

基于可信残差补偿的仿生机器鱼模型预测轨迹跟踪控制

叶嘉侯^{1,2}, 余江^{2,3*}, 陈冠宏^{2,3}, 柯定彬^{2,3}, 杨捷^{1,2}, 张钰伟^{2,3}, 罗晓彤^{2,3}

¹广东海洋大学电子与信息工程学院, 广东 湛江

²广东海洋大学深蓝智能机电产品创新团队, 广东 湛江

³广东海洋大学机械工程学院, 广东 湛江

收稿日期: 2026年9月26日; 录用日期: 2026年10月19日; 发布日期: 2026年10月26日

摘要

针对仿生机器鱼因周期性摆尾推进和水动力耦合导致的模型失配问题, 提出一种基于可信残差补偿的模型预测控制方法。在低维名义模型基础上, 采用时间卷积网络(TCN)以历史轨迹误差和控制输入为特征, 预测有限时域内的模型残差; 根据预测残差与反馈残差的一致性构造可信系数, 对补偿量进行自适应缩放与限幅; 并采用DE-NSGA-II离线优化MPC权重参数。MuJoCo仿真表明: 与标准MPC相比, 所提方法使三工况平均横向误差RMSE降低82.3%, 输入变化率降低91.1%; 在“8”字形轨迹叠加突变水流扰动下, 横向误差RMSE较鲁棒MPC降低47.1%。结果表明, 可信残差补偿机制能有效修正模型失配误差, 在保证输入平滑性的同时显著提升轨迹跟踪精度。

关键词

仿生机器鱼, 模型预测控制, 残差补偿, 时间卷积网络, 轨迹跟踪

Model Predictive Trajectory Tracking Control for Biomimetic Robotic Fish Based on Confidence-Aware Residual Compensation

Jiahou Ye^{1,2}, Jiang Yu^{2,3*}, Guanhong Chen^{2,3}, Dingbin Ke^{2,3}, Jie Yang^{1,2}, Yuwei Zhang^{2,3}, Xiaotong Luo^{2,3}

¹College of Electronic and Information Engineering, Guangdong Ocean University, Zhanjiang Guangdong

*通讯作者。

文章引用: 叶嘉侯, 余江, 陈冠宏, 柯定彬, 杨捷, 张钰伟, 罗晓彤. 基于可信残差补偿的仿生机器鱼模型预测轨迹跟踪控制[J]. 建模与仿真, 2026, 15(10): 115-123. DOI: 10.12677/mos.2026.1510149

²Deep Blue Intelligent Electromechanical Product Innovation Team, Guangdong Ocean University, Zhanjiang Guangdong

³College of Mechanical Engineering, Guangdong Ocean University, Zhanjiang Guangdong

Received: September 26, 2026; accepted: October 19, 2026; published: October 26, 2026

Abstract

To address model mismatch in biomimetic robotic fish caused by periodic tail-fin propulsion and hydrodynamic coupling, a model predictive control method based on confidence-aware residual compensation is proposed. Based on a low-dimensional nominal model, a temporal convolutional network (TCN) is employed to predict model residuals over a finite prediction horizon using historical tracking errors and control inputs as features. A confidence coefficient is then constructed according to the consistency between the predicted and feedback residuals, enabling adaptive scaling and saturation of the compensation term. In addition, DE-NSGA-II is adopted to optimize the MPC weighting parameters offline. MuJoCo simulation results show that, compared with standard MPC, the proposed method reduces the average lateral tracking-error RMSE by 82.3% and the control-input variation rate by 91.1% across three operating conditions. For a figure-eight trajectory subjected to abrupt current disturbances, the lateral tracking-error RMSE is reduced by 47.1% compared with robust MPC. These results demonstrate that the proposed confidence-aware residual compensation mechanism can effectively mitigate model mismatch, significantly improving trajectory-tracking accuracy while maintaining smooth control inputs.

