

# 基于物理信息神经网络的船舶自动靠泊自适应控制研究

## Research on Adaptive Control for Automatic Ship Berthing Based on Physics-Informed Neural Networks

张圣超<sup>1,2</sup>, 高俊杰<sup>3</sup>, 殷非<sup>4</sup>, 刘志刚<sup>3</sup>, 李玩幽<sup>1</sup>  
ZHANG Shengchao<sup>1,2</sup>, GAO Junjie<sup>3</sup>, YIN Fei<sup>4</sup>, LIU Zhigang<sup>3</sup>, LI Wanyou<sup>1</sup>

1. 哈尔滨工程大学 动力与能源工程学院, 哈尔滨 150001

College of Power and Energy Engineering, Harbin Engineering University, Harbin 150001, China

2. 厦门港务船务有限公司, 厦门 361012

Xiamen Port Shipping Co., Ltd., Xiamen 361012, China

3. 上海海事大学 商船学院, 上海 201306

Merchant Marine College, Shanghai Maritime University, Shanghai 201306, China

4. 上海船舶设备研究所, 上海 200031

Shanghai Marine Equipment Research Institute, Shanghai 200031, China

摘要

Abstract

【DOI】10.13788/j.cnki.cbgc.2026.03.Z2

[目的] 现有的自主靠泊技术依赖于精确的数学船舶模型, 且多采用经验公式进行建模, 然而在实际的靠泊场景中, 受到环境、速度等影响, 这些方法无法实时精确地反映当前的船舶操纵状态, 导致靠泊控制精度受限。为解决上述问题, [方法] 提出一种基于物理信息神经网络 (PINN) 的船舶自主靠泊控制方法, 该方法通过构建基于滑动窗口的实时数据集, 通过物理神经网络实时辨识船舶操纵参数, 设计基于增益调度的自适应控制器, 利用辨识出的参数动态调整控制增益, 实现船舶的精确靠泊。[结果] 试验结果显示, PINN 网络能够在动态工况下迅速收敛, 准确辨识船舶参数, 拟合优度达到 0.97, 在靠泊试验中, 确保终端航向角偏差与横向误差收敛至极小范围, 实现平滑、安全的停靠, 航向误差为  $0.13^\circ$ 。[结论] 该方法有效解决在船舶参数未知、复杂工况下, 传统控制算法因模型失配而失效的问题, 提供一种安全、可解释的自适应靠泊控制。

[Purpose] Existing autonomous berthing technologies rely on precise mathematical ship models and mostly employ empirical formulas for modeling. However, in actual berthing scenarios, influenced by environmental factors and speed, these methods cannot accurately reflect the current ship maneuvering status in real-time, leading to limited berthing control accuracy. To address the aforementioned problems, [Method] a ship autonomous berthing control method based on physics-informed neural networks (PINN) is proposed. The method constructs a real-time dataset using a sliding window and identifies ship maneuvering parameters in real-time through the physics-informed neural network. An adaptive controller based on gain scheduling is designed to dynamically adjust control gains using the identified parameters, realizing precise ship berthing. [Result] Experimental results demonstrate that the PINN network can converge rapidly under dynamic conditions and accurately identify ship parameters, with a goodness of fit reaching 0.97. In berthing experiments, the method ensured that the terminal heading deviation and lateral error converged to a minimal range, achieving smooth and safe docking, with a heading error of  $0.13^\circ$ . [Conclusion] The method effectively resolves the failure of traditional control algorithms caused by model mismatch under unknown ship parameters and complex working conditions, offering a safe and interpretable adaptive berthing control solution.

物理信息神经网络; 自主靠泊; 自主水面船舶; 自适应控制  
physics-informed neural network (PINN); autonomous berthing; maritime autonomous surface ship (MASS); adaptive control

## 0 引言

自主水面船舶 (Maritime Autonomous Surface Ships, MASS) 的自动靠泊是指在无人工干预条件下, 使船舶精准停靠于指定泊位点的控制过程。该项技术的实现, 对于提升港口作业效率, 减少人为误操作引起的事故风险具有决定性意义。尽管自主靠泊技术已得到广泛研究, 但现有的自主靠泊方案多基于理想化的确定性模型, 这导致其在实际应用中面临严峻挑战。其主要原因在于一方面对未知船舶的水动力参数的先验信息匮乏, 难以实现精确建模; 另一方面, 受限水域的物理环境导致模型参数发生变化, 使得传统控制架构难以保证理想的控制性能。因此, 如何突破对先验精确模型的依赖, 构建一种能够在参数未知条件下实时捕捉水动力特征变化, 并实现船舶精准靠泊的控制方法, 是实现 MASS 自主靠泊亟待解决的核心问题。

