

具有速度突变抑制的全向移动机器人视觉伺服预测控制

林叶贵, 戴志坚, 何德峰, 邢科新

引用本文

林叶贵, 戴志坚, 何德峰, 邢科新. 具有速度突变抑制的全向移动机器人视觉伺服预测控制[J]. 计算机科学, 2024, 51(11A): 240300003-6.

LIN Yegui, DAI Zhijian, HE Defeng, XING Kexin. Visual Servoing Predictive Control for Omnidirectional Mobile Robots with Suppression of Velocity Abrupt Change [J]. Computer Science, 2024, 51(11A): 240300003-6.

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)

[一种融合激光与视觉的轻量级地貌地图构建方法](#)

Lightweight Terrain Map Building Approach Combining Laser and Vision

计算机科学, 2024, 51(11A): 240400051-9. <https://doi.org/10.11896/jsjcx.240400051>

[基于策略融合及Spiking DRL的移动机器人路径规划方法](#)

Mobile Robots' Path Planning Method Based on Policy Fusion and Spiking Deep Reinforcement Learning

计算机科学, 2024, 51(11A): 240100211-11. <https://doi.org/10.11896/jsjcx.240100211>

[基于改进自适应蚁群算法的移动机器人路径规划](#)

Path Planning for Mobile Robots Based on Modified Adaptive Ant Colony Optimization Algorithm

计算机科学, 2024, 51(6A): 230500145-9. <https://doi.org/10.11896/jsjcx.230500145>

[非结构化场景下的无人车轨迹规划研究](#)

Study on Unmanned Vehicle Trajectory Planning in Unstructured Scenarios

计算机科学, 2024, 51(4): 334-343. <https://doi.org/10.11896/jsjcx.221200079>

[基于人工势场的A*算法的移动机器人路径规划](#)

Path Planning of Mobile Robot with A* Algorithm Based on Artificial Potential Field

计算机科学, 2021, 48(11): 327-333. <https://doi.org/10.11896/jsjcx.200900170>

具有速度突变抑制的全向移动机器人视觉伺服预测控制

林叶贵 戴志坚 何德峰 邢科新

浙江工业大学信息工程学院 杭州 310023

(lyg@zjut.edu.cn)

摘要 在全向移动机器人视觉伺服任务过程中,为了解决由特征点的变化、车轮打滑、动态障碍等情况导致的速度突变问题,提出了一种基于神经动力学的 quasi-min-max MPC 视觉伺服策略。因为视觉误差的突变是引起速度突变的主要原因,所以该策略引入神经动力学模型对视觉误差进行处理,建立基于神经动力学的移动机器人视觉伺服线性参数时变预测模型,采用 quasi-min-max MPC 策略获得最优速度解,从而抑制速度的突变,最终保证移动机器人能够以一个平滑的速度到达期望位姿。仿真结果验证了所提策略在抑制速度突变上的有效性。

关键词 移动机器人;视觉伺服;神经动力学;quasi-min-max MPC

中图分类号 TP242

Visual Servoing Predictive Control for Omnidirectional Mobile Robots with Suppression of Velocity Abrupt Change

LIN Yegui, DAI Zhijian, HE Defeng and XING Kexin

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

Abstract During the visual servoing task of omnidirectional mobile robot, in order to solve the problem of sudden change of speed caused by the change of feature points, wheel slippage, dynamic obstacles and other situations, this paper proposes a neurodynamics-based visual servoing strategy for quasi-min-max MPC. Because the sudden change of visual error is the main cause of the sudden change of speed, the strategy deals with the visual error by introducing a neurodynamics model. A neurodynamics-based time-varying prediction model for the linear parameters of the visual servo of the mobile robot is established, and the quasi-min-max MPC strategy is used to obtain the optimal velocity solution, thus suppressing the sudden changes in velocity. Ultimately, it is ensured that the mobile robot can reach the desired position with a smooth velocity. Simulation results verify the effectiveness of the proposed strategy in suppressing the velocity mutation.

