

【引用格式】李晨, 代笠. 基于 RBF-MPC 的水下机器人避碰控制[J]. 数字海洋与水下攻防, 2022, 5(5): 443-447.

# 基于 RBF-MPC 的水下机器人避碰控制

李 晨<sup>1</sup>, 代 笠<sup>2</sup>

(1. 海军装备部驻宜昌地区军事代表局, 湖北 宜昌 443003;

2. 海军装备部驻广州地区军事代表局, 广东 广州 510000)

**摘 要** 水下机器人避碰控制是自主作业的重要基础, 但复杂的约束条件和模型的不精确性增加了避障路径跟踪的技术难度。在传统模型预测控制的基础上, 结合作业场景多种约束条件, 引入径向基函数神经网络, 提出了一种水平面避碰控制方法。首先, 采用径向基神经网络建立误差补偿函数, 提高传统动力学预测模型精度; 然后, 结合避碰路径跟踪控制, 在滚动优化环节选取性能指标函数, 并显式引入障碍物、执行机构与控制稳定性等约束条件; 最后, 通过仿真试验证明该方法能够控制水下机器人跟踪避碰路径实现水平面内障碍物规避。

**关键词** 水下机器人; 避碰控制; 神经网络; 模型预测控制

中图分类号 TP242

文献标识码 A

文章编号 2096-5753(2022)05-0443-05

DOI 10.19838/j.issn.2096-5753.2022.05.009

## Collision Avoidance Control of Underwater Vehicle Based on RBF-MPC

LI Chen<sup>1</sup>, DAI Li<sup>2</sup>

(1. Military Representative Bureau of the Naval Armaments Department in Yichang, Yichang 430000, China;  
2. Military Representative Bureau of the Naval Armaments Department in Guangzhou, Guangzhou 510000, China)

**Abstract** The collision avoidance control of underwater vehicles is an important basis for autonomous operation, but complicated constraints and imprecision of models increase the technical difficulty of path tracking in avoidance. Based on the predictive control of traditional model, this paper proposes a horizontal-plane collision avoidance control method, combining with various constraints of operation scene and introducing radial basis function neural network. Firstly, radial basis neural network is used to establish error compensation function to improve the accuracy of traditional dynamic predictive model. Then, combining with the tracking control of collision avoidance path, the performance index function is selected in the rolling horizon optimization stage, and the constraints such as obstacles, actuator and control stability are explicitly introduced. Finally, the simulation results show that the proposed method can control the underwater vehicle to track the collision avoidance path to achieve collision avoidance in the horizontal plane.

**Key words** underwater vehicle; collision avoidance; neural network; model predictive control

## 0 引言

水下机器人作为重要的海洋装备, 被广泛应用

于资源勘测、海洋工程、水下救助以及侦察打击等军民领域多种场景。为了在复杂多变的海洋环境中顺利完成使命任务, 水下机器人需要能够结合自身

运动特性,以及周围暗礁、锚链等危险障碍物信息,基于路径跟踪实现有效的避碰控制。

国内外围绕水下机器人路径跟踪控制问题开展了广泛研究,早期研究采用比例-积分-微分控制实现水下机器人运动控制和路径跟踪<sup>[1]</sup>。由于水下机器人运动具有强非线性,并且会受到复杂的外部环境干扰,该类方法往往效果有限。文献[2]-[4]将滑模控制等方法引入路径跟踪控制,以改善传统算法的稳定性和收敛性,但在避碰控制场景下缺乏对外部环境与执行机构等约束进行处理的有效手段。

模型预测控制 (Model Predictive Control, MPC) 具有能够显式处理系统约束的优势。文献[5]构建了 MPC 控制函数,降低无人潜航器轨迹跟踪控制的能耗,同时减小跟踪误差保证跟踪精确性。文献[6]开发了基于 Lyapunov 的 MPC 框架,提高了无人潜航器的轨迹跟踪精度。这些研究基本直接采用传统动力学模型作为预测模型,在模型误差修正方面考虑有所欠缺。

