ 为中心矢量元素的最大间隔. 进行 GA 优化, 得到优化后的 RBF 网络的基宽度与中心矢量. 对学习 $M(q)$ 的 RBF 网络, GA 优化 RBF 网络的结果如图 5, 迭代到 20 代左右即可获得最佳个体.




图 5 GA 优化中心矢量与基宽度的收敛过程

3 RBF 在线学习外骨骼动力学模型

外骨骼机器人系统由于其高度的非线性以及外部环境的影响, 很难求得精确的动力学模型, 借助神经网络的学习能力, 构造一种在线学习的 RBF 网络, 可获取更为准确的动力学方程. 本文提出了 RBF 网络在线学习外骨骼动力学模型 (1) 中的矩阵 $M(q)$ 、 $C(q, \dot{q})$ 以及 $G(q)$. 在 RBF 的结构中, 输入向量为 $X = [x_1, x_2, \dots, x_n]$, 映射到隐含层采用高斯径向基函数

$H_j = \exp(-\|X - c_j\|^2 / (2b_j^2))$, $j = 1, 2, \dots, N$. 式中: N 为隐含层节点数, H_j 为 j th 节点隐含层的输出, b_j 为 j th 节点的基宽度, c_j 为 j th 节点中心矢量.

外骨骼的动力学模型中, 矩阵 $M(q)$ 、 $C(q, \dot{q})$ 以及 $G(q)$ 是关于关节角度、角速度的矩阵. 对于 $M(q)$ 、 $C(q, \dot{q})$ 以及 $G(q)$, 基于 (4) 中的中心矢量与基宽度, 输入矢量分别为关节角度与角速度的组合, 通过高斯径向基函数, 可以得到隐含层的输出为

$$H_M(j) = \exp\left(-\frac{\|X_{M_j}(t) - c_M(j)\|^2}{2(b_M(j))^2}\right), \quad j = 1, 2, \dots, N;$$

$$H_C(j) = \exp\left(-\frac{\|X_{C_j}(t) - c_C(j)\|^2}{2(b_C(j))^2}\right), \quad j = 1, 2, \dots, N;$$

$$H_G(j) = \exp\left(-\frac{\|X_{G_j}(t) - c_G(j)\|^2}{2(b_G(j))^2}\right), \quad j = 1, 2, \dots, N.$$

其中, 输入矢量分别为

$$X_{M_j}(t) = [q_1(t), q_2(t)]^T,$$

$$X_{C_j}(t) = [q_1(t), q_2(t), \dot{q}_1(t), \dot{q}_2(t)]^T,$$

$$X_{G_j}(t) = [q_1(t), q_2(t)]^T.$$

式中: $b_M(j)$ 、 $b_C(j)$ 、 $b_G(j)$ 分别为 j th 节点的基宽度, $c_M(j)$ 、 $c_C(j)$ 、 $c_G(j)$ 分别为 j th 节点的中心矢量, t 是时间变量, 学习过程如图 6, 输入是关节的角度 (角速度), 经过隐含层的映射, 然后与当前时刻的权值相乘, 加和后即可得矩阵 $\tilde{M}(q)$ ($\tilde{C}(q, \dot{q})$), $\tilde{G}(q)$ 输出的元素, 每个时刻对权值进行在线更新.

设外骨骼跟随人体轨迹的角度、角速度、角加速度误差为

$$e(t) = q_h(t) - q(t), \quad \dot{e}(t) = \dot{q}_h(t) - \dot{q}(t), \\ \ddot{e}(t) = \ddot{q}_h(t) - \ddot{q}(t).$$

式中: $q_h(t)$ 是人体轨迹, $q(t)$ 是外骨骼轨迹, 定义 $s(t) = \dot{e}(t) + \lambda e(t)$, 其中, λ 是正常数, 定义等效速度与等效加速度为

$$\dot{q}_r(t) = \dot{q}_h(t) + \kappa e(t), \quad \ddot{q}_r(t) = \ddot{q}_h(t) + \kappa \dot{e}(t).$$