MIZUNO 等<sup>[1]</sup>提出以时间与能耗协同优化为核心的最短时间靠泊控制方法, 实现了船舶的快速靠泊; MAKI 等<sup>[2]</sup>提出了一种基于协方差矩阵适应演化策略 (Covariance Matrix Adaption Evolution Strategy, CMA-ES) 的最优控制方法, 用于执行自动对接, 其中构建了一个最小时间优化问题以实现最优控制。此外也有研究者采用基于非线性模型预测控制 (Nonlinear Model Predictive Control, NMPC) 的方法<sup>[3-6]</sup>, 通过减少当前状态与期望状态的偏差, 采用多目标优化策略, 最终使船舶成功对接到期望的对接点。纵观上述研究成果, 现有的自主靠泊技术大多建立于确定的船舶动力学模型基础上, 靠泊控制的性能的优劣很大程度上都依赖于模型的建立, 然而实际应用中, 船舶往往缺乏先验标定数据, 导致初始

模型存在显著的参数不确定性。

为解决模型参数难以准确获取以及环境干扰导致的不确定性问题, 现有的参数辨识方法的研究包括基于最小二乘法 (Least Squares, LS) 及其改进算法<sup>[7]</sup>、卡尔曼滤波 (Kalman Filter, KF)<sup>[8]</sup>及遗传算法<sup>[9]</sup>以及支持向量机 (Support Vector Machine, SVM)<sup>[10-11]</sup>等回归算法。随着神经网络技术的发展, 赵永生等<sup>[12]</sup>采用径向基函数神经网络逼近船舶模型中的动态不确定参数并实现了船舶的安全靠泊; ZHAO 等<sup>[13]</sup>开发了深度神经网络实现了极短时间内船舶运动参数的预测; 前者多依托明确的船舶运动机理模型框架, 后者虽无需预设固定机理模型但依赖大量的训练数据且缺乏物理的可解释性。

对此, 提出物理信息神经网络 (Physics-Informed Neural Networks, PINN) 是一种新颖的混合建模框架, 通过将偏微分方程或动力学方程直接嵌入神经网络的损耗函数, 将数据驱动学习与物理约束相结合, 用于动态系统建模<sup>[14]</sup>; 夏召丹等<sup>[15]</sup>构建了静水中的基于 PINN 的船舶操纵运动模型; 赵东岳等<sup>[16]</sup>提出了一种基于物理信息神经网络的预报方法, 实现了对船舶约束模水动力的预报; 这些研究表明了 PINN 在船舶操纵性研究的可行性。

现有研究尚未将该方法运用到船舶自主靠泊中。基于此, 本文提出一种基于物理信息神经网络的船舶自动靠泊自适应控制方法。首先提出基于 PINN 的在线辨识网络, 实时估计船舶参数, 然后设计基于辨识参数的自适应控制方法, 实现船舶的精准靠泊; 最后验证方法的可行性。

# 1 基于 PINN 的在线辨识网络设计

## 1.1 网络架构

传统的船舶参数辨识方法受限于数学模型的精确度，基于数据驱动深度学习模型如长短期记忆网络 (Long Short-Term Memory, LSTM)<sup>[17]</sup> 虽然具备较好的非线性逼近能力，但内部的隐式映射导致输出的结果缺乏物理可解释性。因此，本文提出一种基于 PINN 的在线参数辨识网络。网络架构见图 1。

该网络架构分为 4 个模块，输入与输出模块以归一化的时间标量  $t$  作为输入，输出对应时刻

的预测回转角速度  $\hat{r}(t)$ ；运动状态逼近模块利用深度神经网络，实现对船舶低速状态下操纵响应的连续建模；参数辨识模块将水动力系数  $K$  和  $T$  转化为动态变量，赋予系统对未知参数的在线调节能力；物理约束模块通过自动微分，将 1 阶 Nomoto 模型的动力学方程作为物理约束嵌入到网络中。4 个模块协同迭代，既实现了数据拟合也满足了物理约束，有效克服了传统经验公式带来的模型失配的问题。