有研究者进一步将神经网络引入控制器,文献[7]通过神经网络估计水动力阻尼过程的逼近误差,从而提升了控制器对模型不确定项的控制能力。文献[8]利用递归神经网络的动态特性辨识系统,简化了仅辨识未知非线性函数带来的控制器设计复杂性。文献[9]改进 Elman 网络作为预测模型,提出并推导了用于求解预测控制律的灵敏度导数公式,用于水下机器人神经广义预测控制。

因此,本文提出了一种水下机器人避碰控制方法,以引入约束条件的 MPC 算法为基础,采用径向基函数 (Radial Basis Function, RBF) 神经网络修正传统动力学预测模型,对水平面避碰规划路径进行跟踪控制。通过仿真试验证明了该方法能够在避碰场景下实现有效的路径跟踪控制,并且相比传统 MPC 方法控制精度有所提升。

### 1 基于 RBF 神经网络修正的预测模型

本文以水下机器人水平面运动作为分析对象,仅考虑纵向运动、横向运动与偏航运动 3 个自由度。取惯性坐标系与载体坐标系下状态向量分别为  $[x, y, \psi]^T$  与  $[u, v, r]^T$ , 则运动学方程为

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\psi} \end{bmatrix} = \begin{bmatrix} \cos\psi & -\sin\psi & 0 \\ \sin\psi & \cos\psi & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} u \\ v \\ r \end{bmatrix} \quad (1)$$

式中:  $x$  为前向位移;  $y$  为侧向位移;  $\psi$  为航向角;  $u$  为前向速度;  $v$  为侧向速度;  $r$  为航向角速度。

动力学方程为

$$\begin{cases} \dot{u} = \frac{m_{22}}{m_{11}}vr - \frac{d_{11}}{m_{11}}u + \frac{1}{m_{11}}X \\ \dot{v} = -\frac{m_{11}}{m_{22}}ur - \frac{d_{22}}{m_{22}}v + \frac{1}{m_{22}}Y \\ \dot{r} = \frac{m_{11} - m_{22}}{m_{11}}uv - \frac{d_{33}}{m_{33}}r + \frac{1}{m_{33}}N \end{cases} \quad (2)$$

式中:  $m_{11}$ 、 $m_{22}$  与  $m_{33}$  为惯性矩阵元素;  $d_{11}$ 、 $d_{22}$  与  $d_{33}$  为水动力阻尼矩阵元素;  $X$ 、 $Y$  与  $N$  分别为前向作用力、横向作用力与偏航力矩。

根据式 (1) 与式 (2) 建立基础动力学预测模型,考虑到该预测模型建模误差,采用 RBF 神经网络建立误差补偿函数。RBF 神经网络作为一种单隐层前馈网络,由输入层、隐藏层、输出层 3 层网络结构组成,具有较好的非线性函数的逼近功能,并且有利于降低水下机器人控制器的实时运算负担<sup>[10-11]</sup>。本文采用 9 输入 3 输出 RBF 神经网络结构建立误差补偿函数。

输入层向量  $x_i$  由状态测量值、执行机构作用力与状态预测值 3 部分组成,具体定义为

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ x_8 \\ x_9 \end{bmatrix} = \begin{bmatrix} u_m \\ v_m \\ r_m \\ X_a \\ Y_a \\ N_a \\ u_b \\ v_b \\ r_b \end{bmatrix} \quad (3)$$

式中:  $u_m$ 、 $v_m$  与  $r_m$  分别为前向速度、侧向速度与航向角速度的状态测量值;  $X_a$ 、 $Y_a$  与  $N_a$  分别为执行机构产生的前向力、横向力与偏航力矩;  $u_b$ 、 $v_b$  与  $r_b$  分别为基础动力学模型输出的前向速度、侧向速度与航向角速度状态预测值。

