

DOI: 10.13382/j.jemi.B2307116

基于权重自适应更新径向基函数神经网络的 水下游动机械臂镇定控制*

孙非¹ 曹宇赫² 崔特² 任超²

(1. 天津大学内燃机研究所 天津 300072; 2. 天津大学电气自动化与信息工程学院 天津 300072)

摘要:水下游动机械臂 (underwater swimming manipulator, USM) 是一种由水下蛇形机器人和矢量推进器组成的新型水下机器人。USM 系统具有高度非线性、强耦合以及不确定性等特点,其动力学模型难以精确建立。因此,实现 USM 的高精度镇定控制存在挑战。针对这一问题,本文基于反馈线性化和自适应径向基函数神经网络 (radial basis function neural network, RBFNN),设计了一种动力学控制方案以实现 USM 的镇定控制。首先,介绍了 USM 平台结构,基于 Lagrange 方程给出了 USM 的动力学模型,并推导了 USM 的矢量推力系统模型。然后,设计了基于反馈线性化和 RBFNN 的动力学控制器,并通过反步法自适应更新 RBFNN 的权重。其中,权重自适应更新 RBFNN 用于实时估计系统未建模部分、参数误差以及外部扰动,从而对动力学控制器进行补偿。此外,为了将动力学控制器提供的广义力和力矩转换成各个执行器的控制输入,给出了推力分配策略。最后,进行了湖泊实验,分别对 USM 的 I 构型和 C 构型镇定控制,文章所提出的控制方案在两种构型下的稳态误差均小于 0.08 m 和 10°,验证了所提出的 USM 六自由度镇定控制器的有效性。

关键词:水下游动机械臂;动力学建模;反馈线性化;径向基函数神经网络

中图分类号: TP242

文献标识码: A

国家标准学科分类代码: 510.8050

Stabilization control of underwater swimming manipulator based on radial basis function neural network compensator with adaptive weight updating law

Sun Fei¹ Cao Yuhe² Cui Te² Ren Chao²

(1. Tianjin Internal Combustion Engine Research Institute, Tianjin University, Tianjin 300072, China;

2. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China)

Abstract: The underwater swimming manipulator (USM) is a new type of underwater robot composed of an underwater snake robot and several thrusters. The USM system has the characteristics of high nonlinear and uncertainty, and its dynamic model is difficult to establish accurately. Therefore, it is challenging to achieve high precision stabilization control of USM. To solve this problem, this paper designs a dynamic control framework based on feedback linearization and adaptive radial basis function neural network (RBFNN) for USM stabilization control. Firstly, the structure of the USM platform is introduced, the dynamic model of the USM is established based on the Lagrange equation, and the model of the vector thrust system is derived. Then, a dynamic controller based on feedback linearization and RBFNN is designed, and the weight of RBFNN is updated adaptively by backstepping method. Among them, the weight adaptive updating RBFNN is used to estimate the unmodeled part of the system, parameter errors and external disturbances, so as to compensate the dynamics controller. In addition, in order to convert the generalized forces and torques provided by the dynamic controller into the control inputs of each actuator, a thrust distribution strategy is given. Finally, lake experiments are carried out to stabilize the I-shape and C-shape of USM respectively. Compared with traditional methods, the steady-state errors of the proposed control scheme under both configurations are less than 0.08 m and 10°, which verifies the effectiveness of the proposed 6-DOF USM stabilization controller.

Keywords: underwater swimming manipulator; dynamic modeling; feedback linearization; radial basis function neural network

收稿日期: 2023-12-09 Received Date: 2023-12-09

* 基金项目: 国家自然科学基金 (62073235) 项目资助

0 引言

水下游泳机械臂 (underwater swimming manipulator, USM) 是一种新型的水下机器人^[1], 由水下蛇形机器人和矢量推进器构成。USM 的各个模块通过关节铰接, 每个关节都有一个自由度。其结构优势使 USM 能够在狭窄的环境中移动, 连接到连杆上的推进器增强了 USM 的灵活性^[2]。与传统的水下机器人相比, USM 具有更高的环境适应性, 可以执行更具挑战性的任务。

实现 USM 的高精度控制是完成水下巡检、维修等任务的前提。由于水环境带来的外部扰动以及水动力参数实时变化等因素的影响, USM 是一个具有复杂不确定性的系统, 这对实现其镇定控制带来挑战^[3]。

到目前为止, 在现有的文献中, 针对 USM 的研究主要由挪威科技大学研究团队开展。在 2016 年, Sverdrup-Thygeson 等^[4]提出了 USM 的概念, 建立了水平二维平面的运动学和动力学模型, 并提出了一种简单的直线路径跟随控制方法, 开启了 USM 研究的先河。Sverdrup-Thygeson 等^[5]提出了 USM 控制框架, 在假设其动力学控制器可以精准跟踪控制输入的条件下, 以基座悬停作为次级任务, 基于奇异鲁棒任务优先级算法生成广义坐标期望轨迹, 实现了末端执行器的轨迹跟踪。2017 年, Sverdrup-Thygeson 等^[6]综合并拓展了其先前的研究内容, 详细建立了 USM 的运动学模型、推进器推力分配模型和动力学模型; 在假定模型精确已知的前提下, 提出了一种基于反馈线性化的水下游动机械臂运动控制方案, 并进行了仿真验证。Amundsen 等^[7]基于广义雅可比矩阵方法, 提出了不单独控制水下游动机械臂基座的运动学控制方法。自 2017 年起, 在 USM 系统构型保持不变的情况下, Borlaug 等^[8]设计了高阶滑模观测器 (higher-order sliding mode observer, HOSMO) 实现状态估计。在此基础上, 分别基于超螺旋算法^[9]、广义超螺旋算法^[9]、带有自适应增益的超螺旋算法^[10]实现了动力学控制器设计, 并且在 2021 年使用 Eelume 2020 样机进行了验证^[11-12]。此外, 国内外其他高校及研究机构也在进行 USM 的研究, Kumar 等^[13]设计和实现一种自适应推力分配算法, 最大限度地提高 USM 运行效率, Zhang 等^[14]对 USM 现有的运动学和动力学模型进行完善, 并通过仿真验证了机器人的多模态游泳行为。这些算法大多数依赖于准确的动力学模型。实际情况下, USM 动力学模型难以精确获得, 从而导致控制器性能不足, 难以适用于实际工程环境。