Keywords Mobile robot, Vision servoing, Neurodynamics, Quasi-min-max MPC

1 引言

在轮式移动机器人(Wheeled Mobile Robot, WMR)中,视觉伺服是一个重要的研究课题^[1],其目的是通过图像等视觉信息来引导 WMR 到达目标姿态。近年来,国内外学者提出了多种用于稳定 WMR 视觉伺服系统的方法。文献[2]提出了基于图像的自适应控制器,以完成 WMR 的位置控制。文献[3]考虑到移动机器人中心未安装摄像头的情况,提出一种基于视觉的自适应轨迹跟踪方法,并设计了一种两阶段切换轨迹跟踪控制率来解决机器人轨迹跟踪问题;文献[4]提出一种用于解耦 IBVS 的模糊自适应方法,通过提高图像特征检测的精度来将近似误差降到最低。

但是在视觉伺服系统中,摄像头的视野范围是有限的,同时 WMR 自身也有约束需要满足。以上研究方法并没有从自身的约束进行考虑。模型预测控制(Model Predictive Control, MPC)作为一种能够有效处理约束的方法,在视觉伺服中得到了广泛的应用^[5-6]。例如,文献[7]设计了一种结合强化学习和模型预测控制的混合控制方案,用于处理具有可视性状态约束和执行器输入约束的 WMR 视觉伺服问题;文献

[8]采用非线性模型预测控制方法,确保移动机器人停留在全局摄像头的视野范围内完成轨迹跟踪控制;文献[9]开发了一种新的基于视觉伺服的模型预测控制方法,解决了 WMR 在极坐标系下的控制问题;文献[10]提出了一种同时考虑可见性约束和执行器限制,并采用非线性模型预测控制的动态预测控制器。相应地,考虑到 WMR 视觉伺服系统在实际运动过程中会受到很多不确定因素的影响,如光照变化与摄像头振动产生的图像噪声等,因此有学者设计相应的鲁棒 MPC 来进行 WMR 视觉伺服。如文献[11]提出了基于最小二乘法的鲁棒 MPC 控制器,引导移动机器人完成视觉轨迹跟踪;文献[12]提出了一种新的 quasi-min-max MPC 视觉伺服方案,用于在速度和可见性约束下的 WMR 视觉伺服镇定任务。

虽然上述方法一定程度上解决了约束条件下的视觉伺服问题,但是在实际的视觉伺服任务中,WMR 会因特征点的变化、车轮打滑、动态障碍、初始误差过大等不确定因素出现速度突变的情况。而由于 WMR 电机输出扭矩的限制,所求出的不切实际的速度在现实中很难达到^[13],进而导致传统控制方法在实际操作中失效。针对速度跳变问题,近年来也有学者对其进行了研究。例如,文献[14]提出了一种动态控制器,

通过使用反步设计方法生成转矩信号。然而这需要车辆的非线性和复杂的动力学。神经网络方法是处理大速度跳跃的有效方法,但是,这种方法需要计算复杂的在线学习。因此,这种方法的实施成本相当高^[15-17]。而神经动力学作为一种能够有效处理变量突变问题的模型,相比其他方法,有着参数要求较低的优势,并且不需要训练即可使用,实施成本相对较低,因此受到学者的广泛关注。例如,文献[18]引入一种仿生方法,采用神经动力学模型替代滑模控制器中的非线性饱和函数,解决了滑膜控制方案中的高频抖振问题;文献[19]提出一种基于神经动力学模型的水下航行器混合控制策略,相对于传统控制方法速度指令更加平滑;文献[20]将神经动力学与反步控制器相结合并与无迹卡尔曼滤波集成在一起,设计了一种能够提供平滑的速度指令,并具有一定鲁棒性的控制器;文献[21]借助神经动力学解决了传统反步法和滑膜控制中分别存在的速度跳变和抖振问题,并顺利完成跟踪任务。

由此可见,神经动力学在解决速度跳变问题上已经得到了广泛使用,但是将神经动力学与 quasi-min-max MPC 相结合应用于 WMR 的视觉伺服控制鲜有研究。受此启发,本文提出了一种新的基于神经动力学的 quasi-min-max MPC 视觉伺服方案,用于执行器约束和可见性约束下的 WMR 的视觉伺服控制,并解决 WMR 在控制过程中出现的速度跳变问题。首先对 WMR 的非线性视觉伺服系统进行运动学建模,对其中的视觉误差信号采用神经动力学的方法来处理,构成新的视觉伺服误差模型,之后将 WMR 的视觉伺服问题转化成 LMI 形式的凸优化问题,通过求解该优化问题来获取 WMR 的实际控制输入。

本文的主要贡献如下:

1) 针对 WMR 视觉伺服过程中特征点的变化、车轮打滑、动态障碍、轨迹突变等情况所导致的速度突变情况,推导出了—种新的基于神经动力学的视觉伺服误差模型。

2) 为解决 WMR 的速度跳变问题,设计了一种基于神经动力学的视觉伺服 quasi-min-max MPC 控制策略。

3) 通过实验仿真,验证了本文设计的基于神经动力学的 quasi-min-max MPC 控制算法的可行性和有效性。

本文第 2 章给出了麦克纳姆轮 WMR 的神经动力学的视觉伺服误差模型;第 3 章介绍了一种基于神经动力学的 quasi-min-max MPC 控制算法;第 4 章对算法进行了仿真验证;最后总结全文。

2 问题描述

2.1 WMR 的运动学模型

本文采用的是基于麦克纳姆轮的全向轮式移动机器人,其特点是能够实现全方位运动并绕自身重心进行零半径旋转,如图 1 所示,建立了二维坐标系 $X_w O_w Y_w$ 下的运动学模型。 v_x 和 v_y 分别表示全向移动机器人的纵向线速度和横向线速度, ω 表示全向移动机器人的角速度。 θ 表示世界坐标系 X_w 到机器人坐标系 X_r 的夹角,即航向角。具体参数如图 1 所示。给出移动机器人运动学方程:

$$\dot{s}(t) = R(\theta)q(t) \quad (1)$$

$$R(\theta) = \begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (2)$$

其中, $s(t) = [x(t) \ y(t) \ \theta(t)]^T$,表示全向移动机器人质心在世界坐标系 X_w - Y_w 平面的坐标。




图 1 全向轮式移动机器人

Fig. 1 Omnidirectional wheeled mobile robot

根据速度正交分解的关系,求解出全向 WMR 车轮转速与机器人速度之间的关系^[12]。

$$u_w = J(\theta)q(t) \quad (3)$$

其中, $u_w = [\omega_1 \ \omega_2 \ \omega_3]^T$,表示机器人车轮的角速度; L 表示机器人中心点到轮子中心的距离; $J(\theta)$ 表示机器人速度与车轮速度之间的转换矩阵^[22],具体形式如下:

$$J(\theta) = \frac{1}{R} \begin{bmatrix} -\sin\theta & \cos\theta & L \\ -\sin\left(\theta + \frac{2\pi}{3}\right) & \cos\left(\theta + \frac{2\pi}{3}\right) & L \\ -\sin\left(\theta + \frac{4\pi}{3}\right) & \cos\left(\theta + \frac{4\pi}{3}\right) & L \end{bmatrix} \quad (4)$$

2.2 基于神经动力学的视觉伺服误差模型

为解决单目相机无法测量深度的问题,引入新的误差信号向量^[12]如下:

$$\begin{bmatrix} e_1 \\ e_2 \\ e_3 \end{bmatrix} = \begin{bmatrix} \frac{x_p}{y_p} \\ \frac{f}{y_p} \\ \theta \end{bmatrix} - \begin{bmatrix} \cos\theta_e & -\sin\theta_e & 0 \\ \sin\theta_e & \cos\theta_e & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \frac{x_{pd}}{y_{pd}} \\ -\frac{f}{y_{pd}} \\ \theta_d \end{bmatrix} \quad (5)$$

其中, (x_{pd}, y_{pd}) 表示特征点 P 在图像物理坐标系下的期望坐标; θ_d 表示机器人的期望航向角; θ_e 表示机器人航向角的误差,且满足 $\theta_e = \theta - \theta_d$ 。

对式(5)进行微分,并结合运动学模型(1),全方位移动机器人视觉伺服误差模型描述如下:

$$\dot{e} = M(e)q(t) \quad (6)$$

$$M(e) = \begin{bmatrix} -\frac{1}{Z_c} & 0 & -e_2 \\ 0 & \frac{1}{Z_c} & e_1 \\ 0 & 0 & 1 \end{bmatrix} \quad (7)$$

其中, Z_c 表示特征点的高度。从式(7)可以看出矩阵 $M(e)$ 实际上是关于误差 e 呈线性关系。

受神经动力学能够抑制变量产生较大跳变的启发,引入神经动力学以处理视觉伺服误差的突变问题,一般的神经动力学模型如下^[23]:

$$\frac{dx_i}{dt} = -Ax_i + (B - x_i)S_i^+(t) - (D + x_i)S_i^-(t) \quad (8)$$

令 $x_i = E_i$, $S_i^+ = f(e_i)$, $S_i^- = g(e_i)$,对于神经动力学模型(8),可以改写为:

$$\frac{dE_i(t)}{dt} = -A_i E_i(t) + (B_i - E_i(t))f(e_i) - (D_i + E_i(t))g(e_i) \quad (9)$$

$$\begin{cases} f(e_i) = \max(0, e_i) \\ g(e_i) = \max(-e_i, 0) \end{cases} \quad (10)$$