式中: κ 是正常数. 权值的更新是根据实际的轨迹误差以及误差变化率构造的, 权值更新的表达式如下^[12-13]:

$$\begin{aligned} W_M(j) &= W_{M-1}(j) + \eta \cdot H_M(j) \cdot \dot{q}_i(t) \cdot s(t), \\ W_C(j) &= W_{C-1}(j) + \eta \cdot H_C(j) \cdot [\ddot{q}_i(t), \dot{q}_i(t)] \cdot s(t), \\ W_G(j) &= W_{G-1}(j) + \eta \cdot H_G(j) \cdot s(t). \end{aligned}$$

式中: $W_{M-1}(j)$ 、 $W_{C-1}(j)$ 、 $W_{G-1}(j)$ 为初始权值矩阵, $W_M(j)$ 、 $W_C(j)$ 、 $W_G(j)$ 是更新后的权值矩阵, η 是学习速率. 经过 RBF 网络学习后, 网络的输出为

$$\begin{aligned} \hat{M} &= \sum_{j=1}^N H_M(j) W_M(j), \quad \hat{C} = \sum_{j=1}^N H_C(j) W_C(j), \\ \hat{G} &= \sum_{j=1}^N H_G(j) W_G(j). \end{aligned}$$

所以, 控制律(2)改写为

$$T_a = (1 - \alpha^{-1}) (\hat{M}(q) \ddot{q} + \hat{C}(q, \dot{q}) \dot{q}) + \hat{G}(q). \quad (5)$$




图 6 RBF 在线学习动力学模型的 $M(q)$ 矩阵控制框图如图 7 所示.




图 7 在线学习动力学方程的 SAC 控制框图

4 Matlab 仿真结果

图 3 所示的外骨骼主动自由度包括髋关节、膝关节, 踝关节为被动自由度. 根据临床步态实验^[14], 一个步态周期内髋关节、膝关节的轨迹如图 8, 将获得的离散点拟合为时间 t 的(周期为 2 s)方程:

$$\begin{cases} q_{\text{knee}} = 40.93 \cos(1.04t - 0.2082) + \\ 156.8 \cos(5.819t - 0.0467) + \\ 82.25 \cos(7.491t - 4.132), \\ q_{\text{hip}} = 3.848 \cos(0.3297t + 2.138) + \\ 71.85 \cos(3.486t - 1.877) + \\ 41.01 \cos(4.675t - 0.2988). \end{cases} \quad (6)$$




图 8 人体临床步态髋关节、膝关节运动轨迹

取采样周期为 $T_s = 0.001$ s, $0 \leq t \leq 2$, 应用控制律(5), 控制外骨骼机器人跟踪(6)所示的曲线, 得到的跟随效果如图 9. 图 9 表明, 外骨骼的关节轨迹与人体的行走轨迹基本吻合, 实现了高度地跟随. 跟随的误差曲线如图 10, 可以看出, 误差在 0 的小邻域内变化, 基本能够收敛到 0. 为了说明 GA 对 RBF 网络的作用, 常规的 RBF 与优化后的 RBF 比较结果如图 11、12 所示. 优化后的 RBF 网络跟踪误差更小, 优化后的 RBF 网络 SAC 控制使得人机交互信息基本稳定地保持在 0 的小邻域内, 人机交互信息的减小, 表明了外骨骼能够高度跟随人体的运动轨迹.




