

有限值终态零化神经网络及其在机器人运动规划中的应用

汪黎明, 仲国民, 孙明轩, 何熊熊

引用本文

汪黎明, 仲国民, 孙明轩, 何熊熊. [有限值终态零化神经网络及其在机器人运动规划中的应用](#)[J]. 计算机科学, 2025, 52(5): 270-280.

WANG Liming, ZHONG Guomin, SUN Mingxuan, HE Xiongxiang. [Finitely-valued Terminal Zeroing Neural Networks with Application to Robotic Motion Planning](#) [J]. Computer Science, 2025, 52(5): 270-280.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[用于时变矩阵计算的固定时间递归神经网络及其在重复运动规划中的应用](#)

Fixed-time Recurrent Neural Networks for Time-variant Matrix Computing and Its Application in Repeatable Motion Planning

计算机科学, 2024, 51(8): 324-332. <https://doi.org/10.11896/jsjcx.230500052>

[有限值终态递归神经网络计算](#)

Time-variant Neurocomputing with Finite-value Terminal Recurrent Neural Networks

计算机科学, 2020, 47(1): 212-218. <https://doi.org/10.11896/jsjcx.181001898>

[差分隐私流数据实时发布中的自适应参数优化](#)

Adaptive Parameter Optimization for Real-time Differential Privacy Streaming Data Publication

计算机科学, 2019, 46(9): 99-105. <https://doi.org/10.11896/j.issn.1002-137X.2019.09.013>

[基于终态神经网络的冗余机械臂重复运动规划](#)

Repeatable Motion Planning of Redundant Manipulators Based on Terminal Neural Networks

计算机科学, 2018, 45(12): 201-205. <https://doi.org/10.11896/j.issn.1002-137X.2018.12.033>

[基于模拟退火的自适应水波优化算法](#)

Adaptive Water Wave Optimization Algorithm Based on Simulated Annealing

计算机科学, 2017, 44(10): 216-221. <https://doi.org/10.11896/j.issn.1002-137X.2017.10.039>

有限值终态零化神经网络及其在机器人运动规划中的应用

汪黎明 仲国民 孙明轩 何熊熊

浙江工业大学信息工程学院 杭州 310023

(792023809@qq.com)

摘要 针对等式约束的时变二次规划求解问题,提出一种有限值终态零化神经网络,以保证计算误差的有限时间收敛,其有限值特性易于实现;对有限值终态零化神经网络进行理论分析,并给出该神经网络的收敛时间表达式。冗余机械臂的重复运动规划问题可描述为时变二次规划问题,采用有限值终态零化神经网络作为求解器,以获取末端执行器轨迹对应的关节轨迹。考虑到机械臂关节初始偏差难以避免,采用定参数/自适应参数的终态优化指标,在实现机械臂末端位置误差的有限时间收敛的同时,提高重复运动规划的精度。为保证机械臂的平稳运行,提出一种平滑修正的有限值函数用于终态优化指标设计。理论分析机械臂末端执行器位置误差的有限时间收敛条件。数值仿真以及 UR5 机械臂仿真与实验结果,验证了所提计算方案的有效性。

关键词: 终态零化神经网络;有限时间收敛;终态优化指标;冗余机械臂;自适应参数;重复运动规划

中图分类号 TP182

Finitely-valued Terminal Zeroing Neural Networks with Application to Robotic Motion Planning

WANG Liming, ZHONG Guomin, SUN Mingxuan and HE Xiongxiang

School of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China

Abstract To solve the problem of time-varying quadratic programming with equality constraints, this paper proposes a finitely-valued terminal zeroing neural network achieving the finite-time convergence of computing errors while being easy to implement. The convergence of the finitely-valued terminal zeroing neural network is theoretically analyzed, and the specific expression for settling time is provided. The repetitive motion planning problem of redundant robotic manipulators can be described as a time-varying quadratic programming. By employing the finitely-valued terminal zeroing neural network as a solver, the joint position and velocity trajectories, corresponding to the desired end-effector trajectory, can be obtained. Considering the inevitable initial joint shift, a terminal optimization criterion with fixed/adaptive parameters is proposed, aiming for finite-time convergence of end-effector position error and higher precision in repetitive motion planning. To ensure smooth operation of the robotic manipulator, a smooth-corrected finite-value function is proposed for the terminal optimization criterion, and the finite-time convergence of the end-effector position error is established. Numerical simulations and UR5 manipulator simulation and experimental results validate effectiveness of the proposed computing scheme.

Keywords Terminal zeroing neural networks, Finite-time convergence, Terminal optimization criterion, Redundant manipulators, Adaptive parameter, Repetitive motion planning

1 引言

时变二次规划的在线求解问题,在科学与工程领域备受关注。等式约束的时变二次规划作为二次规划重要的组成部分,常应用于机器人运动规划^[1]、最优控制器设计^[2]以及数字图像处理^[3]等领域。现阶段,常采用离散数值方法求解凸二次规划问题,此类方法的最小算术运算次数通常与相关矩阵维数的立方成正比,这使得其在面对大规模或实时计算问题时,效率低下。随着计算机科学的发展,神经网络方法凭借其电路实现的可行性与并行运算的特点,在大规模时变计算问

题方面得到广泛应用。梯度神经网络(Gradient Neural Network, GNN)是一种基于梯度下降思想的传统神经网络模型,常用于求解凸二次规划问题。然而,梯度神经网络缺乏时间导数信息,在计算时变二次规划问题时总是存在滞后误差,无法在有限时间内获得时变的理论解。

零化神经网络^[4]作为一种特殊递归神经网络,派生于Hopfield神经网络,解决了梯度神经网络时间导数信息缺失的问题,被广泛应用于时变问题的求解,如时变矩阵逆运算^[5]、李雅普诺夫方程^[6]以及时变二次规划问题^[7]。激活函数作为零化神经网络的核心组成部分,其合理的设计可保证

到稿日期:2024-04-24 返修日期:2024-09-14

基金项目:国家自然科学基金(62073291,62222315)

This work was supported by the National Natural Science Foundation of China(62073291,62222315).

通信作者:仲国民(zgm@zjut.edu.cn)

零化神经网络的收敛性能。理论上,任何单调递增的奇函数都可作为零化神经网络的激活函数。线性激活函数形式最为简单,但精度较差。Power-sigmoid 激活函数^[8]将误差分段,分别加速收敛过程,实现系统误差的指数收敛。上述激活函数均为渐近收敛,即只有时间趋于无穷时才能收敛至理论解,无法满足现阶段高精作业的需求。为解决这一问题,具有有限时间收敛特性的激活函数被提出。文献[9]提出 Sign-bi-power 激活函数,以求解时变 Sylvester 方程并实现计算误差的有限时间收敛。文献[10]则是在 Sign-bi-power 激活函数的基础上改进,提出一种 Li-函数作为神经网络激活函数,进一步加速了有限时间的收敛过程。然而,上述激活函数值会随神经网络状态变化,且无上下限制,当神经网络初值较大时,此类激活函数可能会放大神经输入,使其超出系统可实现的范围。有限值激活函数,其激活函数值虽随神经网络状态变化,但始终保持有限值,被认为具有现实意义。工程中常采用带有饱和约束的激活函数,如线性饱和和激活函数、球型激活函数以及非凸激活函数。文献[11]采用线性饱和以及非凸激活函数驱动的零化神经网络求解带有不等式约束的欠定线性方程组。文献[12]考虑到系统初态对神经网络实现的影响,提出一种饱和形式的神经动态,并理论分析了通用饱和激活函数的收敛性与鲁棒性。此类激活函数的有限值性质虽考虑到工程实现问题,但神经计算效率较低,无法实现有限时间收敛。针对这一问题,本文提出一种有限时间收敛的有限值激活函数,构造了有限值终态零化神经网络,并理论分析了神经网络的收敛性能。