Keywords

Biomimetic Robotic Fish, Model Predictive Control, Residual Compensation, Temporal Convolutional Network, Trajectory Tracking

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

仿生机器鱼凭借高机动性与低噪声优势在海洋探测领域具有广阔的应用前景，但其流体耦合与周期推进特性导致模型呈现明显非线性与时变性，增加了高精度轨迹跟踪难度。虽然高保真水动力模型能改善预测性能，但计算负担过重[1]；因此，基于低维名义模型并利用数据驱动方法补偿未建模动态，是兼顾精度与实时性的有效途径[2]。现有鲁棒 MPC 与扰动观测器虽能处理外部干扰[3][4]，却难以捕捉周期推进产生的时序相关偏差。时间卷积网络(TCN)在提取时序依赖方面优势显著[5]，但将其引入 MPC 进行残差预测时，若遇突变工况或样本覆盖不足，学习模型的预测偏差可能导致控制过度修正[6]。此外，MPC 权重参数直接决定跟踪精度与输入平滑性的权衡，人工整定难以兼顾多目标最优且缺乏自适应性[7]。

针对上述问题，本文提出一种可信残差补偿 MPC 方法：① 利用 TCN 挖掘历史误差与控制输入的时序特征，预测有限时域模型残差以补偿名义模型；② 构造基于预测 - 反馈一致性的可信系数，对补偿量进行自适应缩放与限幅，抑制不可靠预测引发的性能恶化；③ 采用 DE-NSGA-II 算法离线整定 MPC 权重，实现多目标性能平衡。仿真结果验证了该方法在复杂工况下的有效性。

2. 基于 TCN 的残差预测与可信补偿

2.1. 平面轨迹误差与残差建模

本文主要研究仿生机器鱼在水平面内的轨迹跟踪控制问题，其深度控制由独立回路完成。系统的平面状态变量与控制输入分别定义为：

$$X_k = [x_k \ y_k \ \psi_k \ v_k \ r_k]^T, U_k = [u_{v,k} \ u_{r,k}]^T, \quad (1)$$

其中， x_k 和 y_k 为平面位置， ψ_k 为航向角， v_k 和 r_k 分别为前向速度和偏航角速度； $u_{v,k}$ 和 $u_{r,k}$ 分别为等效推进和转向控制量。采用平面运动学和一阶速度响应建立名义模型。

$$\begin{cases} \dot{x} = v \cos \psi, \\ \dot{y} = v \sin \psi, \\ \dot{\psi} = r, \\ \tau_v \dot{v} + v = K_v u_v, \\ \tau_r \dot{r} + r = K_r u_r. \end{cases} \quad (2)$$

其中， τ_v 和 τ_r 分别为前向速度和偏航角速度的响应时间常数， K_v 和 K_r 为相应输入增益。式(2)为 MPC 采用的低阶名义模型，其参数依据静水标称工况下仿真系统的等效推进与转向响应，通过一阶参数匹配确定。归一化控制输入下，前向速度和偏航角速度的等效动态分别为 $\dot{v} = -0.8v + 1.1u_v$ 和 $\dot{r} = -0.7r + 1.0u_r$ ，由此得到 $\tau_v = 1.25 \text{ s}$ 、 $\tau_r = 1.43 \text{ s}$ 、 $K_v = 1.375$ 和 $K_r = 1.429$ 。上述参数用于描述标称工作点附近的运动响应，并在全部仿真实验中保持不变。

平面轨迹误差的几何关系如图 1 所示。令 p_k ， p_k^r 分别为当前位置和参考位置， n_k^r 为参考轨迹单位法向量，定义误差状态为

$$\begin{cases} e_{y,k} = (n_k^r)^T (p_k - p_k^r), \\ e_{\psi,k} = \text{wrap}(\psi_k - \psi_k^r), \\ e_{v,k} = v_k - v_k^r, \\ e_{r,k} = r_k - r_k^r, \\ E_k = [e_{y,k} \ e_{\psi,k} \ e_{v,k} \ e_{r,k}]^T. \end{cases} \quad (3)$$

其中， e_y 、 e_ψ 、 e_v 和 e_r 分别为横向、航向、前向速度和偏航角速度误差； $\text{wrap}(\cdot)$ 将航向误差限制在 $(-\pi, \pi]$ 内。