图 9 RBF 在线学习 SAC 的人体轨迹跟踪




图 10 RBF 在线学习 SAC 的轨迹跟踪误差

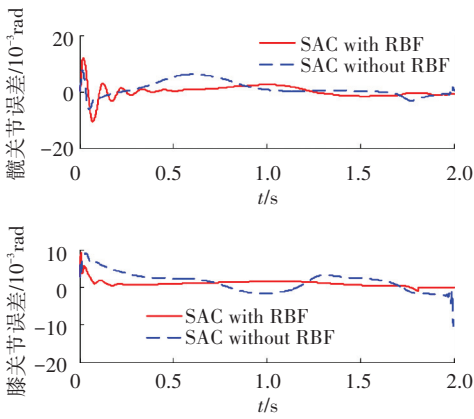


图 11 人体轨迹跟踪误差对比曲线




图 12 人机交互力矩对比曲线

5 结 论

1) 利用 GA 优化出满足适应度函数要求的 RBF 神经网络最佳中心矢量与基宽度,能够一定程度上改善 RBF 网络的映射能力。

2) 设定的在线 RBF 学习过程只作权值的更新,通过设定的算法在线计算外骨骼机器人的动力学模型。

3) GA 优化的 RBF 网络与没有优化的 RBF 网络的 SAC 控制比较表明,GA 优化的 RBF 网络在跟随人体运动轨迹时有较高的精度以及较小的人机交互力矩。

4) 基于 GA 优化的 RBF 网络学习外骨骼动力学模型的方法是可行的,实现 SAC 控制方法精确控制,但实际应用需要试验验证。

参 考 文 献

[1] KAZEROONI H, STEGER R, HUANG L. Hybrid control of the Berkeley Lower Extremity Exoskeleton (BLEEX) [J]. The International Journal of Robotics Research, 2006, 25(5/6): 561-573.

[2] ZOISS A B, KAZEROONI H, CHU Andrew. Biomechanical design of the Berkeley Lower Extremity Exoskeleton (BLEEX)[J]. IEEE/ASME Trans on Mechatronics, 2006, 11(2): 128-138.

[3] GHAN J, STEGER R, KAZEROONI H. Control and system identification for the Berkeley Lower Extremity Exoskeleton (BLEEX) [J]. Advanced Robotics, 2006, 20(9): 989-1014.

[4] JIANG Z, ISHIDA T, SUNAWADA M. Neural network aided dynamic parameter identification of robot manipulators [C]//Proceedings of IEEE International Conference on Systems, Man and Cybernetics. Taipei: IEEE, 2006: 3298-3303.

[5] BIDYADHAR S. DEBASHISHA J. Nonlinear system identification using memetic differential evolution trained neural networks[J]. Neurocomputing, 2011, 74(10): 1696-1709.

[6] 杨智勇, 归丽华, 杨秀霞, 等. 骨骼神经网络灵敏度放大控制方法 [J]. 吉林大学学报: 工学版, 2009 (3): 824-829.

[7] GHAN J, KAZEROONI H. System Identification for the Berkeley Lower Extremity Exoskeleton (BLEEX) [C]// Proceedings of IEEE International Conference on Robotics and Automation. Orlando: IEEE, 2006: 3477-3484.

[8] 杨智勇, 张远山, 顾文锦, 等. 骨骼神经网络灵敏度放大控制方法研究 [J]. 计算机仿真, 2010(1): 177-180.

[9] WANG Hongfa, XU Xinai. Applying RBF neural networks and genetic algorithms to nonlinear system optimization [J]. Advanced Materials Research, 2012, 605-607: 2457-2460.

[10] DING Shifei, XU LI, SU Chunyang, et al. An optimizing method of RBF neural network based on genetic algorithm [J]. Neural Computing & Applications, 2012, 21(2): 333-336.

[11] WANG Binli, BAI Guangliang, WEI Zhaolan. Bridge safety evaluation by RBF neural network with genetic algorithm [C]//Proceedings of IEEE International Conference on Information and Financial Engineering (ICIFE). Chongqing: IEEE, 2010: 563-566.

[12] GE S S, HANG C C, WOON L C. Adaptive neural network control of robot manipulators in task space [J]. IEEE Trans on Industrial Electronics, 1997, 44(6): 746-752.

[13] 刘金琨. 机器人控制系统的设计与 MATLAB 仿真 [M]. 北京: 清华大学出版社, 2008: 31-158.

[14] KIRTLEY C. CGA normative gait database [DB/OL]. [2014-06-5]. <http://www.clinicalgaitanalysis.com/data/>.

(编辑 杨 波)