神经网络能够逼近任意非线性函数, 因此可以用来解决具有无法精确获得模型与未知外部干扰等特性的水下机器人控制问题。其中, 径向基函数神经网络 (radial

basis function neural network, RBFNN) 是 Moody 和 Darken 在 20 世纪 80 年代提出的一种单隐层的三层前馈神经网络。这种结构的神经网络能够以任意精度逼近任意连续函数, 具有全局逼近能力, 从而解决了传统神经网络的局部最优问题; 而且拓扑结构紧凑, 结构参数可实现分离学习, 收敛速度快, 已被广泛应用于非线性系统的控制器设计。Cuong 等^[15]成功地将神经网络用于离线或在线逼近水下机器人的高度非线性动力学, 为了减少计算量, 不是用一个大型神经网络来学习整个动力学, 而是将动力学的复杂性划分为较小的网络。Son 等^[16]设计了一种改进的 PID 神经网络控制器, 能够实现水下机器人在垂直面内深度和俯仰角的全局控制, 克服了饱和区过大的问题, 实现良好的动态性能的同时又能够适应不同的学习速率和网络初始权重; Yen 等^[17]提出了一种基于神经网络遗传算法的滑模控制器, 采用投影算法和 Lyapunov 稳定性定理推导出了网络参数自适应调整算法, 保证了网络的收敛性和稳定性。因此, 本文拟结合 RBFNN, 实时估计系统未建模部分、水动力参数误差以及水环境变化引起的外部扰动, 从而提高控制器的性能。

本文主要内容如下, 首先介绍自主研究设计的 USM 平台, 基于 Lagrange 方程给出 USM 动力学模型, 并推导 USM 的矢量推力系统模型。然后, 基于反馈线性化和 RBFNN, 设计一种动力学控制器, 用于实现 USM 的镇定控制, 并通过反步法给出 RBFNN 的权重自适应更新律。权重自适应更新 RBFNN 可以估计系统未建模部分、建模误差以及外部扰动, 从而对动力学控制器进行补偿。此外, 为了将动力学控制器提供的广义力和力矩转换成各个执行器的控制输入, 给出推力分配策略。最后, 通过湖泊实验, 针对两种不同的 USM 构型, 分别进行 USM 末端执行器的六自由度镇定控制实验, 来证明所提控制方法的有效性。

1 平台介绍及系统动力学建模

1.1 水下游动机械臂平台介绍

在挪威科技大学研究团队研发的样机 Eelume 2016 与 Eelume 2020 基础上, 本文提出了一种新型的 USM 设计方案 USM TJU-1, 如图 1 所示。该平台由头部模块、通用关节模块、矢量推进器模块与尾部模块组成, 各模块之间通过关节铰接连接, 每个关节均具有一个自由度。其中, 矢量推进器模块由旋转壳体 and 矢量推进器组成, 壳体可以绕连杆的轴线旋转, 单个矢量推进器模块安装了两个矢量推进器, 这两个推进器可以轴向旋转来调整自身角度。本文采用的 USM 由 1 个头部模块, 2 个矢量推进器模块和 1 个尾部模块组成, 由 3 个关节铰接连接。为遵循机器人学中的惯例, 在本文后续部分, 称 USM 的尾

部连杆为基座,称头部连杆为末端执行器。

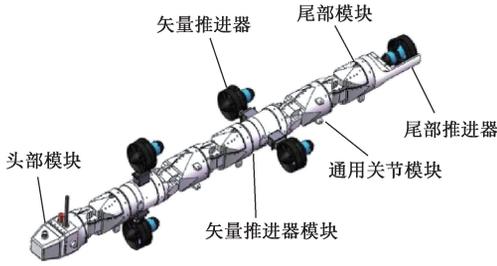


图1 USM TJU-1 结构
Fig. 1 Structure of USM TJU-1

USM 的相关坐标系的可视化表示如图 2 所示。USM 的连杆从尾部到头部依次编号为连杆 1 到连杆 4,第 i 个连杆的坐标系定义为 \sum_{l_i} ,坐标系原点位于连杆 i 的最左侧。第 j 个可旋转壳体的坐标系定义为 \sum_{r_j} 。连杆坐标系和旋转壳体坐标系也被称为物体坐标系。在本文中,定义第 1 个连杆作为基座, \sum_{l_1} 也被称作基座坐标系 \sum_b 。末端执行器坐标系 \sum_e 原点位于第 4 个连杆的最右侧。按照从尾部到头部的顺序,将关节从 1~3 编号,这样连杆 i 和连杆 $i+1$ 就通过关节 i 连接,第 i 个关节旋转方向是参考第 $i+1$ 个连杆坐标系定义的。本文每个关节的旋转轴均为其参考的连杆坐标系的 z 轴。