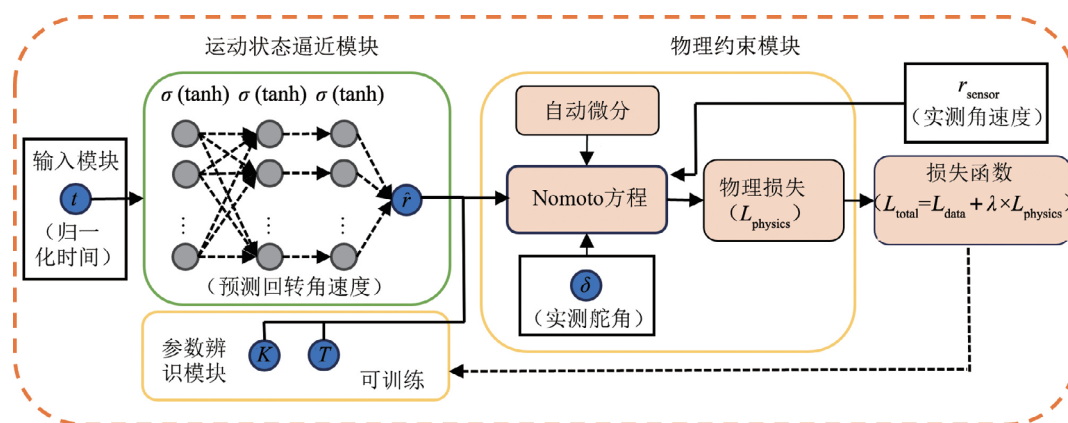


图 1 基于 PINN 的船舶参数在线辨识网络架构

Fig. 1 Online Identification Network Architecture of Ship Parameters Based on PINN

## 1.2 辨识参考模型

为实现实时的船舶参数辨识和控制器设计，若直接选用多维、强耦合的船舶操纵性数学模型 (Maneuvering Modeling Group Model, MMG) 模型作为 PINN 的物理约束模型，会导致计算复杂度高出现难以收敛的情况，因此本文选用 1 阶的野本模型作为物理约束模型。通过时变的参数精确反映船舶的操纵特性。

根据 Nomoto 提出的理论，船舶舵角与回转角速度之间的关系可近似为

$$\frac{r(s)}{\delta(s)} = \frac{K}{1+Ts} \quad (1)$$

通过拉普拉斯逆变换得到

$$T\dot{r}(t) + r(t) = K\delta(t) \quad (2)$$

式 (1) 和式 (2) 中： $r(s)$  为船舶的回转角速度； $\delta(s)$  为实际执行的舵角； $K$  为船舶在单位舵角下的转舵角速度，即旋回性指数， $K$  值越大，船舶的舵效越好，转向能力越强； $T$  为船舶相应舵令的快慢，即惯性时间常数， $T$  值越小，船舶操纵响应越迅速； $s$  为拉普拉斯算子代表复频域变量； $t$  为连续的时间变量。

本文聚焦自动靠泊场景，船舶受低速以及浅水效应的影响， $K$  和  $T$  会呈现出强烈的时变特性。

因此本研究将 Nomoto 模型中的系数视为未知的时变参数，利用物理信息神经网络反向求解真实

参数，通过这种方式来有效解决传统固定参数模型或未知参数模型在靠泊场景下的局限性。

### 1.3 物理约束损失函数

物理信息神经网络的核心思想是将先验物理知识融入机器学习框架中，通过设计合理的损失函数来约束网络的训练。本文构建了联合损失函数  $L_{\text{total}}$ ，联合损失函数由 2 部分加权构成

$$L_{\text{total}} = L_{\text{data}} + \lambda L_{\text{physics}} \quad (3)$$

式中： $\lambda$  为物理约束的权重系数，决定了算法在数据置信度与物理机理置信度之间的平衡关系。

$L_{\text{total}}$  用于衡量网络输出与传感器实测状态之间的误差，确保模型能够准确拟合观测数据见式 (4)，该损失函数通过均方误差的方式计算：

$$L_{\text{data}} = \frac{1}{N} \sum_{i=1}^N \|\hat{r}(t_i) - r_{\text{sensor}}(t_i)\|^2 \quad (4)$$