冗余机械臂是指具有超出给定任务所需最小自由度数的机械臂。冗余的自由度,能使机械臂在执行任务的同时,避开场景中的障碍物,规避机械臂奇异位姿,适应复杂的工作环境和多变的作业需求。冗余特性使得机械臂同一末端的执行器位置可能映射多种关节角度组合,这意味着在执行一周期封闭末端任务后,机械臂可能无法回到初始关节构型,出现关节角漂移现象^[13-15]。这一现象将导致后续出现非期望的关节运动,不仅影响机械臂作业效率,甚至危及周围设备及操作人员的安全。基于伪逆的机械臂运动学控制作为应用最为广泛的方法^[16-18],简单直观,可根据期望轨迹获得关节速度的最小范数解。然而,该方法需要在规划时间内连续求解伪逆,计算负担较大,且无法消除机械臂冗余特性带来的关节角漂移现象。机械臂自运动控制作为一种重复运动规划修正方法^[19],其主要思想是通过增加任务之外的运动来调整机械臂的关节构型,以实现重复运动规划。然而,额外的动作使得机械臂重复作业效率低下。

为解决这一问题,基于二次优化指标(Quadratic Optimization Criterion, QOC)的冗余机械臂重复运动规划方案被提出^[20],将其将机械臂运动控制问题表述为二次优化问题,在末端任务与机械臂物理约束下求取满足重复运动规划要求的最优可行解。文献[21]将二次规划问题表示为紧凑二次轨迹形式,采用对偶算法求解,文中首次提出关节无偏差性能指标,可在实现机械臂末端任务的同时消除关节角漂移现象。然而,对偶算法无法避免矩阵求逆运算,计算效率较低。随着计算机科学的发展,越来越多的智能算法被用于冗余机械臂

轨迹规划,如遗传算法^[22]、粒子群算法^[23]、神经网络方法^[24]等。文献[25]将重复运动指标作为二次优化准则,采用递归神经网络求解,形成连续时间冗余机械臂重复运动规划方案。该方法无需进行矩阵逆运算,计算效率显著提高。文献[26]提出一种具有抗扰能力的固定时间收敛 ZNN,其通过调整激活函数参数,可一定程度地提高系统对有界噪声的鲁棒性。文献[27]提出一种预定时间收敛的鲁棒 ZNN 模型,其在考虑机械臂物理约束的情况下,实现了冗余机械臂重复运动规划任务。以上方法默认机械臂末端执行器初始位置与期望初始位置一致。在工程应用时,初始位置偏差难以避免。文献[28]考虑到此问题,提出一种应用更广泛的冗余机械臂优化指标。零化神经网络作为一种高效的神经动力学计算方法,用于替代机械臂冗余度解析中的矩阵求逆运算,其并行运算的特点,使得 ZNN 能够高效获取高精度的计算结果。采用零化神经网络解决冗余机械臂重复运动规划问题,已然成为一种常规方法。考虑到初始位置偏差,即机械臂实际末端初始位置与期望初始位置不一致的情况,相关文献仅关注神经计算误差的改善问题。机械臂末端执行器误差作为衡量机械臂轨迹规划性能的主要指标,需要进一步重视。

本文在冗余机械臂二次优化指标的基础上引入指标和约束修正函数,构建冗余机械臂重复运动规划的终态优化指标(Terminal Optimization Criterion, TOC),采用有限值终态零化神经网络(Terminal Zeroing Neural Network, TZNN)作为求解器,形成基于终态优化指标的有限值终态零化神经网络求解方案(TOC-TZNN)。在存在关节初始偏差的情况下,TOC-TZNN 可实现冗余机械臂末端执行器误差的有限时间收敛。在此基础上,进一步提出一种自适应系数终态优化指标来提高机械臂末端误差的收敛速度。本文从理论上证明了所提方法的有限时间收敛性,并指出该方法实现冗余机械臂末端执行器误差有限时间收敛的必要条件。从实际应用出发,提出一种分段形式的有限时间激活函数,在误差进入零点的 δ 邻域时切换至二次激活函数,避免机械臂运行途中出现速度突变、震荡等不利现象;在此基础上,实现了冗余机械臂末端误差 δ 自定邻域的有限时间收敛。为进一步验证所提方法的有效性,本文以冗余机械臂 UR5 作为仿真与实验平台,将 TOC-TZNN 方案与传统二次规划机械臂冗余度解析方案进行比较,体现了基于 TOC-TZNN 方案的冗余机械臂重复运动规划方法在关节回拢误差以及末端误差收敛方面的优势。

2 零化神经网络

考虑等式约束的时变二次规划问题:

$$\min_{\mathbf{x}} \frac{1}{2} \mathbf{x}^T(t) \mathbf{Q}(t) \mathbf{x}(t) + \mathbf{q}^T(t) \mathbf{x}(t) \quad (1)$$

$$\text{s. t. } \mathbf{A}(t) \mathbf{x}(t) = \mathbf{b}(t) \quad (2)$$

其中, $\mathbf{Q}(t) \in \mathbb{R}^{n \times n}$ 为对称正定矩阵, $\mathbf{x}(t) \in \mathbb{R}^{m \times n}$ 为行满秩矩阵, $\mathbf{q}(t) \in \mathbb{R}^n$ 与 $\mathbf{b}(t) \in \mathbb{R}^m$ 为已知列向量, $\mathbf{x}(t) \in \mathbb{R}^n$ 表示待求解的未知向量。上标 T 表示矩阵转置运算。由矩阵 $\mathbf{Q}(t)$ 的正定性与等式约束的线性结构可知,式(1)、式(2)为凸二次规划问题,根据最优化理论,凸二次规划存在唯一全局最优

解。采用拉格朗日乘数法可将约束优化问题(1)和(2)转化为无约束优化问题:

$$\min_{x, \lambda} L(x(t), \lambda(t), t) = \frac{1}{2} x^T(t) Q(t) x(t) + q^T(t) x(t) + \lambda^T(t) (A(t) x(t) - b(t)) \quad (3)$$

其中, $\lambda(t)$ 为拉格朗日乘子。对于存在唯一解的无约束优化问题, 最优解通常为驻点。因此, 令 $L(x(t), \lambda(t), t)$ 分别对未知量 $x(t)$ 与 $\lambda(t)$ 求偏导并取零, 则有:

$$\begin{cases} \frac{\partial L(x(t), \lambda(t), t)}{\partial x(t)} = Q(t)x(t) + q(t) + A^T(t)\lambda(t) = 0 \\ \frac{\partial L(x(t), \lambda(t), t)}{\partial \lambda(t)} = A(t)x(t) - b(t) = 0 \end{cases} \quad (4)$$

通过定义:

$$W(t) = \begin{bmatrix} Q(t) & A^T(t) \\ A(t) & 0 \end{bmatrix}$$

$$v(t) = \begin{bmatrix} q(t) \\ -b(t) \end{bmatrix}, y(t) = \begin{bmatrix} x(t) \\ \lambda(t) \end{bmatrix}$$

式(4)用矩阵方程表示为:

$$W(t)y(t) + v(t) = 0 \quad (5)$$

其中, $y(t) \in \mathbb{R}^{m+n}$ 为待求解的未知向量。至此, 等式约束的时变二次规划问题便转化为时变矩阵方程求解问题(式(5))。

2.1 常规零化神经网络

值得注意的是, 零化神经网络作为一种数值计算方法, 求解时通常需人为给定初值, 而真实初值 $y^*(0)$ 未知, 这使得初始计算误差难以避免。定义计算误差函数:

$$e(t) = W(t)y(t) + v(t) \quad (6)$$

零化神经网络通过设计误差动态使得计算误差收敛至零, 即待解向量 $y(t)$ 收敛至理论解 $y^*(t)$ 。常规 ZNN 模型的误差动态方程如下:

$$\dot{e}(t) = -\rho \Phi(e(t)) \quad (7)$$

其中, $\rho > 0$ 为可调参数, 用于调整 ZNN 模型的收敛速率, 参数 ρ 的值越大, 收敛速率越快, 实际应用受到系统硬件等因素约束, 可取系统允许范围内的最大值; $\Phi(\cdot)$ 表示神经网络激活函数。依据误差函数定义, 可得求解等式约束的时变二次规划问题的零化神经网络模型:

$$\dot{W}(t)y(t) + W(t)\dot{y}(t) + \dot{v}(t) = -\rho \Phi(W(t)y(t) + v(t)) \quad (8)$$