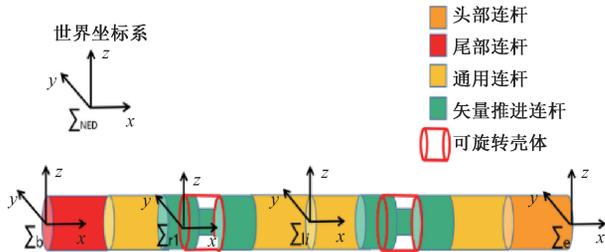


图2 USM TJU-1 坐标系
Fig. 2 Coordinate system of USM TJU-1

1.2 水下游动机械臂动力学建模

表 1 给出了 USM 建模过程中所用的变量及其名称。为了降低水下游动机械臂模型的复杂度,在建模时做出了以下假设:1)在建模时只考虑了推进器产生的推力,忽略了推进器对 USM 运动造成的复杂影响;2)为降低动力学建模的复杂度,将每个连杆都看作圆柱体。

考虑到附加质量力、水阻力、重力和浮力等外力作用,基于拉格朗日建模方法推导得到其动力学模型,如式(1)所示。

$$M(\xi)\ddot{\xi} + C(\xi, \dot{\xi})\dot{\xi} + D(\xi, \dot{\xi}) + g(\xi) + f_d = \tau \quad (1)$$

表 1 USM 数学建模所用到的变量及其含义

Table 1 Definitions of variables of the mathematical models of an USM

变量命名	变量定义
$\xi = [n_1^T \ n_2^T \ q^T \ \beta^T] \in \mathbf{R}^{5+n+h}$	USM 基座状态向量,包含:位置、姿态、关节角度以及壳体旋转角度
$\zeta = [v_b^T \ \omega_b^T \ q^T \ \beta^T] \in \mathbf{R}^{5+n+h}$	USM 基座速度向量,包含:线速度、角速度、关节及壳体角速度

其中, $M(\xi)$ 是包括在水环境中运动带来的附加质量项的惯性矩阵, $C(\xi, \dot{\xi})$ 是科里奥利力-向心力矩阵, $D(\xi, \dot{\xi})$ 代表水阻力, $g(\xi)$ 是重力和浮力项, f_d 代表外扰。控制输入由广义力和力矩 τ 给出。在本文的后续内容中,为了方便表示,参数 ξ, ζ 经常被省略,例如,将 $M(\xi)$ 写为 M 。

1.3 水下游动机械臂矢量推进系统

对于具有矢量推进模块的 USM,推进器提供的力和力矩取决于 USM 的关节角度以及推进器的配置。因此需要建立矢量推进系统的数学模型,用来描述机器人的广义力与推进器推力之间的映射关系。本小节将每个矢量推进器分解为两个固定方向的推进器,最终得到控制输入 u 和广义力和力矩 τ 之间的关系为:

$$\tau = [T_{thr}(\xi, q_{thr}) \ I_{11 \times 11}]u \quad (2)$$

其中, $T_{thr} \in \mathbf{R}^{11 \times 5}$ 是推力分配矩阵, $q_{thr} \in \mathbf{R}^4$ 表示矢量推进器的角度, $u = [r_{thr} \ r_q \ r_\beta] \in \mathbf{R}^{11}$, $r_{thr} \in \mathbf{R}^5$ 是推进器力的矢量, $r_q \in \mathbf{R}^3$ 表示关节力矩, $r_\beta \in \mathbf{R}^2$ 表示旋转关节力矩。

2 基于 RBF 神经网络补偿器的动力学控制器设计

如图 3 的控制框架所示,本文设计了反馈线性化和 RBFNN 相结合的动力学控制器,并通过反步法给出了 RBFNN 的权重自适应更新律。RBFNN 可以估计系统未建模部分、建模误差以及外部扰动,从而补偿动力学控制器。

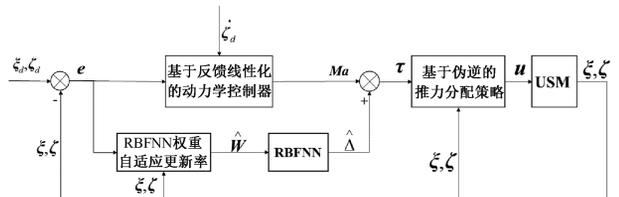


图3 基于 RBFNN 补偿器的动力学控制器
Fig. 3 Dynamic controller based on RBFNN compensator

2.1 控制器设计

由式(1), USM 的动力学模型可表示为:

$$M\dot{\zeta} + n = \tau \quad (3)$$

其中, $n = C\zeta + D + G + f_d$ 为非线性耦合项。基于式(3), 在假设系统非线性部分精确已知的前提下, 设计基于状态反馈线性化的动力学控制器。反馈线性化方法的基本思想是找到广义力 τ 的状态相关的线性函数, 定义新的状态变量 $x = [x_1 \ x_2]^T$, 并令:

$$x_1 = J^+ \zeta, \quad x_2 = \dot{\zeta} \quad (4)$$

其中, x_1 和 x_2 分别为位置层面和速度层面的状态向

量, 且满足 $\dot{x}_1 = x_2$; $J^+ = (J^T J + \lambda^2 I)^{-1} J^T$ 是雅可比矩阵 J 的伪逆^[7], λ 为大于 0 的常数, 可以保证 J^+ 始终保持满秩。根据式(4), 整理得水下游动机械臂动力学方程的状态空间表达式为:

$$\dot{x} = \begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} x_2 \\ -M^{-1}n + M^{-1}\tau \end{bmatrix} \quad (5)$$