### 1.4 在线滑动窗口学习策略

船舶靠泊是一个实时变化的过程，水动力参数受到低速以及环境的影响会呈现时变特性。若采用历史数据的离线训练方式，生成的网络参数无法满足当前的实时工况。为此，本文设计了基于先进先出 (First-in-First-Out) 机制的在线滑动窗口学习策略，通过截断记忆机制实现网络参数的实时变化。令  $k$  为当前离散控制步长，定义时序观测集  $S_k$  为

$$S_k = (t_i, \delta_i, r_{\text{sensor},i})_{i=k-N+1}^k \quad (7)$$

随着时间的更新，窗口  $S_k$  动态吸收最新的状态向量并同步剔除最前端的旧数据，从而在时间域上截断了过去历史数据对参数空间的梯度贡献。

式中： $N$  为滑动窗口内的样本总数； $\hat{r}(t_i)$  为网络在  $t_i$  时刻预测出的回转角速度； $r_{\text{sensor}}(t_i)$  为  $t_i$  实际的回转角速度。

$L_{\text{physics}}$  用来保障时变参数  $(K, T)$  的合理性，使神经网络的预测结果满足船舶操纵性的基本方程，该损失项通过式 (5) 和式 (6) 计算得到

$$f(t_i) = \hat{T} \frac{d\hat{r}(t_i)}{dt} + \hat{r}(t_i) - K\delta(t_i) \quad (5)$$

$$L_{\text{physics}} = \frac{1}{N} \sum_{i=1}^N \|f(t_i)\|^2 \quad (6)$$

式 (5) 和式 (6) 中： $\delta(t_i)$  为实际输入的舵角； $\hat{K}$  和  $\hat{T}$  为网络正在辨识的瞬时水动力系数； $f(t_i)$  为船舶运动模型的动力学误差。

在参数更新机制上，辨识系统的更新与控制系统同步，以特定的控制步数间隔启动优化，在每个更新的触发点，系统以  $S_k$  为微批量样本，利用反向传播算法驱动优化器求解如下目标函数：

$$(\theta^*, \hat{K}_k^*, T_k^*) = \arg \min_{\theta, \hat{K}, T} L_{\text{total}}(S_k; \theta, K, T) \quad (8)$$

式中： $\theta$  为神经网络的权重集； $\hat{K}_k^*$  和  $T_k^*$  分别为  $k$  时刻更新收敛的水动力参数； $\theta^*$ 、 $\hat{K}_k^*$ 、 $T_k^*$  为最优解。

这种参数更新机制能够使辨识系统在短时间内更新水动力参数，确保向自适应控制器输送的模型参数具备严格的动力学一致性与高实时保真性。

## 2

## 基于辨识参数的自适应控制

### 2.1 控制系统总体架构

针对 MASS 在受限水域靠泊工况下面临的水动力参数不确定性的情况，本文构建一种基于辨识参数的自适应控制方法，见图 2。该方法采用

闭环时序控制的方法，在每个离散控制周期内，系统先获取当前时刻下的船舶运动状态向量，并将其输入至参数辨识系统；参数辨识系统的核心

是基于 PINN 的辨识网络。通过参数辨识系统实时输出当前工况下的瞬时水动力系数估计值；自适应控制系统读取最新的参数估计值，在线计算并更新控制器的反馈增益矩阵与前馈补偿项，实

现控制率的动态更新；最后更新后的控制器根据当前轨迹跟踪误差计算最终的舵角与转速指令，控制船舶运动，从而实现船舶沿规划轨迹安全靠泊。

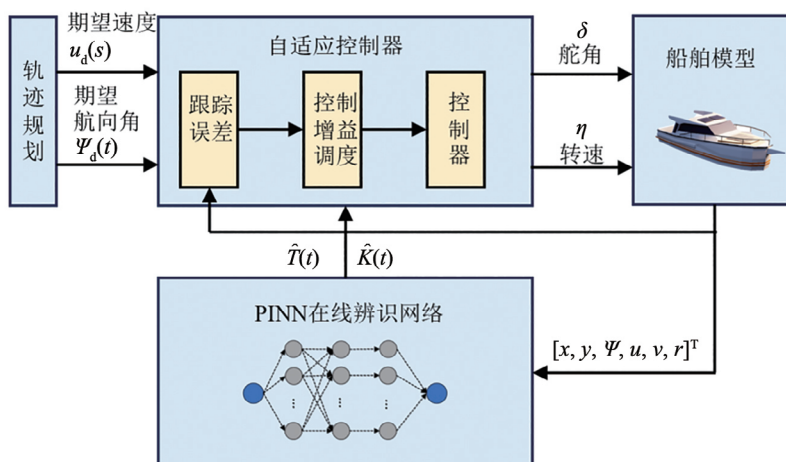


图2 控制系统总体架构

Fig. 2 Overall Architecture of Control System

上述闭环迭代的过程建立在确定性等价原理的基础上，控制器在每一时刻将参数辨识系统输出的瞬态水动力系数估计值视为系统的真实参数，从而避免了对参数估计误差协方差的复杂的