其中, A_i 表示对应误差信号向量中 e_i 的被动衰减率, B_i 和 D_i 分别表示对应误差信号向量中 e_i 的上下界, A_i , B_i 和 D_i 均大于 0; $f(e_i)$ 和 $g(e_i)$ 分别为对应误差信号向量中 e_i 的上界限线性函数和下界限线性函数。通过上述模型的处理, 每个误差的跳变被限制在相应误差信号向量的 $[-D_i, B_i]$ 范围内^[24]。

使用经过神经动力学模型处理过后的误差信号向量 $\mathbf{E} = [E_1 \ E_2 \ E_3]^T$ 代替误差信号向量 $\mathbf{e} = [e_1 \ e_2 \ e_3]^T$, 则基于神经动力学的视觉伺服误差模型为:

$$\dot{\mathbf{E}} = \mathbf{M}(\mathbf{E})\mathbf{q}(t) \quad (11)$$

相应的控制系统的约束应为:

$$E_{1\min} \leq E_1 \leq E_{1\max}, E_{2\min} \leq E_2 \leq E_{2\max} \quad (12a)$$

$$\omega_{i\min} \leq \omega_i \leq \omega_{i\max}, i = 1, 2, 3 \quad (12b)$$

其中, 式(12a)表示的是视觉可见性约束, 即特征点必须在相机的视野范围内; 式(12b)表示的是执行器物理约束, 即车轮所能达到的最大速度和最小速度。

因此, 本文的控制任务是在满足视觉可见性约束(12a)和机器人执行器物理约束(12b)的情况下, 驱动全向移动机器人到达期望位姿, 即使误差 $e \rightarrow 0$, 此时全向移动机器人停止运动, 即速度 $q \rightarrow 0$, 并且保证在控制过程中初始速度为零且不会发生速度跳变。

3 一种基于神经动力学的 quasi-min-max MPC 算法

3.1 基于神经动力学的 quasi-min-max MPC 控制算法设计

针对基于神经动力学的视觉伺服误差模型, 取采样时间为 T_s , 则离散形式下的基于神经动力学的视觉伺服误差模型如下:

$$E(k+1) = E(k) + \mathbf{M}(E(k))J^{-1}(\theta)u_w \quad (13)$$

其中, 矩阵 $\mathbf{M}(E(k))$ 为:

$$\mathbf{M}(E(k)) = \begin{bmatrix} -\alpha T_s & 0 & -E_2(k)T_s \\ 0 & \alpha T_s & E_1(k)T_s \\ 0 & 0 & T_s \end{bmatrix}$$

定义函数 $f_w(u_w) = J^{-1}(\theta)u_w$, 则式(13)改写为:

$$E(k+1) = E(k) + \mathbf{M}(E(k))f_w(u_w) \quad (14)$$

函数 $f_w(u_w)$ 为一个静态的非线性函数, 则该视觉伺服误差模型是一个时变 Hammerstein 系统^[25]。令 $u_d = f_w(u_w)$, 则式(14)实际上是一个线性时变动态模型。

$$E(k+1) = E(k) + \mathbf{M}(E(k))u_d \quad (15)$$

考虑基于神经动力学的全向移动机器人视觉伺服误差模型(15)以及相应的约束(12), 可以定义无穷预测时域下的目标函数为:

$$J_0^\infty(k) = \sum_{i=0}^{\infty} E(i|k)^T \mathbf{Q} E(i|k) + u_d(i|k)^T \mathbf{R} u_d(i|k) \quad (16)$$

其中, \mathbf{Q} 和 \mathbf{R} 为状态加权矩阵和控制量加权矩阵, 分别代表对状态的惩罚以及对控制量的惩罚。根据以上描述并结合文献[12], 最小化目标函数(16)的优化问题可以等价为在该系统