隐藏层采用高斯函数作为激活函数, 则计算方法为

$$h_j(x_i) = \exp\left(-\frac{\|x_i - c_j\|^2}{2\sigma_j^2}\right) \quad (4)$$

式中:  $\|x_i - c_j\|$  表示  $x_i$  和  $c_j$  之间的欧几里得距离; 中心值  $c_j$  为第  $j$  个隐藏层神经节点的高斯基函数中心点矢量值; 宽度  $\sigma_j$  代表隐含层的高斯基函数宽度。

输出层向量  $y_q$  表示基础动力学模型与实际载体的状态修正值, 具体为

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix} = \begin{bmatrix} du \\ dv \\ dr \end{bmatrix} \quad (5)$$

式中,  $du$ 、 $dv$  与  $dr$  分别为前向速度、侧向速度与航向角速度的状态修正值。

其计算方法为

$$y_q = \sum_{j=1}^m h_j^* \omega_{jq}^T = h_1 \omega_{1q} + h_2 \omega_{2q} + \dots + h_m \omega_{mq} \quad (6)$$

式中,  $\omega_{jq}$  是第  $j$  个隐藏层节点到第  $q$  个输出层节点的权重向量。

神经网络采用有监督学习方法(具体为梯度下降法)进行训练<sup>[12]</sup>, 表达为

$$D(t) = \frac{1}{2} \exp(y(t) - y_q(t))^2 \quad (7)$$

式中,  $y$  是基础动力学模型与实际载体的状态偏差值。

则训练过程中权重值  $w_{jq}(t)$  为

$$\Delta \omega_{jq}(t) = -\eta \frac{\partial D}{\partial \omega_{jq}} = \eta (y(t) - y_q(t)) h_j \quad (8)$$

$$\omega_{jq}(t) = \omega_{jq}(t-1) + \Delta \omega_{jq}(t) + \alpha (\omega_{jq}(t-1) - \omega_{jq}(t-2)) \quad (9)$$

式中:  $\eta$  为逼近过程中的学习率;  $\alpha$  为动量因子。

同理, 中心值  $c_j$  与宽度  $\sigma_j$  为

$$\Delta c_j(t) = -\eta \frac{\partial D}{\partial c_j} = \eta (y(t) - y_q(t)) \omega_{jq} h_j \frac{x_i - c_j}{\sigma_j^2} \quad (10)$$

$$c_j(t) = c_j(t-1) + \Delta c_j + \alpha (c_j(t-1) - c_j(t-2)) \quad (11)$$

$$\Delta \sigma_j(t) = -\eta \frac{\partial D}{\partial \sigma_j} = \eta (y(t) - y_q(t)) \omega_{jq} h_j \frac{\|x - c_j\|^2}{\sigma_j^3} \quad (12)$$

$$\sigma_j(t) = \sigma_j(t-1) + \Delta \sigma_j + \alpha (\sigma_j(t-1) - \sigma_j(t-2)) \quad (13)$$

训练神经网络得到误差补偿函数, 即建立状态测量值、执行机构作用力、状态预测值同状态修正值的映射关系。根据该映射关系补偿基础动力学模型误差, 输出载体坐标系下状态向量为

$$\begin{bmatrix} u_f \\ v_f \\ r_f \end{bmatrix} = \begin{bmatrix} u_b + du \\ v_b + dv \\ r_b + dr \end{bmatrix} \quad (14)$$

式中:  $u_f$ 、 $v_f$  与  $r_f$  分别为前向速度、侧向速度与航向角速度的补偿后状态量;  $u_b$ 、 $v_b$  与  $r_b$  分别为基础动力学模型输出的前向速度、侧向速度与航向角速度状态预测值。

通过将神经网络补偿的动力学模型作为 MPC 预测模型, 使预测模型更加逼近真实载体的动力学响应特征, 从而提升基于 MPC 的路径跟踪控制效果。

## 2 基于 MPC 的水下机器人避碰控制

针对水下机器人水平面避碰场景, 本文设计了 RBF-MPC 控制器对避碰路径进行跟踪控制, 性能指标函数为

$$J(t, x(t), u(t)) = \sum_{k=1}^{N_p} (x_k - r_k)^T R (x_k - r_k) + \sum_{k=1}^{N_c} \Delta u_k^T Q \Delta u_k \quad (15)$$