根据参考速度和偏航角速度确定前馈控制量 U_k^r ，并定义控制偏差为 $\delta U_k = U_k - U_k^r$ 。离散化后得到采样周期为 0.05 s 的离散名义误差模型，并记为 $\hat{E}_{k+1}^{\text{nom}} = g_k(E_k, \delta U_k)$ 。

受柔性尾鳍、水动力变化及外部扰动的影响，实际响应与名义预测存在偏差[8]，定义一步模型残差为

$$D_k = E_{k+1} - \hat{E}_{k+1}^{\text{nom}} = [d_{y,k} \ d_{\psi,k} \ d_{v,k} \ d_{r,k}]^T, \quad (4)$$

其中， D_k 综合表征名义模型未描述的周期推进、水动力变化及外部扰动。基于上述定义，构建图 2 所示的可信残差补偿控制框架，其中残差学习与 MPC 分别承担模型修正和在线控制，权重优化在离线阶段完成。




Figure 1. Definition of planar trajectory tracking error for biomimetic robotic fish

图 1. 仿生机器鱼平面轨迹跟踪误差定义




Figure 2. Trustworthy residual compensation MPC overall control framework

图 2. 可信残差补偿 MPC 总体控制框架

2.2. TCN 残差预测与可信融合

相关性分析表明，系统残差与控制输入表现出明显的时序关联特征。为充分捕捉该动态特性，本文选取历史窗口长度 $L=128$ ，并将历史轨迹误差与前一时刻控制量组合，构造为 TCN 的输入向量 Z_k 。

TCN 采用因果膨胀卷积残差结构，给定历史窗口 Z_k ，让网络一次输出未来 N_p 步残差：

$$\hat{D}_k = F_{\theta}(Z_k) = \begin{bmatrix} \hat{D}_k^{(k)\top} \\ \hat{D}_{k+1}^{(k)\top} \\ \vdots \\ \hat{D}_{k+N_p-1}^{(k)\top} \end{bmatrix} \in \mathbb{R}^{N_p \times 4}, \quad (5)$$

其中, $F_\theta(\cdot)$ 表示参数为 θ 的 TCN 模型, 预测长度与 MPC 预测时域一致。为协调不同残差分量的学习精度, 网络采用加权均方差训练:

$$\mathcal{L}_k = \frac{1}{N_p} \sum_{i=0}^{N_p-1} \left(D_{k+i} - \hat{D}_{k+i}^{(k)} \right)^T \Lambda_d \left(D_{k+i} - \hat{D}_{k+i}^{(k)} \right). \quad (6)$$

其中, $\Lambda_d = \text{diag}(\lambda_y, \lambda_\psi, \lambda_v, \lambda_r)$ 为各残差分量的损失权重, 网络训练损失取全部样本窗口 $\mathcal{L}_k$ 的平均值。

为减弱异常预测对闭环控制的影响, 将上一周期预测残差与式(4)得到的反馈残差进行一致性比较, 并据此构造可信系数 $\eta_k \in (0, 1]$ 。可信残差定义为

$$\bar{D}_{k+i}^{(k)} = \eta_k \text{sat}_{D_{\max}} \left(\hat{D}_{k+i}^{(k)} \right), \quad i = 0, \dots, N_p - 1, \quad (7)$$

其中, η_k 由上一控制周期残差预测与反馈残差的归一化一致性误差确定; 一致性降低时, η_k 减小, 残差补偿幅值随之减弱。 $D_{\max}$ 为按残差分量设置的限幅向量, 用于约束补偿幅值, 不直接决定可信系数的敏感度。根据训练数据中各残差分量的幅值范围, 以正常残差不被过度截断、异常预测受到幅值约束为原则设置限幅阈值, 最终取 $D_{\max} = (0.030, 0.050, 0.050, 0.120)^T$, 各分量依次对应 d_y, d_ψ, d_v, d_r , 单位与相应残差分量一致。