凸多面体每个顶点的优化, 即:

$$\min_{\gamma, u_d(0|k), \bar{\mathbf{Q}}(k), \mathbf{Y}(k)} \gamma \quad (17a)$$

$$\text{s. t.} \begin{bmatrix} 1 & * & * & * \\ E(0|k) + \mathbf{M}u_d(0|k) & \bar{\mathbf{Q}} & * & * \\ \mathbf{Q}^{0.5} E(0|k) & 0 & \gamma \mathbf{I} & * \\ \mathbf{R}^{0.5} u_d(0|k) & 0 & 0 & \gamma \mathbf{I} \end{bmatrix} \geq 0 \quad (17b)$$

$$\begin{bmatrix} \bar{\mathbf{Q}}(k) & * & * & * \\ \bar{\mathbf{Q}}(k) + \mathbf{M}u_d(0|k) & \bar{\mathbf{Q}}(k) & * & * \\ \mathbf{Q}^{0.5} \bar{\mathbf{Q}}(k) & 0 & \gamma \mathbf{I} & * \\ \mathbf{R}^{0.5} \mathbf{Y}(k) & 0 & 0 & \gamma \mathbf{I} \end{bmatrix} \geq 0 \quad (17c)$$

$$E_{1\min} \leq E_1(0|k) \leq E_{1\max}, E_{2\min} \leq E_2(0|k) \leq E_{2\max} \quad (17d)$$

$$u_{d\min}(k) \leq u_d(0|k) \leq u_{d\max}(k)$$

其中, 符号 * 表示线性矩阵不等式中的对称结构, $j = 1, 2, 3, 4$ 。在每个采样周期优化问题获得最优解 $(\gamma^*, u_d^*(0|k), \bar{\mathbf{Q}}^*(k), \mathbf{Y}^*(k))$, 根据机器人与其轮子之间的速度关系(3)可以得到最优控制量 $u^{mpc}(k)$, 即:

$$u^{mpc}(k) = J(\theta)u_d^*(0|k), i = 1, 2, 3 \quad (18)$$

利用神经动力学处理过后的误差代替原先的误差来进行准最小最大预测控制, 求得此时的控制信号。此时闭环视觉伺服系统(15)可以表示为:

$$E(k+1) = E(k) + \mathbf{M}(E(k))f_w(u^{mpc}(k)) \quad (19)$$

3.2 算法具体步骤

具体的控制过程如下:

步骤 1 选择适当的权重矩阵 \mathbf{Q} 和 \mathbf{R} 。

步骤 2 在 k 时刻, 测量特征点的坐标值并与期望坐标值进行计算, 从而求得当前时刻的误差信号向量 $\mathbf{e} = [e_1 \ e_2 \ e_3]^T$ 。

步骤 3 根据式(9)更新 $E(k)$ 从而更新 $\mathbf{M}(E(k))$ 。

步骤 4 在线求解优化问题式(17)来获得最优解 $u_d^*(k)$ 。

步骤 5 通过式(18)计算控制输出, 将该输出作用到经过神经动力学处理过后的视觉伺服误差系统式(19)求得下一时刻的误差。

步骤 6 令 $k = k+1$ 并回到步骤 2 继续循环直至达到目标姿态。其具体控制框图如图 2 所示。




图 2 视觉伺服控制策略框图

Fig. 2 Block diagram of vision servoing control strategy

4 仿真分析

仿真求解采用 Matlab 2020a 解决, 设计 3 组仿真实验以验证方法的有效性与其可行性。

在本次仿真验证中, 车轮到质心的距离 L 为 0.8 m, 麦克纳姆轮的半径为 0.1 m。图像的分辨率为 640×480 pixels, 并且相机坐标系原点到特征点 P 的高度 Z_c 为 0.4 m。此外机器

人视觉伺服系统满足如下约束:

$$-4.25 \leq e_1(k) \leq 8, -10 \leq e_2(k) \leq 0$$

$$\omega_{\max} = -\omega_{\min} = [50 \text{ rad/s} \ 50 \text{ rad/s} \ 50 \text{ rad/s}]$$

取采样时间 $T_s = 0.2 \text{ s}$, 权重矩阵 $\mathbf{Q} = \text{diag}\{5, 5, 5\}$, $\mathbf{R} = \text{diag}\{0.001, 0.001, 0.001\}$.