激活函数的选取对于 ZNN 的收敛性质至关重要。常见的激活函数, 如线性激活函数^[8]、Power-sigmoid 激活函数^[8]、Sign-bi-power 激活函数^[9]等, 均随系统误差变化且无上下限, 本文称此类函数为无限值激活函数。若某一时刻系统误差过大, 经无限值激活函数映射后可能超出电路系统可实现的范围, 导致限幅而无法实现理论性能。为此, 有限值激活函数被提出, 其激活函数值随神经网络状态变化始终保持有限值。本文给出几种典型的有限值激活函数。

1) 线性饱和和激活函数

$$\Phi(e_i) = \begin{cases} \mu^+, & e_i > \mu^+ \\ e_i, & \mu^- \leq e_i \leq \mu^+ \\ \mu^-, & e_i < \mu^- \end{cases}$$

其中, $\mu^- < 0, \mu^+ > 0$ 。

2) Sigmoid 激活函数

$$\Phi(e_i) = \frac{1 - \exp(-\zeta e_i)}{1 + \exp(-\zeta e_i)}$$

其中, $\zeta > 2$ 。

3) 球型激活函数

$$\Phi(e) = \begin{cases} e, & \|e\|_2 \leq r \\ r \frac{e}{\|e\|_2}, & \|e\|_2 > r \end{cases}$$

其中, $r > 0$ 。

以上 3 种激活函数均具有固定的上下界, 可依据系统要求设定, 但只能实现神经网络误差的渐近收敛。

2.2 有限值终态零化神经网络

为解决这一问题, 本文提出一种有限时间收敛的有限值激活函数:

$$s(e) = \frac{\eta |e|^\alpha}{\eta |e|^\alpha + 1} \text{sgn}(e) \quad (9)$$

其中, $\eta > 0$ 和 $0 < \alpha < 1$ 为可调参数, $\text{sgn}(\cdot)$ 表示符号函数。其中的矩阵运算表示逐元素计算, 如 $|\cdot|^\alpha$ 表示对向量中的各元素分别取绝对值并计算其 α 次幂, 向量除法表示两向量对应元素相除。对于任意取值的 e , 有 $|s(e)| \leq 1$ 成立, 故称其为有限值激活函数。

采用不同参数的有限值激活函数 $s(e)$ 随误差变化的曲线如图 1 所示。取激活函数 $\Phi(\cdot) = s(\cdot)$ 时, 由式(7)得神经网络模型:

$$\dot{e} = -\rho \frac{\eta |e|^\alpha}{\eta |e|^\alpha + 1} \text{sgn}(e) \quad (10)$$

其中, $\rho > 0$ 为定常参数。




图 1 取不同 α, η 值时的有限值激活函数

Fig. 1 Finite-value activation function with different α, η

有限值激活函数保证了神经网络的有限值与有限时间收敛特性, 故称神经网络(10)为有限值终态零化神经网络。依据神经动态方程(10), 可得求解时变二次规划(1)和(2)的有限值终态零化神经网络模型:

$$\dot{W}(t)y(t) + W(t)\dot{y}(t) + \dot{v}(t) = -\rho \frac{\eta |W(t)y(t) + v(t)|^\alpha}{\eta |W(t)y(t) + v(t)|^\alpha + 1} \text{sgn}(W(t)y(t) + v(t)) \quad (11)$$

有限值终态零化神经网络模型(11)可进一步改写为如下标量形式:

$$\dot{y}_i = \sum_{j=k}^k (I_{ij} - w_{ij}) \dot{y}_j - \sum_{j=1}^k \dot{w}_{ij} y_j + \dot{v}_i - \rho \frac{\eta \left| \sum_{j=1}^k w_{ij} y_j - v_i \right|^\alpha}{\eta \left| \sum_{j=1}^k w_{ij} y_j - v_i \right|^\alpha + 1} \text{sgn} \left(\sum_{j=1}^k w_{ij} y_j - v_i \right) \quad (12)$$

其中, I_{ij} 为单位矩阵中第 i 行第 j 列的元素。有限值终态神

冗余机械臂具有超出任务要求的自由度数,即 $\dim(\boldsymbol{\theta}(t)) > \dim(\mathbf{r}(t))$,作业时同一末端执行器位置可能映射多种关节角度组合,提高了机械臂灵活性的同时,可能导致关节角漂移。为解决此问题,可将机械臂重复运动规划问题描述为二次优化指标(QOC)^[25]:

$$\min_{\dot{\boldsymbol{\theta}}(t)} \frac{1}{2} (\dot{\boldsymbol{\theta}}(t) + \mathbf{z}_1(t))^T (\dot{\boldsymbol{\theta}}(t) + \mathbf{z}_1(t)) \quad (19)$$

$$\text{s. t. } J(\boldsymbol{\theta}(t)) \dot{\boldsymbol{\theta}}(t) = \dot{\mathbf{r}}(t) + K_p(\mathbf{r}(t) - \mathbf{f}(\boldsymbol{\theta}(t))) \quad (20)$$

其中, $\mathbf{z}_1(t) = \kappa(\boldsymbol{\theta}(t) - \boldsymbol{\theta}(0))$ 为机械臂关节约束项,用于消除重复运动规划带来的关节漂移现象; $\kappa > 0$ 为可调参数; $K_p(\mathbf{r}(t) - \mathbf{f}(\boldsymbol{\theta}(t)))$ 为机械臂末端位置误差反馈项; $K_p > 0$ 可用来调整末端执行器误差的收敛速度; $\mathbf{r}(t)$ 为给定期望轨迹。该优化指标默认机械臂末端执行器初始时刻与期望位置一致。工程应用时,定位误差总是存在,实际初始关节角与期望初始关节角难以完全一致。考虑到此问题,一种更加泛用的冗余机械臂重复运动规划二次优化指标被提出^[18]:

$$\begin{cases} \min_{\dot{\boldsymbol{\theta}}(t)} \frac{1}{2} (\dot{\boldsymbol{\theta}}(t) + \mathbf{z}_2(t))^T (\dot{\boldsymbol{\theta}}(t) + \mathbf{z}_2(t)) \\ \mathbf{z}_2(t) = \kappa(\boldsymbol{\theta}(t) - \boldsymbol{\theta}_d(0)) \end{cases} \quad (21)$$

其中, $\boldsymbol{\theta}_d(0)$ 为期望轨迹的初始关节角度。

为进一步理解机械臂二次优化指标及其约束,我们将探讨指标、约束对机械臂重复运动规划的影响。

1) 指标在机械臂重复运动规划中的作用

在不考虑等式约束的理想情况下,指标(19)的极小值为零,此时:

$$\dot{\boldsymbol{\theta}}(t) + \kappa(\boldsymbol{\theta}(t) - \boldsymbol{\theta}_d(0)) = 0 \quad (22)$$

定义关节角回拢误差 $e_\theta(t) = \boldsymbol{\theta}(t) - \boldsymbol{\theta}_d(0)$, 式(22)可表示为:

$$\dot{e}_\theta(t) + \kappa e_\theta(t) = 0 \quad (23)$$

该形式使得 $e_\theta(t)$ 随时间 t 的增加渐近收敛至零。二次优化指标通过极小化关节回拢误差,使得机械臂以相较于起始关节角最小的角度变化完成末端任务,以此消除关节角漂移现象。但是,优化指标的线性设计难以保障关节回拢精度。

2) 约束在机械臂重复运动规划中的作用

通过定义末端位置误差 $e_r(t) = \mathbf{r}(t) - \mathbf{f}(\boldsymbol{\theta}(t))$, 约束(20)可改写为:

$$\dot{e}_r(t) + K_p e_r(t) = 0 \quad (24)$$

在初始位置误差存在时,该形式使得 $e_r(t)$ 随时间 t 的增加渐近收敛至零。位置误差反馈项 $K_p e_r(t)$ 可检测误差并及时补偿,但等式约束的线性设计只能实现机械臂末端执行器误差的渐近收敛。