式中:  $t$  为时间;  $x$  为系统状态;  $u$  为控制输入量;  $N_c$  为控制时域;  $N_p$  为预测时域;  $r$  为避碰路径所对应系统状态; 为控制量的增量;  $R$  和  $Q$  分别代表控制输出和控制增量的权重矩阵。系统状态  $x$  与控制输入量  $u$  等变量随着时间  $t$  变化, 其下标  $k$  为离散控制的序列编号。

结合水下机器人避碰路径跟踪离散控制过程, 系统状态  $x$  包括惯性坐标系与载体坐标系下状态向量  $[x, y, \psi]^T$  与  $[u, v, r]^T$ , 控制输入量  $u$  包括执行机构产生的  $X_a$ 、 $Y_a$  与  $N_a$ 。

环境约束主要体现为障碍物对系统状态的位置约束, 通过避碰路径跟踪误差来实现

$$e_{\min} \leq x_k - r_k \leq e_{\max} \quad (16)$$

执行机构约束为则体现为控制量约束

$$u_{\min} \leq u_k \leq u_{\max} \quad (17)$$

$$\Delta u_{\min} \leq \Delta u_k \leq \Delta u_{\max} \quad (18)$$

为了提高控制过程的稳定性，补充状态向量约束

$$\psi_{\min} \leq \psi_k \leq \psi_{\max} \quad (19)$$

$$v_{\min} \leq v_k \leq v_{\max} \quad (20)$$

在每一个控制周期内，控制器以式(16)–(20)为约束条件，根据式(15)求解性能指标函数最小的一组最优控制量序列，再将该序列第一个控制量作为执行指令，从而实现对水下机器人避碰规划路径的闭环跟踪控制。

### 3 仿真实验

为验证基于RBF-MPC的水下机器人避碰控制算法，在MATLAB下开展运动控制仿真试验，基于某型自研产品数值仿真设置动力学模型参数，具体如下表所示。

表 1 动力学模型参数表  
Table 1 Dynamic model parameters

变量	值
$m_{11}$	31.43 kg
$m_{22}$	66 kg
$m_{33}$	8.33 kg·m <sup>2</sup>
$d_{11}$	7.8 kg/s
$d_{22}$	262 kg/s
$d_{33}$	188 kg·m <sup>2</sup> /s

采用传统 MPC 与 RBF-MFC 2 种算法对预设的全局避碰规划路径进行跟踪控制，其中传统 MPC 直接以动力学模型作为预测模型，RBF-MFC 采用离线训练神经网络修正后动力学模型作为预测模型。设定初始艏向角为 0，初始坐标为原点，水下机器人水平面避碰运动过程如图 1–6 所示。