4.1 实验 1

为验证本文所提出方法的有效性,设计实验以验证其能够在满足视觉约束的前提下产生平滑的速度指令并完成视觉伺服任务。本次实验中,选取机器人初始位置为 $(-3.2, -4, 0)$, 则机器人的视觉伺服误差为 $(8, -10, 0)$, 神经动力学参数 $A1=A2=4, B1=8, B2=0, D1=4.25, D2=10$ 。实验结果如图 3—图 5 所示。

图 3 给出了特征点轨迹和移动机器人运动轨迹,从右上角的像素坐标图可知 4 个特征点均收敛至期望位置,同时没有超出视野范围。机器人在世界坐标系下的轨迹也收敛至期望位置,可知本文方法很好地满足了跟踪要求以及可见性约束。图 4 给出了车轮转速。分析图 4 可知,移动机器人的速度在初始时刻并未发生跳变而是从零开始,符合实际。同时整体速度曲线的变化较为平滑。分析图 5 视觉伺服误差图可知,本文算法能够使视觉误差收敛至零,且整体曲线变化较为平滑且无跳变。实验 1 的仿真结果证明本文方法能够在满足视觉约束以及机器人物理约束的前提下完成视觉伺服任务,同时能够生成较为平滑的速度指令,可见所提方法的可行性。




图 3 WMR 运动轨迹与特征点轨迹图

Fig. 3 WMR motion trajectory and feature point trajectory diagram




图 4 车轮转速

Fig. 4 Wheel rotation speed




图 5 WMR 视觉伺服误差

Fig. 5 WMR visual servoing error

4.2 实验 2

为了验证本文所采用方法的有效性,设计了对比实验,将本文方法与 quasi-min-max MPC 进行对比。机器人初始坐标为 $(-2, -4, 0)$, 则视觉伺服误差为 $(5, -10, 0)$, 其他参数设置与实验 1 一致,仿真结果如图 6—图 8 所示。其中实线和虚线分别表示本文方法和 quasi-min-max MPC。




图 6 WMR 运动轨迹与特征点轨迹图

Fig. 6 WMR motion trajectory and feature point trajectory diagram

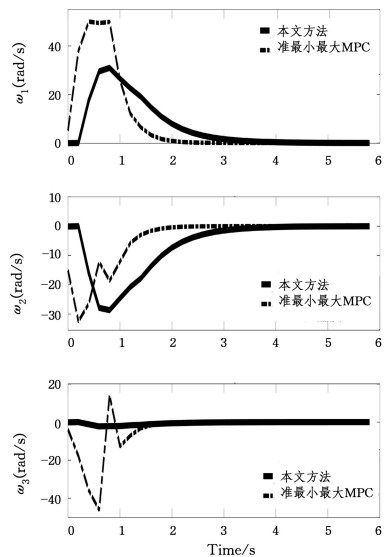


图 7 车轮转速

Fig. 7 Wheel rotation speed

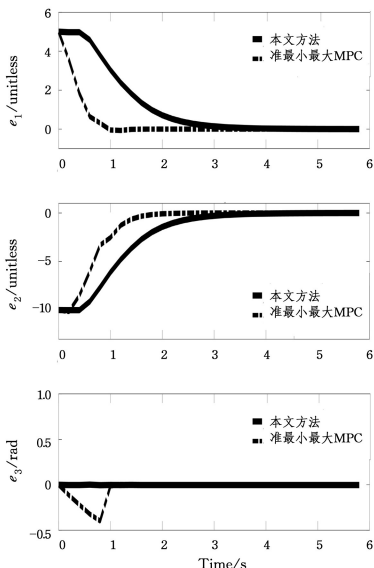


图8 WMR 视觉伺服误差

Fig. 8 WMR visual servoing error

图6给出了特征点轨迹和移动机器人运动轨迹,从右上角的像素坐标图可知4个特征点均收敛至期望位置,同时没有超出视野范围。机器人在世界坐标系下的轨迹也收敛至期望位置,可知本文方法很好的满足了跟踪要求以及可见性约束。图7给出了车轮转速,与没有使用神经动力学的 quasi-min-max MPC 对比可知,本文方法能够使 WMR 的初始速度从 0 开始并且速度变化的幅度比 quasi-min-max MPC 小,且没有发生 0.5 s 和 0.8 s 左右的速度跳变,整体的速度曲线较为平滑。同时分析图 8 可知,视觉伺服误差经过神经动力学模型的处理变化更为平滑,不仅整体的变化幅度更小,而且没有出现 0.8 s 处那样的误差跳变。整体的仿真结果证明了所提方法对视觉伺服误差跳变有着较好的抑制作用,体现了其的有效性。

4.3 实验 3

在实际情况中,WMR 会受到外部的扰动,因此在受扰环境下验证本文方法的有效性十分重要。在实验 2 的仿真环境下,将幅值为 0.1 的随机白噪声添加到控制输入,以此来模拟实际环境中遇到的各类干扰。仿真结果如图 9—图 11 所示。其中实线和虚线分别表示本文方法和 quasi-min-max MPC。