3.1 终态优化指标

针对上述问题,本节提出一类允许初始偏差的冗余机械臂重复运动规划终态优化方案,以提高机械臂关节回拢精度的同时实现机械臂末端执行器误差的有限时间收敛。

3.1.1 定参数终态优化指标

在二次优化指标(19)和(20)的基础上,通过引入指标以及约束修正函数,提出定参数的终态优化指标,其形式如下:

$$\min_{\dot{\boldsymbol{\theta}}(t)} \frac{1}{2} (\dot{\boldsymbol{\theta}}(t) + \mathbf{z}_3(t))^T (\dot{\boldsymbol{\theta}}(t) + \mathbf{z}_3(t)) \quad (25)$$

$$\text{s. t. } J(\boldsymbol{\theta}(t)) \dot{\boldsymbol{\theta}}(t) = \dot{\mathbf{r}}(t) + \kappa_2 R(\mathbf{r}(t) - \mathbf{f}(\boldsymbol{\theta}(t))) \quad (26)$$

其中, $\mathbf{z}_3(t) = \kappa_1 \Theta(\boldsymbol{\theta}(t) - \boldsymbol{\theta}_d(0))$ 为关节回拢角度约束项, $\kappa_2 R(\mathbf{r}(t) - \mathbf{f}(\boldsymbol{\theta}(t)))$ 为机械臂末端执行器位置偏差反馈项, $\kappa_1 > 0$ 和 $\kappa_2 > 0$ 为可调参数。 $\Theta(\cdot)$ 为指标修正函数, $R(\cdot)$ 为约束修正函数。

值得注意的是,参数 κ_2 的选取对末端执行器误差的收敛至关重要。从等式约束(26)来看,参数 κ_2 选取过小会导致末端执行器误差 $e_r(t)$ 收敛速度慢;过大的参数 κ_2 会放大等式约束的误差初值,影响后续神经网络计算的收敛速度。而末端执行器误差只有在神经网络误差收敛后才能收敛(见定理2证明),间接限制了末端执行器误差的收敛速度。

3.1.2 自适应参数终态优化方案

根据上述定参数终态优化指标的问题,可知期望参数 κ_2 应满足:1)初值小,神经网络误差初值小,收敛时间短;2)逐渐增大,可保证末端执行器误差收敛速度;3)考虑实际应用,还应满足误差收敛至零点后保持一个有限值。基于上述3点,给出有限值自适应参数终态优化方案:

$$\min_{\dot{\boldsymbol{\theta}}(t)} \frac{1}{2} (\dot{\boldsymbol{\theta}}(t) + \mathbf{z}_3(t))^T (\dot{\boldsymbol{\theta}}(t) + \mathbf{z}_3(t)) \quad (27)$$

$$\text{s. t. } J(\boldsymbol{\theta}(t)) \dot{\boldsymbol{\theta}}(t) = \dot{\mathbf{r}}(t) + \kappa_2(t) R(\mathbf{r}(t) - \mathbf{f}(\boldsymbol{\theta}(t))) \quad (28)$$

其中, $\kappa_2(t)$ 表示误差相关的有限值自适应参数,其余参数与定参数终态优化指标一致。为方便描述,定义末端执行器误差 $e_r(t) = \mathbf{r}(t) - \mathbf{f}(\boldsymbol{\theta}(t))$ 。

本文提出两种有限值自适应参数。

1) 反正切型有限值自适应参数

$$\kappa_2(t) = \lambda + \mu \frac{2}{\pi} \arctan\left(\frac{1}{\gamma \|e_r(t)\|_2 + \delta}\right) \quad (29)$$

2) 指数型有限值自适应参数

$$\kappa_2(t) = \lambda + \mu \exp(-\gamma \|e_r(t)\|_2) \quad (30)$$

其中, $\lambda \geq 0, \mu > 0, \gamma > 0$ 为可调参数。为避免奇异,反正切型有限值自适应参数(29)中的 $\delta \rightarrow 0^+$, 应用时可取当前设备能取到的最小正值。有限值自适应参数(29)和(30)为 $\|e_r(t)\|_2$ 相关函数,其中 $\|\cdot\|_2$ 表示二范数运算符。实际应用时,可选取合适参数来调整有限值自适应参数的上下界与收敛率,以满足任务需求。参数 λ 为有限值自适应参数的理论下界。有限值自适应参数上界为 $\lambda + \mu$, 当取 $\mu = 0$ 时退化为定参数。 γ 用于调整有限值自适应参数的变化率。

值得注意的是,终态优化方案的形式与性质随修正函数选取不同而有所差异。 $\Theta(\cdot)$ 与 $R(\cdot)$ 函数的选取,直接影响机械臂重复运动规划精度和位置误差收敛速度。理论上,任何单调递增的奇函数都可作为指标和约束修正函数。终态优化指标(25)和(27)的形式并不唯一,可替换为 $\dot{\boldsymbol{\theta}}^T(t) \dot{\boldsymbol{\theta}}(t) / 2 + \mathbf{z}_3^T(t) \dot{\boldsymbol{\theta}}(t)$, 该形式与(25)和(27)等效^[14]。

3.2 平滑修正有限值终态神经网络

为求解终态优化方案,需对其进行预处理。根据第2章所述,可将二次优化问题转化为方程组求解问题:

$$\mathbf{W}(t) \mathbf{y}(t) = \mathbf{v}(t) \quad (31)$$

其中:

$$\mathbf{W}(t) = \begin{bmatrix} \mathbf{I} & \mathbf{J}^T(\boldsymbol{\theta}(t)) \\ \mathbf{J}(\boldsymbol{\theta}(t)) & 0 \end{bmatrix}, \mathbf{y}(t) = \begin{bmatrix} \dot{\boldsymbol{\theta}}(t) \\ \boldsymbol{\lambda}(t) \end{bmatrix}$$

$$\mathbf{v}(t) = \begin{bmatrix} -\kappa_1 \Theta(\boldsymbol{\theta}(t) - \boldsymbol{\theta}_d(0)) \\ \dot{\mathbf{r}}(t) - \kappa_2 R(\mathbf{r}(t) - \mathbf{f}(\boldsymbol{\theta}(t))) \end{bmatrix}$$

其中, \mathbf{I} 为适当维度的单位矩阵。定义神经网络误差:

$$\mathbf{E}(t) = \mathbf{W}(t) \mathbf{y}(t) - \mathbf{v}(t) \quad (32)$$

值得注意的是,只有在等式约束(26)或(28)成立时,即 $E(t) = 0$, 终态优化指标才能保证机械臂末端位置误差的有限时间收敛。计算时,由于神经网络解初值 $\mathbf{y}(0)$ 未知,初始计算误差难以避免,需借助零化神经网络修正解,以满足优化指标及其约束。理论上,具有渐近收敛特性的零化神经网络在时间 t 趋于无穷时,误差收敛至零点,此时等式约束(26)或(28)无法在有限时间内成立,需采用终态零化神经网络求解。构建有限值终态零化神经网络的误差动态方程:

$$\dot{\mathbf{E}}(t) = -\rho \Phi(\mathbf{E}(t)) \quad (33)$$

其中, $\rho > 0$ 为可调参数; $\Phi(\cdot)$ 为神经网络的有限值激活函数。因此,由式(33)描述的神经网络被称为有限值终态零化神经网络。将误差(32)代入误差动态方程(33),并取 $\Phi(\cdot) = S(\cdot)$ 可得有限值终态零化神经网络方程:

$$\mathbf{W}(t) \dot{\mathbf{y}}(t) + \dot{\mathbf{W}}(t) \mathbf{y}(t) - \dot{\mathbf{v}}(t) = -\rho S(\mathbf{W}(t) \mathbf{y}(t) - \mathbf{v}(t)) \quad (34)$$