图 1 航行轨迹图  
Fig. 1 Trajectory graph




图 2 路径跟踪误差曲线图  
Fig. 2 Curve graph of path tracking error

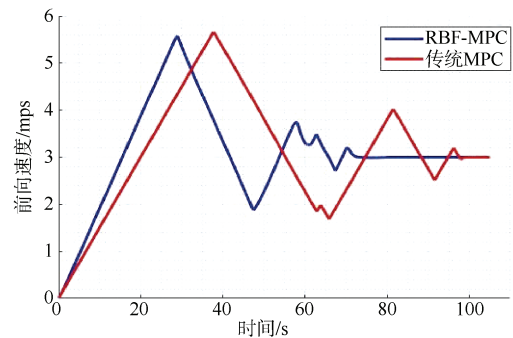


图 3 前向速度曲线图  
Fig. 3 Curve graph of forward velocity




图 4 航向角曲线图  
Fig. 4 Curve graph of heading angle




图 5 前向推力曲线图  
Fig. 5 Curve graph of forward thrust

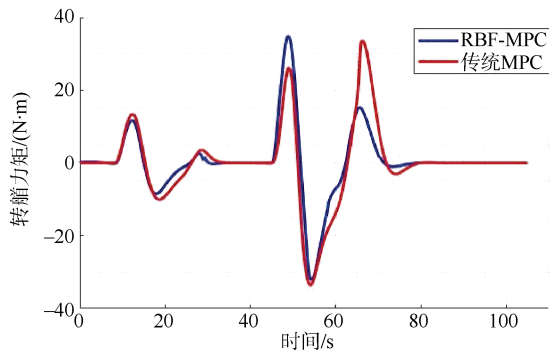


图6 转舵力矩曲线图

Fig. 6 Curve graph of turn stem torque

根据避碰航行轨迹可初步看出,2种方法均可控制水下机器人跟踪避碰规划路径,先后左偏约5 m与12.5 m,依次避开2个障碍物。

进一步分析避碰路径跟踪误差,传统MPC控制算法的均值为0.033 m,标准差为0.51 m,2次避碰最大值分别达到0.75 m与2.7 m;RBF-MPC控制算法的均值为0.006 m,标准差为0.17 m,2次避碰最大值分别为0.09 m与0.6 m,在平滑度与精确性方面的控制效果均有所提升。

#### 4 结束语

本文针对水下机器人避碰场景下的路径跟踪控制问题,设计了一种RBF-MPC控制方法。通过RBF神经网络补偿传统动力学模型的建模误差,提高了预测控制模型精度。在滚动优化环节显式考虑外部环境、执行机构等约束条件,求解避障路径的跟踪控制量。仿真结果证明该方法能够有效控制水下机器人跟踪避碰路径规避障碍物,并且相比于传统MPC控制方法路径跟踪误差更小。

#### 参考文献

[1] FOSSEN T I. Handbook of marine craft hydrodynamics

and motion control[M]. New York: John Wiley & Sons, 2011.

- [2] JAVADI-MOGHADDAM J, BAGHERI A. An adaptive neuro-fuzzy sliding mode based genetic algorithm control system for under water remotely operated vehicle[J]. Expert Systems with Applications, 2010, 37 (1): 647-660.
- [3] 王香,张永林. 基于RBF神经网络的AUV路径跟踪分数阶滑模控制[J]. 水下无人系统学报, 2020, 28 (3): 284-290.
- [4] CHEN W, HU S L, WEI Q Y. Design of ROV adaptive sliding mode control system for underwater vehicle based on RBF neural network[C]// 2021 33rd Chinese Control and Decision Conference (CCDC). Kunming: IEEE, 2021.
- [5] YAO F, YANG C, ZHANG M J, et al. Optimization of the energy consumption of depth tracking control based on model predictive control for autonomous underwater vehicles[J]. Sensors, 2019, 19 (1): 162.
- [6] SHEN C, SHI Y, BUCKHAM B. Trajectory tracking control of an autonomous underwater vehicle using Lyapunov-based model predictive control[J]. IEEE Transactions on Industrial Electronics, 2017, 65 (7): 5796-5805.
- [7] 王璐. 自治水下机器人的非线性控制方法研究[D]. 哈尔滨: 哈尔滨工程大学, 2013.
- [8] 赵杰梅. 离散非线性系统的预测控制方法研究[D]. 哈尔滨: 哈尔滨工程大学, 2013.
- [9] 张铭钧,高萍,徐建安. 基于神经网络的自治水下机器人广义预测控制[J]. 机器人, 2008 (1): 91-96
- [10] 段海庆,贾鹤鸣,周佳加,等. 基于神经网络的欠驱动水下机器人地形跟踪控制[J]. 东南大学学报(自然科学版), 2012, 42 (S1): 203-207.
- [11] 曾德伟. 水下机器人的轨迹跟踪控制方法研究[D]. 广州: 华南理工大学, 2017.
- [12] 贾亮瑜. 自主水下机器人回收姿态控制研究[D]. 镇江: 江苏科技大学, 2020.

(责任编辑: 张曼莉)