3. 基于多目标权重优化的残差补偿 MPC 控制

3.1. 残差补偿 MPC 预测模型

$$\hat{E}_k^{(k)} = E_k, \quad \hat{E}_{k+i+1}^{(k)} = g_{k+i} \left(\hat{E}_{k+i}^{(k)}, \delta U_{k+i}^{(k)} \right) + \bar{D}_{k+i}^{(k)}, \quad (8)$$

其中, $\hat{E}_{k+i}^{(k)}$ 表示时刻 k 对未来第 i 步轨迹误差的预测值, $\delta U_{k+i}^{(k)}$ 表示为对应的控制偏差, 可信残差仅修正名义模型, 控制序列仍由 MPC 在线求解。

MPC 综合考虑轨迹误差、控制作用和输入变化, 归一化控制输入后定义目标函数为:

$$J_k = \sum_{i=1}^{N_p-1} \left(\hat{E}_{k+i}^{(k)} \right)^T Q \hat{E}_{k+i}^{(k)} + \sum_{i=0}^{N_p-1} \left(\delta U_{k+i}^{(k)} \right)^T R \delta U_{k+i}^{(k)} + \sum_{i=0}^{N_p-1} \left(\Delta U_{k+i}^{(k)} \right)^T S \Delta U_{k+i}^{(k)} + \left(\hat{E}_{k+N_p}^{(k)} \right)^T P \hat{E}_{k+N_p}^{(k)}, \quad (9)$$

其中, Q 、 R 、 S 分别为误差、控制作用和输入变化权重, P 为终端权重; 预测首步的输入变化相对于上一周期实际控制量计算。引入可信残差补偿后, 预测模型在保留名义模型结构的基础上, 对周期推进、水动力变化及外部扰动引起的模型失配进行修正。由此, 有限时域内的预测模型的响应更接近真实系统的动态响应, 为 MPC 滚动优化提供更可靠的预测基础。

3.2. MPC 权重的 DE-NSGA-II 离线寻优

MPC 权重决定跟踪精度、控制作用和输入平滑性之间的折中。Vallerio 等[9]将 NMPC 权重整定转化为多目标优化问题。本文采用 DE-NSGA-II 对主要权重进行多工况离线优化, 待优化参数为:

$$\Omega = (q_y, q_\psi, q_v, q_r, r_u, s_{\Delta u})^T, \quad (10)$$

其中, q_y, q_ψ, q_v 和 q_r 对应 Q 的四个对角权重, r_u 和 $s_{\Delta u}$ 分别对应 R 和 S , 对每组候选 Ω , 在代表性工作点线性化名义模型, 并由离散 Riccati 方程确定终端权重 P 。

每组候选权重均在直线、圆形和 S 形工况下进行闭环评价, 对发散或持续饱和的解施加惩罚。将误差和控制输入按允许范围归一化, 并定义三个优化目标:

$$F_{1,s}(\Omega) = \frac{1}{K_s} \sum_{k=1}^{K_s} \tilde{E}_{k,s}^T \tilde{E}_{k,s}, \quad (11)$$

$$F_{2,s}(\Omega) = \frac{1}{K_s} \sum_{k=1}^{K_s} \tilde{U}_{k,s}^T \tilde{U}_{k,s}, \quad (12)$$

$$F_{3,s}(\Omega) = \frac{1}{K_s - 1} \sum_{k=2}^{K_s} \Delta \tilde{U}_{k,s}^T \Delta \tilde{U}_{k,s}, \quad (13)$$

其中, F_1 、 F_2 、 F_3 分别评价跟踪误差、控制作用和输入变化, 并对三类工况等权汇总, s 为工况索引, K_s 为该工况采样点数。因此, 权重整定写为

$$\min_{\Omega} (F_1(\Omega), F_2(\Omega), F_3(\Omega))^T, \quad (14)$$

受 Peng 等[10]采用差分进化算子进行多目标搜索的思路启发, 本文在 NSGA-II 中引入差分变异和交叉生成候选个体, 并通过非支配排序和拥挤距离完成筛选。DE-NSGA-II 的种群规模为 20, 最大迭代次数为 40, 采用随机基向量、单差分向量和二项交叉的 DE/rand/1/bin 策略生成试验个体, 差分权重 $F = 0.7$, 交叉概率 $CR = 0.8$ 。六个待优化权重 $q_y, q_\psi, q_v, q_r, r_u, s_{\Delta u}$ 的搜索范围依次为 $[1, 80]$ 、 $[1, 40]$ 、 $[1, 30]$ 、 $[1, 20]$ 、 $[0.01, 2]$ 和 $[0.01, 5]$ 。差分变异对每个目标个体执行, 不另设独立变异概率。NSGA-II 与 DE-NSGA-II 采用相同的种群规模、迭代次数及参数搜索范围。