图 9 给出了特征点轨迹和移动机器人运动轨迹,右上角像素坐标图中的黑色方框代表干扰所带来的特征点偏移,但最后依旧能够收敛至期望位置。机器人在世界坐标系下的轨迹也收敛至期望位置,可知本文方法很好地满足了跟踪要求以及可见性约束。




图9 WMR 运动轨迹与特征点轨迹图

Fig. 9 WMR motion trajectory and feature point trajectory diagram

图 10 给出了车轮转速,分析该图可知,车轮转速在干扰的影响下波动上升但不会发生巨大跳变。同时分析图 10 的 WMR 视觉伺服误差可知,即使在干扰作用下,本文方法依旧能够收敛至零且没有剧烈的跳变。整体的仿真结果证明了所提方法能够在受扰环境下完成视觉伺服任务且能够有效抑制速度的突变。

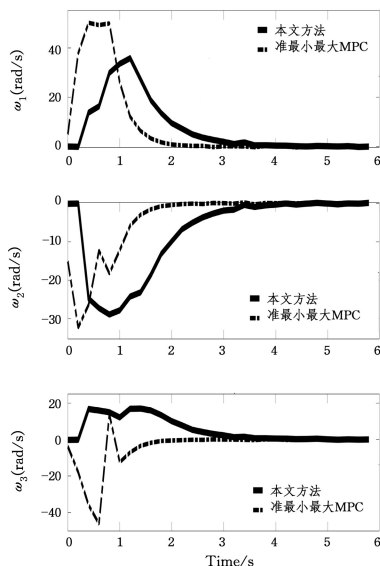


图10 车轮转速

Fig. 10 Wheel rotation speed

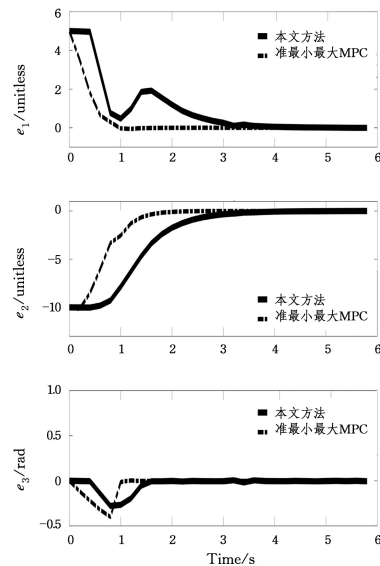


图11 WMR 视觉伺服误差

Fig. 11 WMR visual servoing error

结束语 本文设计的基于神经动力学的视觉伺服预测控制算法,在满足约束的条件下,WMR 以初始速度为零,并以相对平滑的速度完成视觉伺服任务。通过神经动力学模型处理视觉伺服误差,减少速度的突变,极大地提高了系统的稳定性,但是视觉伺服的稳定时间会相应增加。利用仿真实验验证了本文算法的可行性和有效性。后续将对神经动力学模型参数进行自适应研究,从而提高算法的自适应性。