从图1中可以看出,有限值激活函数 $s(\cdot)$ 在零点附近的高梯度会放大误差在零点附近的变化,用于指标、约束修正时,可能会造成机械臂关节速度突变,不利于机械臂平稳运行。可引入二次函数修正零点梯度,给出平滑修正的有限值激活函数:

$$s'(\cdot) = \begin{cases} \frac{\eta}{\eta + 1} \frac{|\cdot|^\alpha}{|\cdot|^\alpha + 1} \text{sgn}(\cdot), & |\cdot| \geq \delta \\ \left(\frac{\alpha \eta \delta^{\alpha-2}}{(\eta \delta^\alpha + 1)^2} - \frac{\eta \delta^{\alpha-2}}{\eta \delta^\alpha + 1} \right) |\cdot|^2 \text{sgn}(\cdot) + \\ \left(\frac{\eta \delta^{\alpha-2}}{\eta \delta^\alpha + 1} - \frac{\alpha \eta \delta^{\alpha-2}}{(\eta \delta^\alpha + 1)^2} \right) (\cdot), & |\cdot| < \delta \end{cases} \quad (35)$$

其中, $\delta \geq 0$ 为可调整分段边界。有限值激活函数 $s'(\cdot)$ 在零点附近的 δ 邻域内切换为二次函数来修正零点梯度,相应地,其有限时间收敛性质在零点附近的 δ 邻域内切换为渐近收敛。取不同 δ 值的激活函数 $s'(\cdot)$ 如图3所示。




图3 取不同参数 δ 值时的有限值激活函数

Fig. 3 Finite-value activation function with different δ

3.3 收敛性分析

机械臂重复运动规划中的指标修正函数 $\Theta(\cdot)$ 、约束修正函数 $R(\cdot)$ 以及神经网络激活函数 $\Phi(\cdot)$ 职责各不相同,但作用机制类似,理论上都只要求函数为单调递增奇函数。本节采用有限时间收敛的有限值激活函数(9),同时用于指标修正、约束修正以及神经网络计算修正,可实现机械臂末端执行器的有限时间收敛。

定理2 有限值终态零化神经网络(34)求解冗余机械臂

重复运动规划问题(25)和(26),采用有限值激活函数(9)修正约束(26),即 $R(\cdot) = s(\cdot)$ 时,神经网络计算误差 $E(t)$ 可在有限时间

$$T_{1,i} = \frac{|E_i(0)|}{\rho} + \frac{1}{\rho \eta (1-\alpha)} |E_i(0)|^{1-\alpha} \quad (36)$$

从系统允许的任意初值收敛至零。机械臂末端执行器位置误差 $e_r(t)$ 可在有限时间

$$T_{2,i} = T'_{1,i} + \frac{|e_{r,i}(T'_{1,i})|}{\kappa_2} + \frac{1}{\kappa_2 \eta (1-\alpha)} |e_{r,i}(T'_{1,i})|^{1-\alpha} \quad (37)$$

收敛至零。其中, E_i 与 $e_{r,i}$ 分别表示 $E(t)$ 和 $e_r(t)$ 的第 i 个元素, T'_1 为时间向量 T_1 的后3位,表示神经计算误差 $E(t)$ 后3位元素的收敛时间。

证明:式(36)证明见定理1。由 $E(t)$ 定义(32)可知

$$E_2(t) = \mathbf{J}^T(\boldsymbol{\theta}(t)) \dot{\boldsymbol{\theta}}(t) - \dot{\mathbf{r}}(t) - \kappa_2 R(\mathbf{r}_d(t) - \mathbf{f}(\boldsymbol{\theta}(t))) \quad (38)$$

为 $E(t)$ 后3位元素。由定理1可知其收敛时间为:

$$T'_{1,i} = \frac{|E_{2,i}(0)|}{\rho} + \frac{1}{\rho \eta (1-\alpha)} |E_{2,i}(0)|^{1-\alpha}$$

式(38)用位置误差 $e_r(t)$ 简洁表示为:

$$\dot{e}_r(t) = -\kappa_2 R(e_r(t)) + E_2(t) \quad (39)$$

可以发现,机械臂末端误差 $e_r(t)$ 的收敛情况会受到 $E_2(t)$ 的影响。当 $t \geq T'_1$ 时 $E_2(t) = 0$, 此时式(39)可改写为:

$$\dot{e}_r(t) = -\kappa_2 R(e_r(t)) \quad (40)$$

与神经网络误差动态方程(33)类似,式(40)可使误差 $e_r(t)$ 在有限时间内收敛至零点。若将 $t = T'_1$ 看作初始时刻,则初始误差为 $e_r(T'_1)$ 。参考定理1证明,得机械臂末端误差收敛时间为:

$$T_{2,i} = T'_{1,i} + \frac{|e_{r,i}(T'_{1,i})|}{\kappa_2} + \frac{1}{\kappa_2 \eta (1-\alpha)} |e_{r,i}(T'_{1,i})|^{1-\alpha} \quad (41)$$

至此,定理2得证。

定理3 有限值终态零化神经网络(34)求解冗余机械臂重复运动规划问题(25)和(26),平滑修正的有限值激活函数(35)用于约束修正,即 $R(\cdot) = s'(\cdot)$ 时,神经网络计算误差 $E(t)$ 可在有限时间 T_1 (见定理1)时刻从系统允许的任意值收敛至零。当 $|e_{r,i}(T'_1)| > \delta$ 时,机械臂末端执行器位置误差 $e_r(t)$ 可在有限时间

$$T_{2,i} = T'_{1,i} + \frac{|e_{r,i}(T'_{1,i})| - \delta}{\kappa_2} + \frac{1}{\kappa_2 \eta (1-\alpha)} (|e_{r,i}(T'_{1,i})|^{1-\alpha} - \delta^{1-\alpha}) \quad (42)$$

时刻收敛至界 δ 上,渐近收敛至零点。若 T'_1 时刻的位置误差 $|e_{r,i}(T'_1)| \leq \delta$, 则有 $T_{2,i} \leq T'_{1,i}$ 。其中, T'_1 表示神经计算误差 $E(t)$ 后3位元素的收敛时间。具体形式见定理1证明。

与定理1相比,定理2神经网络激活函数未作改变,神经网络计算误差 $E(t)$ 可在有限时间 T_1 时刻收敛的特性不变。

综上,基于二次规划的零化神经网络的机械臂冗余度解析方案,其末端执行器误差有限时间收敛要求二次规划约束(26)或(28)与零化神经网络(34)同时满足有限时间收敛特性。

4 仿真与实验

为验证所提有限值终态零化神经网络的有效性,本章将

其用于时变方程组数值的求解。冗余机械臂重复运动规划方面,采用有限值终态零化神经网络求解定参数/自适应参数终态优化指标,并通过与常规重复运动规划指标的冗余度解析方案相比较,来验证所提方案的有效性。

4.1 时变二次规划求解

考虑等式约束的时变二次规划问题(1)和(2),已知:

$$Q(t) = \begin{bmatrix} \cos(t)+2 & \sin(2t) \\ \sin(2t) & \cos(t)+2 \end{bmatrix}, p(t) = \begin{bmatrix} \cos(2t) \\ \sin(2t) \end{bmatrix}$$

$$A(t) = [\cos(3t) \quad \sin(3t)], b(t) = \sin(4t)$$

由第 2 章可知,依据最优化理论可将二次规划问题转化为矩阵方程求解问题:

$$W(t)y(t) + v(t) = 0$$

其中:

$$W(t) = \begin{bmatrix} \cos(t)+2 & \sin(2t) & \cos(3t) \\ \sin(2t) & \cos(t)+2 & \sin(3t) \\ \cos(3t) & \sin(3t) & 0 \end{bmatrix}$$

$$v(t) = [-\cos(2t) \quad -\sin(2t) \quad \sin(4t)]^T$$

此时,待解向量 $y(t) = [x_1(t) \quad x_2(t) \quad \lambda(t)]^T$, $\lambda(t)$ 表示拉格朗日乘子。仿真时选取随机初值 $y(0) = [2 \quad -1 \quad 1]^T$, 神经网络增益 $\rho = 1$ 。为验证所提有限值终态零化神经网络的有效性,采用常规零化神经网络作为对照组,并选取 3 种典型的有限值激活函数用于零化神经网络设计,包括线性饱和和激活函数、Sigmoid 激活函数以及球型激活函数。仿真结果如图 4—图 6 所示。为保证比较的公平性,将 4 种有限值激活函数的值域范围设置一致,均为 $[-1, 1]$, 具体参数设置为:线性饱和和激活函数中 $\mu^+ = 1, \mu^- = -1$; Sigmoid 激活函数中 $\zeta = 3$; 球型激活函数中 $r = 1$; 本文所提有限值激活函数中取 $\alpha = 1/3, \eta = 2, 3, 10$ 这 3 种情况以验证参数对收敛性能的影响。图 4 给出了基于线性饱和、Sigmoid 以及球型激活函数的常规零化神经网络求解时变二次规划问题的结果。图 5 给出了采用有限值终态零化神经网络求解二次规划问题的结果。可以看出,在同一神经网络参数下,有限值终态神经网络首先收敛至解析解 $y^*(t)$ 。值得注意的是,仿真中采用的 4 类激活函数均为有限值函数,这表示其可将网络状态映射至一个有限区间,能保证电路的可实现性。