通过非线性补偿可以得到如下控制律:

$$\tau = Ma + n \quad (6)$$

其中, $a \in \mathbf{R}^{5+n+h}$ 是加速度级的控制量。为达到期望

位姿 ξ_d 、期望速度 ζ_d 及其导数 $\dot{\zeta}_d$, 定义位置误差为 $e_1 = x_{1d} - x_1$, 速度误差为 $e_2 = x_{2d} - x_2$, 将控制量 a 设计为期望加速度和误差反馈的线性组合:

$$a = \dot{\zeta}_d + K_D e_2 + K_P e_1 \quad (7)$$

其中, $K_D \in \mathbf{R}^{(5+n+h) \times (5+n+h)}$ 和 $K_P \in \mathbf{R}^{(5+n+h) \times (5+n+h)}$ 为对角正定增益矩阵。

由式(3)可知, $n = C + D + G + f_d$ 为非线性耦合项。定义 $f(\xi, \zeta)$, 用来表示动力学模型中的非线性项; 定义 $\Delta f(\xi, \zeta)$ 表示 $f(\xi, \zeta)$ 项的改变, 即非线性项改变的不确定量, 则 $n = f(\xi, \zeta) + \Delta f(\xi, \zeta)$, 在后续推导中, 将用 $f, \Delta f$ 简写代替。

神经网络可有效拟合系统误差项^[18-20], 本文利用 RBFNN 逼近水下游动机械动力学模型改变量 Δf , 并将网络输出用于控制律 τ 中。

RBFNN 的一般结构如图 4 所示, 其中, i_r 表示输入层节点的个数, j_r 表示隐含层节点的个数, k_r 表示输出层节点的个数。

本文所选择的激活函数为高斯函数, 则 RBFNN 的隐含层第 j 个节点的输出 $H_j(x_r)$ 为:

$$H_j(x_r) = \exp\left(-\frac{\|x_r - b_j\|^2}{2\lambda_j^2}\right) \quad (j = 1, 2, \dots, j_r) \quad (8)$$

其中, x_r 为输入信号, b_j 为激活函数中心, λ_j 为激活函数宽度。则 RBF 神经网络的输出 y_r 为:

$$y_r = \sum_{j=1}^{j_r} w_j H_j(x_r) = W^T H(x_r) \quad (9)$$

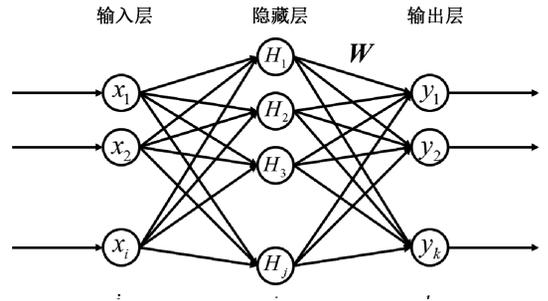


图 4 RBFNN 结构示意图

Fig. 4 RBFNN structure diagram

其中, W 为隐含层到输出层的权值矩阵, w_j 为 W 中的元素之一。

考虑到非线性项的改变量, 式(7)可表示为:

$$\tau = Ma + f + \Delta f \quad (10)$$

由 RBFNN 的非线性逼近能力可知, 存在最优网络权值 W^* , 使得:

$$\Delta f = W^{*T} H(X) \quad (11)$$

其中, $H(X)$ 为 RBFNN 隐含层输出。在自适应控制律中, RBFNN 输出可表示为:

$$\hat{f} = \hat{W}^T H(X) \quad (12)$$

其中, \hat{f} 为 Δf 的估计值, \hat{W}^T 为 RBFNN 权值的估计值。

将式(12)代入式(3)~(10)中, 可得到基于自适应更新权重的 RBFNN 的动力学控制律为:

$$\tau = Ma + f + \hat{W}^T H(X) \quad (13)$$

将式(13)代入式(5)中, 得:

$$\dot{x} = \begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} x_2 \\ a - M^{-1} \tilde{W}^T H(X) \end{bmatrix} \quad (14)$$

其中, $\tilde{W}^T = W^{*T} - \hat{W}^T$ 为最优权重与权重估计值的误差。

根据式(14), 系统的误差动力学方程可以表示为:

$$\dot{e} = \dot{x}_d - \dot{x} = A_e e + B_e \quad (15)$$

$$\text{其中, } A_e = \begin{bmatrix} \mathbf{0}_{(5+n+h) \times (5+n+h)} & I_{(5+n+h) \times (5+n+h)} \\ -K_P & -K_D \end{bmatrix} \text{ 为误差动}$$

力学方程的状态变换矩阵, $B_e = \begin{bmatrix} \mathbf{0}_{(5+n+h) \times (5+n+h)} \\ M^{-1} \tilde{W}^T H(X) \end{bmatrix}$, $e^T = [e_1^T \ e_2^T]$ 为误差状态向量。

选取李雅普诺夫函数 V 为:

$$V = \frac{1}{2} e^T e + \frac{1}{2\gamma} \tilde{W}^T \tilde{W} \geq 0 \quad (16)$$