参考文献

[1] NAZARI A A, ZAREINIA K, JANABI-SHARIFI F. Visual ser-

- voing of continuum robots: methods, challenges, and prospects [J]. *The International Journal of Medical Robotics + Computer Assisted Surgery*, 2022, 18: e2384.
- [2] LIANG X, WANG H, LIU Y, et al. Image-based position control of mobile robots with a completely unknown fixed camera[J]. *IEEE Transactions on Automatic Control*. 2018, 63(9): 3016-3023.
- [3] SHAO Z, ZHANG J. Vision-based adaptive trajectory tracking control of wheeled mobile robot with unknown translational external parameters[J]. *IEEE/ASME Transactions on Mechatronics*, 2024, 29(1): 358-365.
- [4] SHI H, XU M, HWANG K. A fuzzy adaptive approach to decoupled visual servoing for a wheeled mobile robot [J]. *IEEE Transactions on Fuzzy Systems*, 2020, 28(12): 3229-3243.
- [5] HE D, HUANG H, CHEN Q. Quasi-min-max mpc for constrained nonlinear systems with guaranteed input-to-state stability[J]. *Journal of the Franklin Institute*. 2014, 351(6): 3405-3423.
- [6] HE D F, DING B C, YU S Y. Review of fundamental properties and topics of model predictive control for nonlinear systems[J]. *Control Theory and Applications*, 2013, 30(3): 273-287.
- [7] WU J, JIN Z, LIU A, et al. A hybrid deep-q-network and model predictive control for point stabilization of visual servoing systems[J]. *Control Engineering Practice*, 2022, 128: 105314.
- [8] BAI H, GAO J, SUN X, et al. Model Predictive Visual Trajectory-Tracking Control of Wheeled Mobile Robots[C]//2019 IEEE 28th International Symposium on Industrial Electronics (ISIE). 2019: 569-574.
- [9] LI Z, YANG C, SU C, et al. Vision-based model predictive control for steering of a nonholonomic mobile robot [J]. *IEEE Transactions on Control Systems Technology*. 2016, 24(2): 553-564.
- [10] CAO Z C, YIN L J, FU Y L, et al. Predictive control for visual servo stabilization of nonholonomic mobile robots[J]. *Acta Automatica Sinica*, 2013, 39(8): 1238-1245.
- [11] LIU A, ZHANG W, YU L. Robust predictive tracking control for mobile robots with intermittent measurement and quantization[J]. *IEEE Transactions on Industrial Electronics (1982)*. 2021, 68(1): 509-18.
- [12] LIN Y G, XING K X, HE D F. Quasi-min-max mpc for visual servoing stabilization of omnidirectional wheeled mobile robots [J]. *Asian Journal of Control*, 2023, 25(3): 1924-1938.
- [13] ZHU D Q, ZHANG G L, LI R. Biological inspired three-dimensional tracking control algorithm for autonomous underwater vehicles[J]. *CAAI Transactions on Intelligent Systems*, 2014, 9(2): 180-185.
- [14] GHOMMAM J, MNIF F, DERBEL N. Global stabilisation and tracking control of underactuated surface vessels[J]. *IET Control Theory & Applications*, 2010, 4(1): 71-88.
- [15] PAN C, LAI X, YANG S X, et al. An efficient neural network approach to tracking control of an autonomous surface vehicle with unknown dynamics[J]. *Expert Systems with Applications*, 2013, 40(5): 1629-1635.
- [16] CHU Z, ZHU D, YANG S X. Observer-based adaptive neural network trajectory tracking control for remotely operated vehicle[J]. *IEEE Transaction on Neural Networks and Learning Systems*, 2017; 28(7): 1633-1645.
- [17] LEE S, JANG W, KIM C. Tracking-by-segmentation using super pixel-wise neural network[J]. *IEEE Access*, 2018, 6: 54982-54993.
- [18] YAN T, XU Z, YANG S X. Consensus formation tracking for multiple AUV systems using distributed bioinspired sliding mode control [J]. *IEEE Transactions on Intelligent Vehicles*, 2023, 8(2): 1081-1092.
- [19] XU Z, YAN T, YANG S X, et al. A hybrid tracking control strategy for an unmanned underwater vehicle aided with bioinspired neural dynamics[J]. *IET Cyber-systems and Robotics*, 2022, 4(3): 153-162.
- [20] XU Z, YANG S X, GADSDEN S A. Enhanced bioinspired backstepping control for a mobile robot with unscented kalman filter [J]. *IEEE Access*, 2020, 8: 125899-125908.
- [21] XU Z, YANG S X, GADSDEN S A, et al. Backstepping and Sliding Mode Control for AUVs Aided with Bioinspired Neurodynamics[C]//2021 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2021: 2113-2119.
- [22] WANG C, LIU X, YANG X, et al. Trajectory tracking of an omni-directional wheeled mobile robot using a model predictive control strategy[J]. *Applied Sciences*, 2018, 8(2): 231.
- [23] GROSSBERG S. Nonlinear neural networks; principles, mechanisms, and architectures [J]. *Neural Networks*, 1988, 1(1): 17-61.
- [24] ZHANG W, WANG H B, SUN F C, et al. Finite-time control of mobile robot systems with unmeasurable angular and linear velocities via bioinspired neurodynamics approach[J]. *Applied Soft Computing*, 2019, 85: 105753.
- [25] HE D F, YU S M. Input-to-state stabilizing model predictive control of multi-variables Hammerstein systems with bounded disturbances[J]. *Control Theory and Applications*, 2019, 36(4): 605-612.



LIN Yegui, born in 1987, Ph. D. His main research interests include model predictive control and visual servoing of mobile robots.



HE Defeng, born in 1979, Ph.D, professor. His research interests include model predictive control and its applications to connected autonomous vehicles.