非线性补偿。这一机制在保证控制精度的同时，显著降低了自适应控制设计的复杂度，确保了系统在参数持续演化的非平稳过程中具备良好的实时性与工程可行性。

## 2.2 自适应航向保持控制

在低速靠泊阶段，受限水域的岸壁效应与浅水效应会导致船舶操纵性指数  $K$  大幅衰减以及惯性时间常数  $T$  增加，传统的固定增益控制器难以维持良好的操纵性能。为克服该问题，本研究提出一种结合前馈补偿与状态反馈的自适应控制策略。

靠泊轨迹跟踪的关键是保持当前航向与预定航向保持一致，因此系统采用前馈补偿的比例微分算法来实现航向的控制。

$$e_{\psi}(t) = \psi_d(t) - \psi(t) \quad (9)$$

式中： $e_{\psi}(t)$  为航向跟踪误差； $\psi_d(t)$  为当前时刻的期望航向； $\psi(t)$  为当前时刻的实际航向。

其时域数学表达式如式 (10) 所示。定义航向跟踪误差为  $e_{\psi}(t)$

$$\delta(t) = K_p(t)e_{\psi}(t) - K_d(t)r(t) + \delta_{ff}(t) \quad (10)$$

式中： $\delta(t)$  为输出至舵机的舵角指令； $K_p(t)$  与  $K_d(t)$  分别为待设计的时变比例增益与微分增益； $r(t)$  为船舶当前时刻的回转角速度； $\delta_{ff}(t)$  为基于期望轨迹的前馈补偿项，用于预先平衡已知轨迹所需的转向力矩。

为了计算获得最优控制增益  $K_p(t)$  与  $K_d(t)$ ，将上述控制律代入基于确定性等价原理的 1 阶 Nomoto 动力学方程中式 (11)。经过拉普拉斯变换，推导出闭环系统的二次误差动力学方程，如式 (12) 所示，为确保船舶在全速域靠泊过程中具备一致的动态响应品质，系统须保证上述 2 阶误差系统的特征根始终配置在期望位置。引入标准 2 阶系统的期望特征方程式 (13)：

$$\hat{T}(t)\dot{r}(t)+r(t)=K(t)\delta(t) \quad (11)$$

$$\ddot{e}_\psi(t)+\frac{1+\hat{K}(t)K_d(t)}{\hat{T}(t)}\dot{e}_\psi(t)+\frac{\hat{K}(t)K_p(t)}{T(t)}e_\psi(t)=0 \quad (12)$$

$$s^2+2\zeta\omega_n s+\omega_n^2=0 \quad (13)$$

式(13)中： $\zeta$ 为期望的闭环阻尼比，决定了系统超调量的大小； $\omega_n$ 为期望自然频率，决定了系统的响应速度。

通过对比闭环误差方程与期望特征方程的对应系数可以得出 $K_p(t)$ 与 $K_d(t)$ 。

### 2.3 纵向速度规划与跟踪控制

自动靠泊的关键约束是实现终端位置的零速停靠，为解决时间域规划在终端约束上的不确定性，本文构建了基于剩余航程的空间域速度规划器。定义船舶距离泊位中心的欧式剩余航程 $s(t)$ 为

$$s(t)=\sqrt{[x_d-x(t)]^2+[y_d-y(t)]^2} \quad (16)$$

式中： $x_d$ 为目标位置的横坐标； $y_d$ 为目标位置的纵坐标； $x(t)$ 为实际位置的横坐标； $y(t)$ 为实际位置的纵坐标。

为确保速度指令的单调收敛与平滑过渡，设计基于双曲正切函数的空间域速度剖面 $u_d(s)$ 为

$$u_d(s)=\begin{cases} u_{\min}+(u_{\text{appr}}-u_{\min}) \\ \quad \tanh\left(\lambda\frac{s}{s_{\text{de}}}\right) & s>0 \\ 0 & x\leq 0 \end{cases} \quad (17)$$