其中, $\gamma > 0$ 。结合式(15)和式(16), 对李雅普诺夫函数 V 求导可得:

$$\dot{\mathbf{V}} = \mathbf{e}^T \mathbf{A}_e \mathbf{e} + \tilde{\mathbf{W}}^T (\mathbf{e}_2^T \mathbf{M}^{-1} \mathbf{H}(\mathbf{X}) + \frac{1}{\gamma} \dot{\tilde{\mathbf{W}}}) \quad (17)$$

取自适应更新律为:

$$\dot{\tilde{\mathbf{W}}} = -\gamma \mathbf{e}_2^T \mathbf{M}^{-1} \mathbf{H}(\mathbf{X}) \quad (18)$$

结合式(18)和(17),有:

$$\dot{\mathbf{V}} = \mathbf{e}^T \mathbf{A}_e \mathbf{e} \leq -b_1 \left(\frac{1}{2} \mathbf{e}^T \mathbf{e} \right) \quad (19)$$

其中, $b_1 = \lambda_{\min}(\mathbf{A}_e)$, 即矩阵 \mathbf{A}_e 的最小奇异值。对式(19)两侧沿 $[0, t]$, 可得:

$$V(t) \leq V(0) e^{-b_1 t} \quad (20)$$

因此, $\lim_{t \rightarrow \infty} \mathbf{e} = \mathbf{0}$, 且 \mathbf{e} 有界。基于以上分析, 可以得出结论, 本节所设计的基于 RBFNN 补偿器的动力学控制器可使系统跟踪误差全局渐进稳定。

2.2 基于伪逆的推力分配策略

2.1 节中, 控制器输出为广义力和力矩 $\boldsymbol{\tau}$, 无法直接作为每个执行机构的输入量。因此, 需要通过推力分配策略, 将动力学控制器提供的广义力和力矩 $\boldsymbol{\tau}$ 转换成控制输入 \mathbf{u} , 进而分配给各个推进器和关节执行器。受文献[19]启发, 本文给出了一种推力分配策略, 最终得到推力分配显式解为:

$$\mathbf{u} = \mathbf{T}^\dagger(\boldsymbol{\xi}) \boldsymbol{\tau} \quad (21)$$

其中, $\mathbf{T}^\dagger(\boldsymbol{\xi}) \in \mathbf{R}^{(9+n+h) \times (5+n+h)}$ 是利用正则化方法计算的广义最小二乘伪逆:

$$\mathbf{T}^\dagger(\boldsymbol{\xi}) = \mathbf{T}^T(\boldsymbol{\xi}) (\mathbf{T}(\boldsymbol{\xi}) \mathbf{T}^T(\boldsymbol{\xi}) + \kappa \mathbf{I})^{-1} \quad (22)$$

其中, κ 为大于 $\mathbf{0}$ 的正则化参数, 能够始终使 $\mathbf{T}^\dagger(\boldsymbol{\xi})$ 保持满秩。

3 实验验证

本文实验装置平台如图5所示。实验所用的水下运动机械臂平台由头部连杆、矢量推进连杆与尾部连杆组成, 连杆之间通过单自由度关节铰接连接。其中, 两组矢量推进器对称安装在旋转壳体上, 旋转壳体可绕连杆的轴线方向旋转, 矢量推进器可以进行轴向旋转来调整自身角度, 用以提供大小和方向可变的矢量推进力; 尾部连杆上连接了带有推进器的助推装置, 用于在机器人尾部施加推力, 以提高水下运动机械臂的运动速度。

USM 的物理参数如表2所示。USM 样机的尾部连杆内置以 STM32F401CB 芯片为核心的主控板, 用来实现与上位机和各关节板之间的数据传输。其余各连杆均内置一块关节控制板, 芯片选用 STM32F100C4, 用于控制关节电机角度、推进器舵机角度以及推进器转速。主控板与各关节板之间使用 CAN 通信实现数据传输。传感器选用声学多普勒速度仪 (doppler velocity log, DVL), 型号为 Water Linked A50。该传感器安装在尾部连杆下方,

用于采集 USM 基座的位置、姿态以及线速度信息。

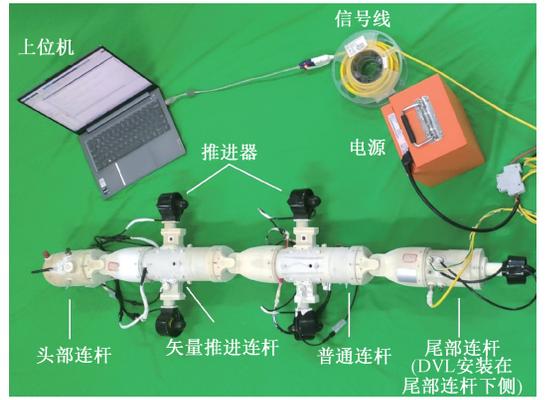


图5 USM TJU-1 实验平台

Fig. 5 USM TJU-1 experimental platform

表2 USM TJU-1 系统参数
Table 2 Parameters of TJU USM-1

	参数	参数值
头部	长度 l_1/m	0.15
	质量 m_1/kg	0.6
	半径 r_1/m	0.05
矢量推进	长度 l_2/m	0.22
	质量 m_2/kg	2.5
	半径 r_2/m	0.05
尾部	长度 l_3/m	0.15
	质量 m_3/kg	0.6
	半径 r_3/m	0.05