图 4 常规零化神经网络求解时变二次规划的结果

Fig. 4 Results of solving time-varying quadratic programming with conventional zeroing neural network




图 5 有限值终态零化神经网络(11)求解时变二次规划的结果

Fig. 5 Results of solving time-varying quadratic programming with finite-value terminal zeroing neural network(11)

为更直观地反映误差收敛情况,图 6 给出了神经网络计算误差的收敛过程,其中纵轴 $\|e\|_2 = \sqrt{\sum_{i=1}^n e_i^2}$ 表示误差二范数。可以看出,在初始误差相同,神经网络参数一致的情况下,基于球型、线性饱和以及 Sigmoid 激活函数的零化神经网络收敛速度慢,理论上需要无穷时间才能收敛至精确解,而实际求解时间有限,导致其计算精度不高;而有限值终态神经网络在保证有限值特性的同时,可使误差 $e(t)$ 在有限时间内收敛至零点。




图 6 神经计算误差

Fig. 6 Neural computing errors

4.2 机械臂重复运动规划

本节分别采用常规机械臂重复运动规划方案和本文所提机械臂重复运动终态优化方案实现 UR5 机械臂闭合圆形轨迹规划。设定 UR5 机械臂期望回拢角度 $\theta_d(0) = [-\pi/2, -\pi/2, -\pi/2, -\pi/2, \pi/2, 0]^T$ rad, 圆的半径设为 0.15 m, 其圆面与 XY 平面的夹角为 $\pi/6$ rad, 末端执行器完成圆形轨迹时间 $T = 10$ s。考虑到机械臂的初始位置不在期望的运动轨迹上,将机械臂的 6 个关节角初值设为 $\theta(0) = \theta_d(0) + \Delta\theta(0)$, 其中 $\Delta\theta(0) = [-0.25, 0, 0.3, 0, 0, 0]^T$ rad。设定仿真增益 $\kappa_1 = 1, \kappa_2 = 2, \rho = 1$ 。为验证终态优化指标的冗余机械臂重复运动规划方案的有效性,本节进行 3 组对比仿真实验。

1)基于二次优化指标的零化神经网络求解方案(QOC-ZNN)

$$\Theta(\cdot) = \cdot; R(\cdot) = \cdot; \Phi(\cdot) = \cdot$$

2)基于二次优化指标的有限值终态零化神经网络求解方案(QOC-TZNN)

$$\Theta(\cdot) = \cdot; R(\cdot) = \cdot; \Phi(\cdot) = s(\cdot)$$

3)基于终态优化指标的有限值终态零化神经网络求解方案(TOC-TZNN)

$$\Theta(\cdot) = s'(\cdot); R(\cdot) = s'(\cdot); \Phi(\cdot) = s(\cdot)$$

以上3种方案中,除修正函数 $\Theta(\cdot)$ 和 $R(\cdot)$ 及激活函数 $\Phi(\cdot)$ 不同外,其余参数一致。有限值激活函数 $s(\cdot)$ 与 $s'(\cdot)$ 中的参数选取为 $\alpha=1/3, \eta=2$,在TOC-TZNN方案中, $\delta_\Theta = \delta_R = 0.01$ 分别表示 $s'(\cdot)$ 在修正函数 $\Theta(\cdot)$ 和 $R(\cdot)$ 中的分段边界取值。

图7给出了采用终态优化指标的冗余机械臂UR5关节运动的轨迹。其中,红色虚线为期望末端轨迹,蓝色实线表示机械臂末端的实际运动轨迹,黑色实线为机械臂连接杆。可以看到,机械臂末端初始位置在期望轨迹之外,存在初始偏差。图8给出了相应的机械臂关节角轨迹。可以看出,在一个封闭轨迹结束后,关节角收敛至期望初始关节角 $\theta_d(0)$,实现了冗余机械臂的重复运动规划。




图7 冗余机械臂UR5轨迹规划的整体图(电子版为彩图)

Fig.7 Full view of trajectory planning for redundant manipulator UR5




图8 冗余机械臂UR5的关节角轨迹

Fig.8 Joint angles of redundant manipulator UR5

图9—图11给出了QOC-ZNN方案、QOC-TZNN方案和TOC-TZNN方案在冗余机械臂UR5上的仿真结果,分别用绿色、蓝色和红色曲线表示。机械臂末端执行器的运动轨迹如图9所示,其中,期望轨迹表示为黑色虚线。由图可知,机械臂末端执行器初始位置不同于期望初始位置,在位置误差反馈项的作用下,机械臂末端执行器随着时间的推移逐渐收敛至期望轨迹。QOC-ZNN方案因指标、约束以及神经网络

误差动态的线性设计,机械臂末端执行器误差收敛缓慢。QOC-TZNN方案由于终态零化神经网络的有限时间收敛性,因此二次优化指标中的等式约束在有限时间内成立,一定程度提高了机械臂末端执行器误差的收敛速度;然而约束中位置误差反馈项的线性设计没有改变,只能实现机械臂末端执行器误差的渐近收敛。TOC-TZNN方案通过引入约束修正函数,实现了机械臂末端执行器误差的有限时间收敛。机械臂末端执行器在XYZ轴的位置误差 $e_r(t)$ 收敛情况如图10所示。在同一初始误差的情况下,相比QOC-ZNN与QOC-TZNN方案,TOC-TZNN方案的位置误差在XYZ轴上都具有更快的收敛速度。




图9 UR5末端执行器的运动轨迹(电子版为彩图)

Fig.9 End-effector trajectories of UR5

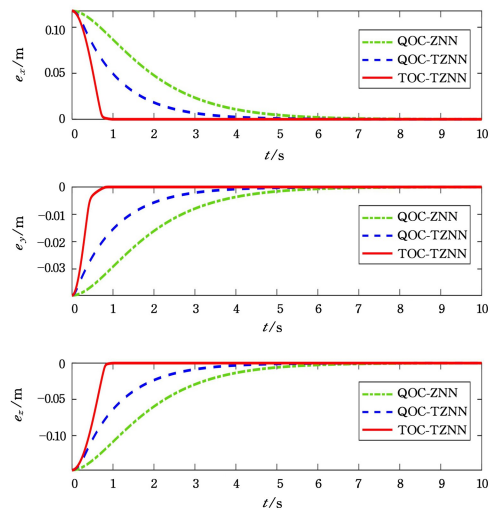


图10 UR5末端执行器的位置误差(电子版为彩图)

Fig.10 End-effector position error of UR5

冗余机械臂重复运动规划的关节角偏移问题是影响安全作业的一大隐患,终态优化指标(TOC)通过引入指标修正函数 $\Theta(\cdot)$,增强期望初始关节角 $\theta_d(0)$ 对当前关节角度 $\theta(t)$ 的吸引力,有效减小关节回扰误差,具体效果如表2所列。