式中： $u_{\min}$ 为最小靠泊速度； $u_{\text{appr}}$ 为初始速度； $s_{\text{de}}$ 为减速航程阈值。

$$K_p(t)=\frac{\hat{T}(t)\omega_n^2}{\hat{K}(t)} \quad (14)$$

$$K_d(t)=\frac{2\zeta\omega_n\hat{T}(t)-1}{\hat{K}(t)} \quad (15)$$

控制增益与 $\hat{K}(t)$ 成反比关系， $\hat{K}(t)$ 与 $\hat{T}(t)$ 成正比关系。这意味着当PINN感知到船舶的回转能力下降或惯性增大时，算法会自动提升反馈增益，利用逆模型补偿机制来保障操纵性能，从而确保靠泊过程的航向稳定性。

纵向跟踪控制在于调节螺旋桨转速 $\eta$ 以实现跟踪对 $u_d$ 的跟踪。基于1阶纵向动力学式(18)，设计自适应控制率，并利用PINN辨识得到的惯性时间常数对比例增益进行实时调整：

$$T_u\dot{u}+u=K_u n \quad (18)$$

$$n_c(t)=n_{\text{ff}}+K_{p,u}(t)e_u(t)+K_{i,u}\int_0^t e_u(\tau)d\tau \quad (19)$$

$$e_u=u_d(s)-u \quad (20)$$

$$K_{p,u}(t)=\alpha\hat{T}(t) \quad (21)$$

式(18)~式(21)中： $T_u$ 为船舶纵向运动的惯性时间常数； $u$ 为船舶当前的实际纵向速度； $K_u$ 为船舶纵向运动的稳态增益； $n_c(t)$ 为 $t$ 时刻的螺旋桨指令转速； $n_{\text{ff}}$ 为前馈指令转速； $K_{p,u}(t)$ 为随时间动态调整的比例控制增益； $K_{i,u}$ 为随时间动态调整的积分控制增益； $e_u(t)$ 为 $t$ 时刻的纵向速度跟踪误差； $e_u(\tau)$ 为积分区间内 $\tau$ 时刻的纵向速度跟踪误差； $\alpha$ 为比例系数。

## 3

### 仿真试验与结果分析

本文开展了数值仿真试验以验证所提控制策略的有效性。选用KVLCC2作为试验模型，具体参数见表1；本文为了模拟实际航行，采用MMG动力学模型作为被控对象进行前向仿真。

表1 船模主要参数

Tab. 1 Main Parameters of Ship Models

主要参数	数值
船长 $L/m$	2.909
船宽 $B/m$	0.527
吃水 $d/m$	0.189

### 3.1 在线辨识网络可行性分析

为了验证基于 PINN 的在线辨识网络在动态工况下的有效性与鲁棒性，本文模拟了船舶的 Z 形操舵试验，Z 形试验具有丰富的频谱特征，能够为系统辨识提供充分的持续激励，有效检验船舶操纵性参数的辨识精度。

图 3 为旋回性指数  $K$  和追随性指数  $T$  随着训练轮次的收敛过程。从图 3 中可知，尽管  $T$  的初始猜测值与真值偏差较大，但在物理损失函数的约束下，经过约 1 500 个轮次的训练， $K$  值稳定在 0.12， $T$  值稳定在 2.23。参数曲线最终呈现出平滑且收敛的特性，未出现发散或剧烈振荡，证明了 PINN 算法在处理动态数据时具有极强的寻优能力和数值稳定性。




图 3  $K, T$  在线辨识收敛过程

Fig. 3  $K, T$  Identifies the Convergence Process Online

图 4 进一步展示了训练过程中损失函数的收敛特性。在训练初期（迭代次数 0 ~ 500），总损失值呈现快速的下降趋势，表明网络模型通过梯度下降算法，迅速从初始化的参数空间向全局最优解空间逼近。随着迭代轮次的推进，损失下降速率逐渐趋缓并进入精细调节阶段，最终稳定在 0.057 3，显示出算法良好的渐进收敛性。物理损失项的同步收敛证实了网络输出对 Nomoto 的 1 阶微分方程约束的有效性，最终收敛在 0.043 9。拟合优度为 0.976 1，证明拟合效果较好。




图 4 总损失与物理约束损失的收敛曲线

Fig. 4 Convergence Curves of Total Loss and Physical Constraint Loss

图 5 为航向角的验证结果显示，辨识模型积分得到的航向角与真实值在相位上高度吻合，两者的过零点几乎完全重合。这一现象证实了辨识出的时间常数  $T$  准确捕捉到了船舶对舵令响应的滞后特性及惯性特征。虽然模型降维导致预测峰值略低于真值，但线性模型依然精准复现了 KVLCC2 船型巨大的惯性特征，即在反向打舵后航向角仍继续偏转约  $5^\circ$  的超调现象。综上所述，基于 PINN 的在线辨识网络能够从复杂的非线性船舶运动数据中，快速、稳定地解算出具有明确物理意义的线性模型参数，验证了该方案作为自动靠泊控制系统中参数观测器的可行性。