为验证所提控制方案的有效性与鲁棒性, 本文分别对 USM 的“I”构型与“C”构型进行镇定控制实验。

3.1 USM“I”构型镇定控制

在本节实验中, USM 始终保持“I”构型, 即关节角 $[q_1 \ q_2 \ q_3] = [0 \ 0 \ 0]$, 如图6所示, 进行了 45 s 实验验证。本小节将第2章提出控制器与未经补偿的动力学控制器进行了对比, 用来验证具有自适应更新律的 RBFNN, 对动力学控制器的补偿作用。控制器参数如表3所示。末端执行器期望位姿为 $[\mathbf{n}_{1d}^T \ \mathbf{n}_{2d}^T] = [0.5 \ 0 \ -0.5 \ 0 \ 0 \ 0]$ 。

表3 “I”构型下控制器参数
Table 3 Controller parameters of I-shape

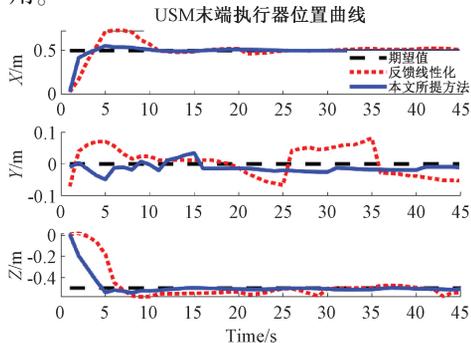
参数名称	参数值
\mathbf{K}_P	$diag(3.1, 2.8, 5.0, 4.2, 3.7, 5.5, 0, 0, 0, 0)$
\mathbf{K}_D	$diag(0.5, 0.3, 2.0, 0.6, 0.4, 0.2, 0, 0, 0, 0)$
b_j	$rand(-1, 1)$
λ_j	3
γ	0.2
κ	0.1



图 6 USM 的 I 构型示意图

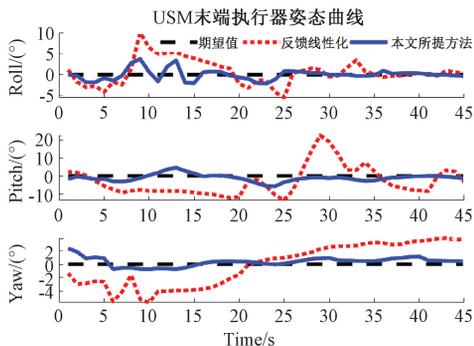
Fig. 6 I-shape of the USM

实验结果如图 7 和 8 所示。图 7(a)~(b)展示了两种方案下末端执行器镇定控制的结果。图 8 给出了两种方法下推进器的推力结果。通过对比可以看出,基于 RBF 神经网络补偿的动力学控制器,对动力学模型参数变化以及未建模部分具有良好的估计效果,从而使控制器的控制精度更高。在实际环境中,动力学模型参数变化更为剧烈,从而更能体现出 RBF 神经网络对控制器的补偿作用。



(a) 末端执行器位置

(a) Position of end effector

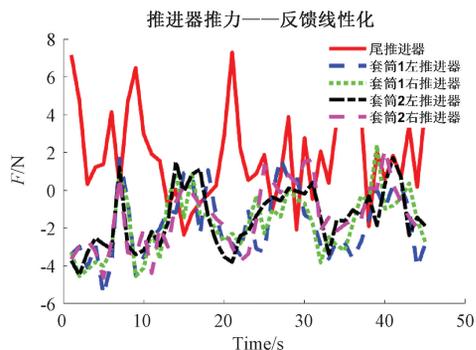


(b) 末端执行器姿态

(b) Orientation of end effector

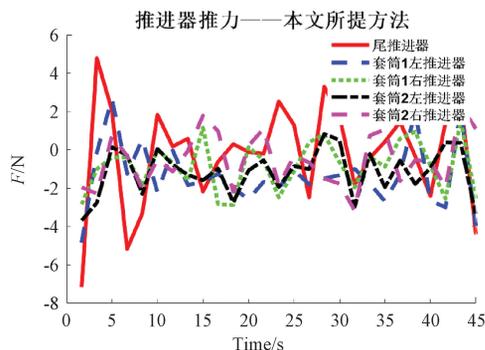
图 7 “I”构型下 USM 末端执行器镇定控制结果

Fig. 7 Stabilization control results of end-effector of the USM with I-shape



(a) 基于反馈线性化的推力

(a) Force based on feedback linearization method



(b) 基于本文提出方法的推力

(b) Force based on the method proposed in this paper

图 8 “I”构型推进器推力

Fig. 8 Force of thrusters with I-shape

3.2 USM“C”构型镇定控制

在本节实验中,USM 始终保持“C”构型,即关节角 $[q_1 \ q_2 \ q_3] = [60^\circ \ 60^\circ \ 60^\circ]$,如图 9 所示,进行了 45 s 实验验证。本小节将第 2 章提出控制器与未经补偿的动力学控制器进行了对比,用来验证具有自适应更新律的 RBFNN,对动力学控制器的补偿作用。控制器参数与 3.2 节中基本一致,修改部分已在表 4 中给出。末端执行器期望位姿与“I”构型镇定控制实验的设置相同。