表2 UR5关节回扰误差

Table 2 Joint error of UR5

关节回扰误差	QOC-ZNN	QOC-TZNN	TOC-TZNN
$\theta_1(10) - \theta_{d1}(0)$	-1.35×10^{-4}	-2.18×10^{-5}	-4.47×10^{-9}
$\theta_2(10) - \theta_{d2}(0)$	6.34×10^{-5}	1.17×10^{-5}	-1.33×10^{-8}
$\theta_3(10) - \theta_{d3}(0)$	7.02×10^{-5}	-7.39×10^{-5}	2.99×10^{-8}
$\theta_4(10) - \theta_{d4}(0)$	4.85×10^{-5}	6.08×10^{-5}	-9.11×10^{-8}
$\theta_5(10) - \theta_{d5}(0)$	6.11×10^{-5}	5.36×10^{-5}	2.41×10^{-8}
$\theta_6(10) - \theta_{d6}(0)$	0	0	0

图 11 给出了 3 种方案的神经计算误差。相比于 QOC 方案, TOC-TZNN 方案的神经计算误差初值 $E(0)$ 由于指标和约束修正函数的引入而改变, 其误差收敛速度与 QOC-TZNN 一致, 仅受 TZNN 影响。机械臂末端执行器的位置误差是冗余机械臂轨迹规划的重点, 神经计算误差的收敛情况不能作为衡量轨迹规划效果的标准。




图 11 神经计算误差 $E(t)$ (电子版为彩图)

Fig. 11 Neural computing error $E(t)$

图 12 给出了不同定参数 κ_2 的终态优化指标与自适应参数终态优化指标所得机械臂末端执行器的位置误差, 其中红色实线表示自适应参数终态优化指标所得结果。

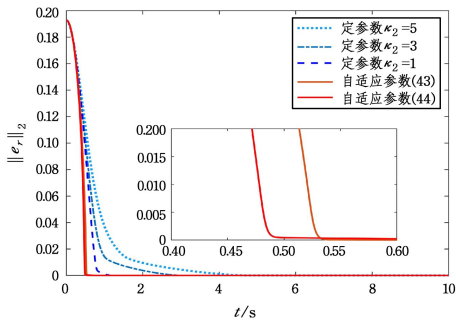


图 12 定参数/自适应参数终态优化指标所得机械臂末端位置误差 (电子版为彩图)

Fig. 12 End-effector position error of manipulator using fixed/adaptive parameter terminal optimization criterion

仿真时, 预设系统所能承受的参数范围为 $[0, 5]$ 。自适应参数设定为:

$$\kappa_2(t) = 5 \frac{2}{\pi} \arctan\left(\frac{1}{40 \|e_r(t)\|_2 + 10^{-8}}\right) \quad (44)$$

和

$$\kappa_2(t) = 0.5 + 4.5 \exp(-20 \|e_r(t)\|_2) \quad (45)$$

可知 $0 \leq \kappa_2(t) \leq 5$ 满足系统要求。仿真结果显示采用定参数终态优化指标可改善机械臂末端执行器误差收敛的进程。由 3.1 节可知, 过大或过小的参数都会减慢末端误差收敛的速度, 最优参数的选取往往需要多次尝试, 实际运用时效率低下。带有自适应参数的终态优化指标可解决这一问题。值得注意的是, TOC-TZNN 方案中指标与约束修正函数 $\Theta(\cdot)$ 和 $R(\cdot)$ 均采用平滑修正的有限值函数 (35), 以避免有限值激活函数 $s(\cdot)$ 在零点附近的高梯度放大误差而导致机械臂速度突变。图 13 给出了采用式 (9) 和式 (35) 所得的机械臂角速度轨迹。可以看出, 平滑修正后的有限值函数 (35) 能有效解决机械臂关节速度突变的问题。




图 13 函数 (9) 与平滑修正后的函数 (35) 所得机械臂的角速度
Fig. 13 Manipulator angular velocity obtained by function (9) and smoothed function (35)

下面进一步验证基于终态优化指标的冗余机械臂重复运动规划方案 (TOC-TZNN) 在实际机械臂上的应用效果。将 QOC-ZNN, QOC-TZNN 和 TOC-TZNN 方案用于实际机械臂 UR5, 以执行圆形平面轨迹的规划任务。实验平台如图 14 所示。




图 14 实验中所用冗余机械臂 UR5

Fig. 14 Redundant manipulator UR5 used in experiment

为更好地记录实验结果, 期望轨迹采用二维平面轨迹, 轨迹直径为 16cm, 圆面平行于 XY 平面, 末端执行器完成圆形轨迹时间 $T=10$ s。设 UR5 机械臂期望回拢角 $\theta_d(0) = [-\pi/2, -\pi/2, -\pi/2, -\pi/2, \pi/2, 0]^T$ rad, 机械臂实际关节角初值为 $\theta(0) = \theta_d(0) + \Delta\theta(0)$, 其中 $\Delta\theta(0) = [-0.05, 0, 0, 0, 0, 0]^T$ rad。实验参数选取与仿真一致, 实验结果如图 15 所示。从图中易看出, 在初始关节偏移的情况下, TOC-TZNN 方案的冗余机械臂末端位置误差收敛速度快, 期望轨迹跟踪任务的完成度更高。




图 15 UR5 末端执行器的运动过程

Fig. 15 Movement of end-effector of UR5

结束语 本文提出一种有限时间收敛的有限值终态零化神经网络来求解时变二次规划问题。针对初始偏差下的冗余机械臂重复运动规划问题,提出一种定参数/自适应参数终态优化指标,采用有限值终态零化神经网络方法求解,可在改善机械臂关节回拢精度的同时实现末端执行器位置误差的有限时间收敛,并理论分析了所提网络的有限时间收敛性。为保证机械臂的平稳运行,提出平滑修正的有限值函数用于终态优化指标。基于冗余机械臂 UR5 开展了 QOC-ZNN, QOC-TZNN 以及 TOC-TZNN 3 种方案的重复运动规划仿真与实验,结果验证了 TOC-TZNN 方案的有效性。