图 5 辨识模型与 MMG 模型在 Z 形操舵下的航向角对比验证

Fig. 5 Comparison and Verification of Heading Angle Between the Identification Model and the MMG Model Under Z-Shaped Steering

### 3.2 自适应靠泊控制

为了进一步验证本文提出的基于 PINN 在线辨识参数的自适应控制策略在低速、强非线性工况下适用性,本节开展了 KVLCC2 船舶模型的自动靠泊仿真试验。该试验通过考察当船舶处于低速时,流体动力导数随航速剧烈变化且模型参数未知的复杂环境下,控制系统对规划路径的跟踪精度与动态稳定性。试验设定船舶初始位置为距离泊位纵向  $-500\text{ m}$ 、横向  $300\text{ m}$  处,初始航向角为  $0^\circ$ ,初始船速为  $0.8\text{ m/s}$ ,控制目标是操纵船舶平滑切入规划路径并最终停泊于原点,同时要求终端航向角偏差与纵向速度均收敛至安全阈值内。图 6 为船舶靠泊轨迹。

由图 6 结果可知,尽管初始时刻存在较大的航向偏差,但在该控制器作用下,船舶能够迅速调整姿态,实际航行轨迹与规划路径在靠泊中后段呈现出高度重合的特性。特别是在靠泊末端,控制器实现了对泊位的精准停靠,横向误差与终端航向角误差均收敛至极小范围,体现了算法在低速域优异的纠偏能力。从速度变化上看(图 7~图 9),船舶在自动靠泊过程中纵向速度  $u$  呈现平滑收敛特性,全程无振荡并最终稳定维持在极低靠泊速度。特别是在靠泊末段( $t > 800\text{ s}$ )低速舵效显著衰减的工况下,得益于 PINN 对模型参数的实时辨识与反馈增益的自适应调整,回转角速度  $r$  仍能输出足够的舵向控制力矩,有效抑制了航向偏差。与此同时,横向速度  $v$  始终被抑制在零值附近,未出现明显横向漂移。试验结果表明本文设计的控制系统能够有效地完成船舶的自主靠泊,即便在未预先离线标定参数的情况下,也能实现高精度的自动靠泊,验证了该方法的有效性与鲁棒性。




图 6 船舶靠泊轨迹

Fig. 6 Ship Berthing Trajectory




图 7 纵向速度  $u$  变化曲线

Fig. 7 Longitudinal Velocity  $u$  Change Curve




图 8 横向速度  $v$  变化曲线

Fig. 8 Lateral Velocity  $v$  Change Curve




图 9 回转角速度  $r$  变化曲线

Fig. 9 Rotational Angular Velocity  $r$  Change Curve

## 4 结论

船舶自动靠泊控制需应对低速浅水效应带来的剧烈流体动力干扰,且许多船舶参数未知,现有基于经验公式的传统模型难以实时反映当前复杂的操纵状态。本文建立了基于物理信息神经网络的船舶自动靠泊自适应控制方法,利用 PINN 网络对船舶操纵运动参数进行在线辨识,并以此为基础设计自适应控制器,实现了对时变参数的动态补偿。通过仿真试验验证可得到如下结论:

1) PINN 网络有效克服了纯数据驱动模型缺乏可解释性的缺陷,能够在有限的滑动窗口数据下,快速、稳定地解算出具有明确物理意义的旋

回性指数  $K$  和追随性指数  $T$ , 准确捕捉船舶的操纵特性。

2) 提出的自适应控制方法能够根据在线辨识结果实时调整反馈增益,有效维持了艏向控制力矩,在无需先验精确标定的情况下,实现了轨迹的高精度跟踪与平滑的停靠。

本文主要研究了参数未知以及低速工况下的自动靠泊控制问题。在未来的工作中,可拓展考虑风、流等环境干扰因素,并开展实船试验验证,进一步提高自动靠泊系统的工程适用性。

### 参考文献:

- [1] MIZUNO N, UCHIDA Y, OKAZAKI T. Quasi Real-Time Optimal Control Scheme for Automatic Berthing[J]. IFAC-PapersOnLine, 2015, 48(16): 305-312.
- [2] MAKI A, SAKAMOTO N, AKIMOTO Y, et al. Application of Optimal Control Theory Based on the Evolution Strategy (CMA-ES) to Automatic Berthing[J]. Journal of Marine Science and Technology, 2020, 25(1): 221-233.
- [3] LI S, LIU J, NEGENBORN R R, et al. Automatic Docking for Underactuated Ships Based on Multi-Objective Nonlinear Model Predictive Control[J]. IEEE Access, 2020, 8: 70044-70057.
- [4] MARTINSEN A B, BITAR G, LEKKAS A M, et al. Optimization-Based Automatic Docking and Berthing of ASVs Using Exteroceptive Sensors: Theory and Experiments[J]. IEEE Access, 2020, 8: 204974-204986.
- [5] WANG S, SUN Z, YUAN Q, et al. Autonomous Piloting And Berthing Based on Long Short Time Memory Neural Networks and Nonlinear Model Predictive Control Algorithm[J]. Ocean Engineering, 2022, 264: 112269.
- [6] ZHANG M, YU S R, CHUNG K S, et al. Time-Optimal Path Planning and Tracking Based on Nonlinear Model Predictive Control and its Application on Automatic Berthing[J]. Ocean Engineering, 2023, 286: 115228.
- [7] ZHU M, WEN Y, SUN W, et al. A Novel Adaptive Weighted Least Square Support Vector Regression Algorithm-Based Identification of the Ship Dynamic Model[J]. IEEE Access, 2019, 7: 128910-128924.
- [8] ZHENG J, YAN D, YAN M, et al. An Unscented Kalman Filter Online Identification Approach for a Nonlinear Ship Motion Model Using a Self-Navigation Test[J]. Machines, 2022, 10(5): 312.
- [9] MILLER A. Ship Model Identification with Genetic Algorithm Tuning[J]. Applied Sciences, 2021, 11(12): 5504.
- [10] LUO W, MOREIRA L, GUEDES S C. Manoeuvring Simulation of Catamaran by Using Implicit Models Based on Support Vector Machines[J]. Ocean Engineering, 2014, 82: 150-159.
- [11] XU H, SOARES C G. Hydrodynamic Coefficient Estimation for Ship Manoeuvring in Shallow Water Using an Optimal Truncated LS-SVM[J]. Ocean Engineering, 2019, 191: 106488.
- [12] 赵永生, 吴韬, 白一鸣. 未知时变扰动及模型参数动态不确定下船舶自动靠泊控制 [J]. 上海海事大学学报, 2022, 43(1): 8-13.
- [13] ZHAO Y S, WU T, BAI Y M. Automatic Ship Berthing Control Under Unknown Time-Varying Disturbances and Dynamic Uncertainty of Model Parameters [J]. Journal of Shanghai Maritime University, 2022, 43(1): 8-13.
- [13] ZHAO Y, ZHAO J X, WANG Z Z, et al. A Comprehensive Comparison Study Between Deep Operator Networks Neural

- Network and Long Short-Term Memory for Very Short-Term Prediction of Ship Motion[J]. *Journal of Hydrodynamics*, 2024, 36(6): 1167-1180.
- [14] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-Informed Neural Networks: a Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations[J]. *Journal of Computational Physics*, 2019, 378: 686-707.
- [15] 夏召丹, 马翔, 刘义, 等. 基于虚实结合的波浪环境下船舶操纵运动机器学习建模研究 [J]. *水动力学研究与进展 A 辑*, 2022, 37(6): 763-768.  
XIA Z D, MA X, LIU Y, et al. Research on Machine Learning Modeling of Ship Maneuvering Motion in Wave Environment Based on Virtual-Real Combination [J]. *Chinese Journal of Hydrodynamics*, 2022, 37(6): 763-768.
- [16] 赵东岳, 邹璐, 刘小健, 等. 基于物理信息神经网络的船舶约束模水动力预报 [J]. *水动力学研究与进展 A 辑*, 2025, 40(4): 523-531.  
ZHAO D Y, ZOU L, LIU X J, et al. Hydrodynamic Prediction of Ship Captive Model Based on Physics-Informed Neural Networks [J]. *Chinese Journal of Hydrodynamics*, 2025, 40(4): 523-531.
- [17] ZHOU X, ZOU L, ZOU Z J. A Unified Physics-Data-Driven Modeling Method for Predicting Time-Series Ship Maneuvering Motions in Regular Waves[J]. *Ocean Engineering*, 2025, 341: 122747.