3.3. 执行与深度控制

本研究的实际控制输入由尾鳍的摆动频率、摆幅和中心偏置角三个关键参数构成。

$$f_k = h_f(u_{v,k}), A_k = h_A(u_{v,k}), \theta_{0,k} = h_\theta(u_{r,k}), \quad (15)$$

其中, MPC 输出经标定映射转换为尾鳍摆动频率 f_k 、摆幅 A_k 和中心偏置角 $\theta_{0,k}$ 。深度方向采用独立 PID 回路跟踪给定轨迹, 深度测量滤波后反馈给控制端。至此, 通过平面姿态的 MPC 控制与深度方向的 PID 调节, 实现了机器鱼在三维空间内的全状态轨迹跟踪控制。

4. 仿真实验与结果讨论

4.1. 仿真环境与评价指标

本文在 MuJoCo 物理引擎中建立闭环仿真系统(周期 0.05 s), 涵盖直线、圆形、S 形及水流工况。采用完整轨迹划分数据集, 并以“8”字形轨迹独立测试泛化性。实验包括残差预测、消融及多工况测试。预测用 RMSE/NRMSE 评价; 控制用横向误差 RMSE、MaxAE、IAE 及平滑度衡量; 定义恢复时间为扰动后至误差连续 1 s 收敛于 0.03 m 的时间, 以量化抗扰性。

4.2. 实验结果与分析

4.2.1. 残差预测与可信融合性能

如表 1 所示, TCN 的综合 NRMSE 为 0.061, 在五种对比模型中表现最优。尽管 LSTM 与 GRU 在部分单分量预测中取得了略优的数值, 但 TCN 展现出了更为均衡且卓越的综合预测性能。

如图 3 所示, 在突变水流干扰下, TCN-CF-MPC 凭借可信融合机制显著优于 TCN-MPC: 最大横向误差从 0.1477 m 降至 0.1278 m, 恢复时间由 7.00 s 缩短至 5.10 s。这表明可信系数成功抑制了预测偏差引起的过度补偿, 增强了系统的抗扰动能力。为分析残差限幅参数的敏感性, 由式(7)可知, 该参数仅在预测残差超过设定阈值时影响补偿结果。对于第 j 个残差分量, 当 $|\hat{d}_{j,k+i}^{(k)}| \leq D_{\max,j}$ 时, 可信补偿量为 $\eta_k \hat{d}_{j,k+i}^{(k)}$, 限幅阈值在不触发限幅的范围内变化不影响补偿结果; 当 $|\hat{d}_{j,k+i}^{(k)}| > D_{\max,j}$ 时, 可信补偿量为

$\eta_k D_{\max,j} \operatorname{sgn}(\hat{d}_{j,k+i}^{(k)})$ ，其幅值对限幅阈值的变化率为 η_k 。因此，减小 $D_{\max}$ 可增强对异常预测的幅值约束，但过小的阈值可能截断正常残差，造成补偿不足；增大 $D_{\max}$ 则可保留更多预测信息，但同时提高异常补偿的幅值上限。本文根据训练数据中的残差幅值范围设置初始限幅，并采用 1.25 倍裕量确定最终参数，以协调正常残差补偿与异常预测抑制。

Table 1. The testing performance of different residual prediction models
表 1. 不同残差预测模型的测试性能