图 9 USM 的 C 构型示意图

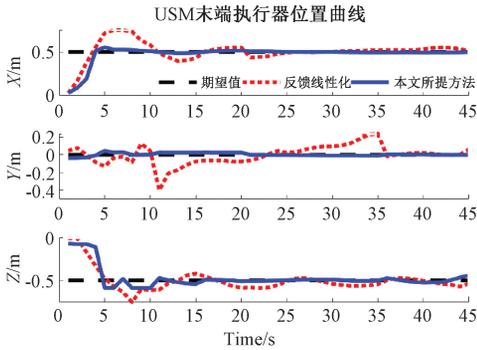
Fig. 9 C-shape of the USM

表4 “C”构型下控制器参数

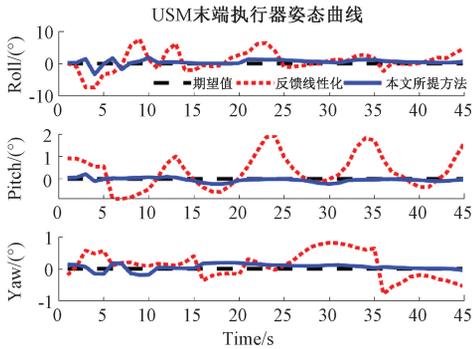
Table 4 Controller parameters of C-shape

参数名称	参数值
K_P	$diag(2.4, 4.6, 3.3, 4.7, 1.6, 4.5, 0, 0, 0, 0)$
K_D	$diag(0.2, 0.2, 0.6, 0.1, 0.7, 0.5, 0, 0, 0, 0)$

“C”构型实验结果如图10和11所示。图9(a)~(b)展示了两种方案下末端执行器镇定控制的结果。图11给出了两种方法下推进器的推力结果。当USM保持“C”构型时,其重心位置偏离机器人本体,从而导致滚转以及俯仰自由度的控制难度变大。可以看到图9(b)中,基于反馈线性化的动力学控制器对滚转以及俯仰角的控制效果并不理想;而加入了RBFNN补偿的动力学控制器则可以在这两个自由度上实现良好的控制精度。



(a) 末端执行器位置
(a) Position of end effector



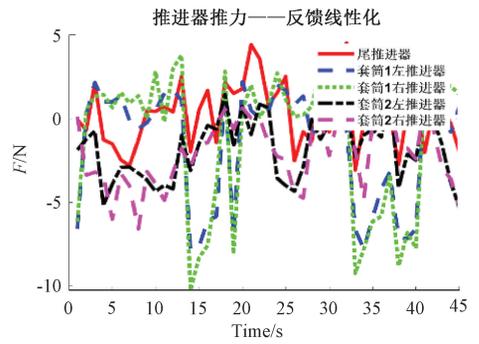
(b) 末端执行器姿态
(b) Orientation of end effector

图10 “C”构型下USM末端执行器镇定控制结果

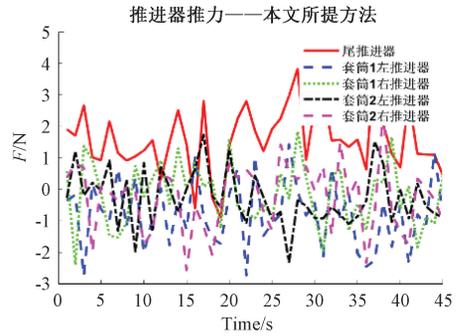
Fig. 10 Stabilization control results of end-effector of the USM with C-shape

4 结论

本文首先介绍了自主研究设计的USM平台,基于Lagrange方程给出了USM动力学模型,并推导了USM的矢量推力系统模型。然后,基于反馈线性化方法和RBF神经网络方法,设计了控制框架,用来实现USM的镇定控制。通过反步法推导了RBF神经网络的权重自适应



(a) 基于反馈线性化的推力
(a) Force based on feedback linearization method



(b) 基于本文提出方法的推力
(b) Force based on the method proposed in this paper

图11 “C”构型推进器推力

Fig. 11 Force of thrusters with C-shape

更新律。权重自适应更新RBF神经网络可以估计系统未建模部分、建模误差以及外部扰动,从而对动力学控制器进行补偿。最后,通过湖泊实验,针对两种不同的USM构型,分别进行USM末端执行器的六自由度镇定控制实验,证明了所提控制方法的有效性。本文通过权重自适应RBFNN补偿了USM系统的不确定性,包括水环境变化引起的相关参数改变以及外部扰动。实验结果证明了神经网络方法在处理复杂不确定性问题时展现出了强大的能力,但如何进一步提高基于学习的控制方法的精度,仍有待深入研究。

参考文献

[1] SVERDRUP-THYGESON J, KELASIDI E, PETERSEN K Y. The underwater swimming manipulator—a bio-inspired AUV [C]. 2016 IEEE/OES Autonomous Underwater Vehicles (AUV). IEEE, 2016: 387-395.

[2] AALBU S V. Subsea inspection and intervention with underwater swimming manipulators [D]. Norwegian; Norwegian University of Science and Technology, 2018.

[3] BORLAUG I L G, GRAVDAHL J T, SVERDRUP-THYGESON J. Trajectory tracking for underwater swimming manipulators using a super twisting algorithm [J]. Asian Journal of Control, 2019, 21(1): 208-223.