参 考 文 献

- [1] ZHANG Y N,JIANG D C,WANG J. A recurrent neural network for solving Sylvester equation with time-varying coefficients [J]. *IEEE Transactions on Neural Networks*, 2002, 13(5):1053-1063.
- [2] JOHANSEN T A,FOSSEN T I,BERGE S P. Constrained nonlinear control allocation with singularity avoidance using sequential quadratic programming[J]. *IEEE Transactions on Control Systems Technology*,2004,12(1):211-216.
- [3] LEITHEAD W E,ZHANG Y. $O(n^2)$ -operation approximation of covariance matrix inverse in gaussian process regression based on quasi-newton BFGS method[J]. *Communications in Statistics Simulation and Computation*,2007,524:216-228.
- [4] ZHANG Y N,GE S S. A general recurrent neural network model for time-varying matrix inversion[C]// *Proceedings of the 42nd IEEE Conference on Decision and Control Maui, Hawaii USA*,2003:6169-6174.
- [5] XIAO X C,JIANG C Z,LU H Y, et al. A parallel computing method based on zeroing neural networks for time-varying complex-valued matrix Moore-Penrose inversion [J]. *Information Sciences*,2020,36(2):367-380.
- [6] XIAO L,ZHANG Y N,HU Z S, et al. Performance benefits of robust nonlinear zeroing neural network for finding accurate solution of Lyapunov equation in presence of various noises [J]. *IEEE Transactions on Industrial Informatics*,2019,15(9):5161-5171.
- [7] ZHANG Z J,LU Y Y,ZHENG Y Y, et al. A new varying-parameter convergent-differential neural-network for solving time-varying convex QP problem constrained by linear-equality[J]. *IEEE Transactions on Automatic Control*,2018,63(12):4110-4125.
- [8] ZHANG Y N,GE S S. Design and analysis of a general recurrent neural network model for time-varying matrix inversion[J]. *IEEE Transactions on Neural Networks*, 2005, 13(5): 1053-1063.
- [9] LI S,CHEN S F,LIU B. Accelerating a recurrent neural network to finite-time convergence for Solving time-varying Sylvester equation by using a Sign-Bi-power activation function[J]. *Neural Processing Letters*,2013,37(2):189-205.
- [10] GUO D S,ZHANG Y N. Li-function activated ZNN with finite-time convergence applied to redundant-manipulator kinematic control via time-varying Jacobian matrix pseudoinversion[J]. *Applied Soft Computing*,2014,24:158-168.
- [11] LU H Y,JIN L,LUO X, et al. RNN for solving perturbed time-varying underdetermined linear system with double bound limits on residual errors and state variables[J]. *IEEE Transactions on Industrial Informatics*,2019,15(11):5931-5942.
- [12] JIN L,LIU F Y,LU H Y, et al. Saturation-allowed neural dynamics applied to perturbed time-dependent system of linear equations and robots[J]. *IEEE Transactions on Industrial Electronics*,2021,68(10):9844-4854.
- [13] SHAMIR T,YOMDIN Y. Repeatability of redundant manipulators; mathematical solution of the problem[J]. *IEEE Transactions on Automatic Control*,1988,33(11):1001-1009.
- [14] ZHANG Y N,TAN Z G,CHEN K, et al. Repetitive motion of redundant robots planned by three kinds of recurrent neural networks and illustrated with a four-link planar manipulator's straight-line example[J]. *Robotics and Autonomous Systems*, 2009,57(6/7):645-651.
- [15] ZHANG Y N,ZHANG Z J. Design and experimentation of acceleration-level drift-free scheme aided by two recurrent neural networks[J]. *IET Control Theory & Applications*,2013,7(1):25-42.
- [16] KLEIN C A,HUANG C H. Review of pseudoinverse control for use with kinematically redundant manipulators [J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1983, SMC-13(3):245-250.
- [17] KRZYSZTOF T,ADAM R,IDA G. Lagrangian Jacobian inverse for nonholonomic robotic systems [J]. *Nonlinear Dynamics*, 2015,82(4):1923-1932.
- [18] LIAO B L,LIU W. Pseudoinverse-Type Bi-Criteria Minimization Scheme for Redundancy Resolution of Robot Manipulators[J]. *Robotica*,2015,33(10):2100-2113.
- [19] ZHANG P C,REN X H,ZHANG Z J. An efficient self-motion scheme for redundant robot manipulators:a varying-gain neural self-motion approach[J]. *Robotica*,2021,39(10):1897-1908.
- [20] DANIEL E W. Resolved motion rate control of manipulators and human prostheses[J]. *IEEE Transactions on Systems, Man, and Cybernetics; Systems*,1969,MMS-10(2):47-53.
- [21] CHENG F T,CHEN T H,SUN Y Y. Resolving manipulator redundancy under inequality constraints[J]. *IEEE Journal on Robotics and Automation*,1994,10(1):65-71.
- [22] TAROKH M,ZHANG X M. Real-time motion tracking of robot manipulators using adaptive genetic algorithms[J]. *Journal of Intelligent & Robotic Systems*,2014,74(3):697-708.
- [23] LIU F,HUANG H L,LI B. A parallel learning particle swarm optimizer for inverse kinematics of robotic manipulator[J]. *International Journal of Intelligent Systems*,2021,36(10):6101-6132.

- [24] LI S, ZHANG Y N, JIN L. Kinematic control of redundant manipulators using neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28 (10): 2243-2254.
- [25] ZHANG Y N, WANG J, XIA Y S. A dual neural network for redundancy resolution of kinematically redundant manipulators subject to joint limits and joint velocity limits [J]. IEEE Transactions on Neural Networks, 2003, 14(3): 658-667.
- [26] XIAO L, ZHANG Y S, DAI J H, et al. A new noise-tolerant and predefined-time ZNN model for time-dependent matrix inversion [J]. Neural Networks, 2019, 117(1): 124-134.
- [27] HU Z S, XIAO L, DAI J J, et al. A unified predefined-time convergent and robust ZNN model for constrained quadratic programming [J]. IEEE Transactions on Industrial Informatics, 2021, 17(3): 1998-2010.
- [28] SUN M X, ZHANG Y, WU Y X, et al. On a finitely activated terminal RNN approach to time-variant problem solving [J].

IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(12): 7289-7302.



WANG Liming, born in 1996, doctoral student. His main research interests include neural computing and robot path planning.



ZHONG Guomin, born in 1983, Ph.D., lecturer. His main research interests include system identification, iterative learning control, and neural computing.

(责任编辑:柯颖)

“多模态手写签名识别与鉴别关键技术及应用”科技成果 鉴定会在线上举行

3月25日,新疆大学、华南理工大学等单位完成的“多模态手写签名识别与鉴别关键技术及应用”科技成果鉴定会在线上举行。

鉴定委员会由 CCF 会士、中国科学院院士、北京大学梅宏教授担任主任委员。中国工程院院士、中南大学桂卫华教授, CCF 会士、副理事长、中国科学院院士、清华大学胡事民教授, CCF 虚拟现实专委会主任、北京理工大学王涌天教授, CCF 会士、人工智能与模式识别专委会主任、山西大学梁吉业教授, 南京邮电大学刘青山教授, 北京科技大学殷绪成教授, CCF 常务理事、北京师范大学黄华教授, CCF 会士、中国科学院软件研究所张健研究员担任委员。CCF 会士、中国工程院院士、新疆大学吾守尔·斯拉木教授出席鉴定会, 并代表完成单位致辞。出席本次会议的项目组成员有 CCF 常务理事、新疆大学库尔班·吾布力教授、阿力木江·艾沙教授、徐学斌老师, 华南理工大学金连文教授、康文雄教授等。

库尔班·吾布力教授代表成果团队汇报项目的研制报告、技术总结报告、查新报告和应用报告。北京科技大学殷绪成教授宣读测试意见和测试组名单, 南京邮电大学刘青山教授宣读资料审查报告和资料审查组名单。成果团队分别演示了多文种离线手写签名识别与鉴别系统、多文种在线手写签名识别与鉴别系统、空中签名识别与鉴别系统以及视听多模态手写签名识别与鉴别系统软件。

该成果由新疆大学、华南理工大学、华云(河北雄安)大数据科技有限公司、乌鲁木齐市公安局刑事侦查支队、新疆恒正司法鉴定中心等单位共同完成, 研究从 2011 年至今历时 14 年。成果提出了多种适用于维、哈、柯文签名的局部和全局特征, 设计了特征融合和特征匹配的策略, 实现了维、哈、柯签名的自动识别与鉴别; 提出了一种基于深度学习的动态签名验证框架 Syn-Sig2Vec, 无需训练即可发现熟练伪造者攻击; 提出了一种基于视听技术和深度学习的多模态手写签名验证方法 MMHSV, 进一步提升了识别与鉴别的准确率。成果构建了融合在线录入、离线采集和空中签名轨迹的多模态签名数据集, 开发了系列软件, 取得了软件著作权 21 项, 获得授权发明专利 11 项, 发表学术论文 70 余篇, 出版专著 2 部。项目研究过程中, 培养博士生 2 人, 硕士生 32 人, 青年教师 8 人; 指导学生多次在学科竞赛中获得佳绩包括三项国际学科竞赛 3 项冠军。项目成果在乌鲁木齐市公安局刑侦支队、新疆恒正司法鉴定中心、新疆法团律师事务所等 10 多家公安刑侦、司法鉴定中心、律师事务所及企业推广使用, 经济和社会效益显著。

经质询讨论, 鉴定委员会认为, 项目在多模态手写签名(尤其是新疆少数民族多文种签名)识别与鉴别方面取得了创新性成果, 具有自主知识产权, 整体技术达到国际先进水平, 其中基于视频的空中签名鉴别技术、视听多模态签名识别与鉴别技术达到国际领先水平, 同意通过科技成果鉴定。

CCF 对被评级成果出具鉴定证书, 可作为项目验收、科技奖励申报、科技成果登记、新产品税收优惠、科技计划立项、生产许可证审批、技术转让、科技成果宣传推广、资产评估和知识产权等的依据, 详情可邮件或电话咨询。欢迎各高校、科研院所、企业和个人积极申请科技成果评价。