模型	RMSE(d_y)/m	RMSE(d_ψ)/rad	RMSE(d_v)/(m/s)	RMSE(d_r)/(rad/s)	NRMSE
MLP	0.00295	0.00184	0.00093	0.00136	0.090
LSTM	0.00169	0.00135	0.00086	0.00108	0.067
GRU	0.00207	0.00124	0.00080	0.00073	0.065
Transformer	0.00209	0.00131	0.00085	0.00109	0.071
TCN	0.00183	0.00121	0.00072	0.00084	0.061




Figure 3. Reliable fusion response under turbulent flow
图 3. 突变水流下的可信融合响应

4.2.2. 离线权重优化结果

在相同种群规模和迭代次数下，DE-NSGA-II 的终代理想点距离和超体积分别为 0.035 和 0.956，优于 NSGA-II 的 0.091 和 0.868。依据理想点距离选取折中权重为 $(q_y, q_\psi, q_v, q_r, r_u, s_{\Delta u}) = (41.73, 23.61, 16.28, 10.14, 0.417, 1.362)$ ，并固定用于后续闭环实验。

4.2.3. 消融实验

各模块的消融实验结果如表 2 所示(指标取三种工况平均值)。由表可知，残差预测是降低稳态误差的关键，使平均 RMSE 由 0.1691 m 降至 0.0548 m。在此基础上引入可信融合机制，虽然平均 RMSE 略有波动，但大幅改善了峰值与恢复时间，验证了其抑制过度补偿的有效性。结合离线权重整定后，本文方法取得了最佳控制效果，平均 RMSE 和 F_3 分别降至 0.0300 m 和 1.44×10^{-5} ，较传统 MPC 分别降低了 82.3%和 91.1%。

4.3. 综合闭环性能

图 4 给出多工况轨迹跟踪结果。圆形恒定水流和 S 形随机水流下，本文方法的横向 RMSE 分别为 0.0277 m 和 0.0338 m；“8”字形突变水流下的定量结果见表 3，其 RMSE、最大横向误差和 IAE 较鲁棒

Table 2. The results of the ablation experiment
表 2. 消融实验结果

方法	RMSE(e_y)/m	Max(e_y)/m	IAE(e_y)	恢复时间/s	F_3
普通 MPC	0.1691	0.3114	3.0214	>12.0	1.62e-04
TCN-MPC	0.0548	0.1477	0.9529	7.00	2.05e-04
TCN-CF-MPC	0.0586	0.1278	1.0192	5.10	3.80e-05
本文方法	0.0300	0.0796	0.5168	4.00	1.44e-05

Table 3. Performance comparison of different control methods under the “8”-shaped sudden flow condition
表 3. “8” 字形突变水流工况下不同控制方法的性能比较

方法	RMSE(e_y)/m	Max $ e_y $ /m	IAE/(m·s)	RMSE(e_ψ)/rad	RMSE(e_v)/(m/s)	RMSE(e_r)/(rad/s)
PID	0.2460	0.4626	4.1721	1.0195	0.1136	1.7198
LOS-PID	0.1760	0.3642	2.9535	0.7752	0.0937	1.4218
模糊滑模	0.1370	0.3224	2.2220	0.6550	0.0772	1.3428
鲁棒 MPC	0.0780	0.2053	1.2035	0.2345	0.0567	0.5932
本文方法	0.0413	0.1171	0.6068	0.0981	0.0302	0.2108




Figure 4. Multi-condition trajectory tracking results
图 4. 多工况轨迹跟踪结果

MPC 分别降低 47.1%、43.0%和 49.6%。深度误差 RMSE 为 0.0067 m，完整控制流程 p95 计算时间为 21.8 ms，低于 50 ms 控制周期。

5. 结论

针对仿生机器鱼在周期推进与外部水流干扰下的模型失配难题，本文提出了一种基于可信残差补偿的模型预测控制(TCN-CF-MPC)方法。该方法利用 TCN 网络挖掘历史状态信息以预测有限时域内的模型残差，引入可信融合机制以在预测置信度低时抑制异常补偿，并采用 DE-NSGA-II 算法离线寻优以平衡跟踪精度与控制平滑性。消融实验表明，残差预测显著降低了稳态跟踪误差，可信融合机制有效抑制了突变阶段的误差峰值与过度补偿，离线权重整定进一步优化了系统综合性能。实验结果显示，相较于传统 MPC，本文方法在三种工况下的平均横向 RMSE 和输入变化率分别降低了 82.3%和 91.1%；在“8”字形突变水流测试中，横向 RMSE 较鲁棒 MPC 降低了 47.1%，且在线计算耗时满足实时控制要求。未来