[4] SVERDRUP-THYGESON J, KELASIDI E, PETERSEN K

- Y. Modeling of underwater swimming manipulators [J]. IFAC-PapersOnLine, 2016, 49(23):81-88.
- [5] SVERDRUP-THYGESON J, KELASIDI E, PETTERSEN K Y. A control framework for biologically inspired underwater swimming manipulators equipped with thrusters[J]. IFAC-PapersOnLine, 2016, 49(23): 89-96.
- [6] SVERDRUP-THYGESON J, KELASIDI E, PETTERSEN K Y. The underwater swimming manipulator-A bioinspired solution for subsea operations [J]. IEEE Journal of Oceanic Engineering, 2018, 43(2):402-417.
- [7] AMUNDSSEN MF, SVERDRUP-THYGESON J, KELASIDI E. Inverse kinematic control of a free-floating underwater manipulator using the generalized jacobian matrix[C]. Proceedings of the European Control Conference (ECC). Piscataway: IEEE, 2018; 276-281.
- [8] BORLAUG I L G, PETTERSEN K Y, GRAVDAHL J T. Trajectory tracking for an articulated intervention AUV using a super-twisting algorithm in 6 DOF [J]. IFAC-PapersOnLine, 2018, 51(29): 311-316.
- [9] BORLAUG I L G, PETTERSEN K Y, GRAVDAHL J T. Tracking control of an articulated intervention AUV in 6DOF using the generalized super-twisting algorithm[C]. Proceedings of American Control Conference (ACC). Piscataway: IEEE, 2019; 5705-5712.
- [10] BORLAUG I L G, PETTERSEN K Y, GRAVDAHL J T. The generalized super-twisting algorithm with adaptive gains[C]. Proceedings of European Control Conference (ECC). Piscataway: IEEE, 2020; 1624-1631.
- [11] BORLAUG I L G, PETTERSEN K Y, GRAVDAHL J T. Tracking control of an articulated intervention autonomous underwater vehicle in 6DOF using generalized super-twisting: Theory and experiments[J]. IEEE Transactions on Control Systems Technology, 2020, 29(1): 353-369.
- [12] BORLAUG I L G, PETTERSEN K Y, GRAVDAHL J T. Comparison of two second-order sliding mode control algorithms for an articulated intervention AUV: Theory and experimental results[J]. Ocean Engineering, 2021, 222: 108480.
- [13] KUMAR V S, RAJAGOPAL P. Implementing an adaptive thrust distribution algorithm on the robust control system for serial split-hull underwater vehicles[J]. IEEE Access, 2022, 10: 122912-122932.
- [14] ZHANG J, CHEN Y, LIU Y. Dynamic modeling of underwater snake robot by hybrid rigid-soft actuation[J]. Journal of Marine Science and Engineering, 2022, 10(12): 1914.
- [15] VAN CUONG P, NAN W Y. Adaptive trajectory tracking neural network control with robust compensator for robot manipulators[J]. Neural Computing and Applications, 2016, 27: 525-536.
- [16] SON N, VAN KIEN C, ANH H P H. A novel adaptive feed-forward-PID controller of a SCARA parallel robot

using pneumatic artificial muscle actuator based on neural network and modified differential evolution algorithm[J]. Robotics and Autonomous Systems, 2017, 96: 65-80.

- [17] YEN V T, NAN W Y, VAN CUONG P. Recurrent fuzzy wavelet neural networks based on robust adaptive sliding mode control for industrial robot manipulators[J]. Neural Computing and Applications, 2019, 31: 6945-6958.
- [18] LAKHEKAR G V, WAGHMARE L M, JADHAV P G. Robust diving motion control of an autonomous underwater vehicle using adaptive neuro-fuzzy sliding mode technique[J]. IEEE Access, 2020, 8: 109891-109904.
- [19] 秦志昌. 非线性动力学系统的多目标优化控制设计[D]. 天津: 天津大学, 2016.
QIN ZH CH. Multi-objective optimal control design for nonlinear dynamical systems [D]. Tianjin: Tianjin University, 2016.
- [20] 徐颀钰, 李岩松, 胡杰祥, 等. 基于 RBF-PID 的互感器校验主从时钟误差修正算法[J]. 电子测量与仪器学报, 2023, 37(11): 152-160.
XU G Y, LI Y S, HU J X, et al. Error correction algorithm of master-slave clock for transformer calibration based on RBF-PID [J]. Journal of Electronic Measurement and Instrument, 2023, 37(11): 152-160.

作者简介

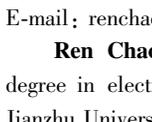


孙非, 2013 年本科毕业于吉林大学热能与动力工程(汽车发动机)专业, 工学学士。现为天津内燃机研究所未来技术研究院副院长, 主要从事高性能特种动力及水下特种装备研发工作。

E-mail: sfei@tju.edu.cn

Sun Fei received his B. Sc. degree in Thermal Energy and Power Engineering (Automotive Engine) from Jilin University in 2013. He is currently the vice president of Future Technology Research Institute of Tianjin Internal Combustion Engine Research Institute. His main research interests include high-performance special power and underwater special equipment.

任超(通信作者), 2009 年获得山东建筑大学电气工程与自动化专业学士学位, 2011 年获得哈尔滨工业大学控制科学与与控制工程专业硕士学位, 2015 年获得日本京都立命馆大学机器人专业博士学位, 现为天津大学副教授, 主要研究方向为机器人控制及仿生机器人。



E-mail: renchao@tju.edu.cn

Ren Chao (Corresponding author) received the B. Sc. degree in electrical engineering and automation from Shandong Jianzhu University in 2009, the M. Sc. degree in control science and control engineering from the Harbin Institute of Technology in 2011, and the Ph. D. degree in robotics from Ritsumeikan University, Kyoto, Japan, in 2015. He is currently an Associate Professor with Tianjin University, Tianjin, China. His main research interests include robot control and biorobotics.