工作将开展复杂水流环境下的实物水池实验，并研究面向时变动力学的在线残差自适应修正策略。

基金项目

广东省大学生创新创业训练计划项目“融合 MPC-TF 控制与 STDnet-ST 视觉的水下救援仿生鱼设计”；项目编号：S202610566008；广东海洋大学深蓝智能机电产品创新团队。

参考文献

- [1] Wang, Z.P., Li, Z.G., Xia, G.Q., Kang, H.F., *et al.* (2025) Data-Driven Dynamic Modeling for Precise Trajectory Tracking of a Bio-Inspired Robotic Fish. *Applied Ocean Research*, **156**, Article 104463. <https://doi.org/10.1016/j.apor.2025.104463>
- [2] Zhang, H., Ge, J., Su, J., Gu, K., Wang, F., Chen, W., *et al.* (2025) Model Predictive Control with Residual Learning and Real-Time Disturbance Rejection: Design and Experimentation. *Control Engineering Practice*, **165**, Article 106587. <https://doi.org/10.1016/j.conengprac.2025.106587>
- [3] Yan, Z.P., Yan, J.Y., Cai, S.J., *et al.* (2023) Robust MPC-Based Trajectory Tracking of Autonomous Underwater Vehicles with Model Uncertainty. *Ocean Engineering*, **286**, Article 115617. <https://doi.org/10.1016/j.oceaneng.2023.115617>
- [4] Wang, X.Q., Wang, M., Liu, X.Y., Pan, S.D. and Yu, J.Z. (2026) Trajectory Tracking and Obstacle Avoidance Control for a Bionic Robotic Fish Based on NDOB and Online Parameter Adaptation. *Ocean Engineering*, **358**, Article 125800. <https://doi.org/10.1016/j.oceaneng.2026.125800>
- [5] Zhang, X., He, B., Gao, S., Zhou, L.Q. and Huang, R.H. (2023) Sequential Learning Navigation Method and General Correction Model for Autonomous Underwater Vehicle. *Ocean Engineering*, **278**, Article 114347. <https://doi.org/10.1016/j.oceaneng.2023.114347>
- [6] Wang, Y., Sun, Z., Tian, X., Jia, Y., Li, H., Wang, B., *et al.* (2026) Trajectory Tracking Control of Autonomous Underwater Vehicles Using GP-Based Model Predictive Control. *Drones*, **10**, Article 498. <https://doi.org/10.3390/drones10070498>
- [7] Li, J.W., Xia, Y.K., Xu, G.H., *et al.* (2024) Enhanced Three-Dimensional Trajectory Tracking Control for AUVs in Variable Operating Conditions Using FMPC-FTTSMC. *Ocean Engineering*, **310**, Article 118805. <https://doi.org/10.1016/j.oceaneng.2024.118805>
- [8] Chen, Z.G., Tian, X.L., Chen, X., Wen, B.R. and Li, X. (2023) An Experimental Study of the Wire-Driven Compliant Robotic Fish. *Ocean Engineering*, **279**, Article 114433. <https://doi.org/10.1016/j.oceaneng.2023.114433>
- [9] Vallerio, M., Van Impe, J. and Logist, F. (2014) Tuning of NMPC Controllers via Multi-Objective Optimisation. *Computers & Chemical Engineering*, **61**, 38-50. <https://doi.org/10.1016/j.compchemeng.2013.10.003>
- [10] Peng, W., Wei, C.G., Yang, J.H., Chen, X.R., Qi, B.Z., *et al.* (2025) Rolling Schedule Design for the ESP Rolling Process Based on NSGA-II-DE. *ISA Transactions*, **158**, 427-441. <https://doi.org/10.1016/j.isatra.2024.12.047>