

# 基于深度卷积神经网络 AUV 六自由度运动 辨识建模

李辰宇<sup>1</sup>, 梅斌<sup>1</sup>, 白响恩<sup>2</sup>, 张杰<sup>1</sup>, 王恒<sup>1</sup>

(1. 大连海事大学 航海学院, 辽宁 大连 116026;

2. 上海海事大学 商船学院, 上海 201306)

**摘要:**针对自主水下航行器(AUV)的动力学建模问题,考虑 AUV 六自由度运动的非线性,提出一种基于深度卷积神经网络的非线性系统黑箱辨识建模方法。提取舵信号最大幅值对应频率,作为变分模态分解(VMD)降噪方法的设置阈值,降低 AUV 模型试验数据噪声,解决了 VMD 分层参数难以调谐的问题;利用双向长短期记忆(BiLSTM)和注意力机制,建立非线性系统黑箱模型,利用 Adam 优化方法求解 AUV 六自由度运动黑箱模型;采用 AUV 船模试验数据开展模型训练和预测验证,并与 CNN-LSTM、CNN-BiLSTM 和 CNN-LSTM-Attention 建模方法作比较,求解并分析 AUV 运动的速度项、姿态角和运动轨迹。试验结果表明:深度卷积神经网络的均方根误差(RMSE)、决定系数( $R^2$ )和平均绝对百分比误差(SMAPE)比 CNN-LSTM 模型分别改善了 79.29%、3.84% 和 74.41%,验证运动建模方法的可行性和有效性。该方法能为水下航行器的精确避碰和自主导航提供一种有效的动力学建模策略。

**关键词:**自适应变分模态分解;双向长短期记忆;注意力机制;水下航行器船模试验

**中图分类号:**U661.33 **文献标志码:**A **DOI:**10.3969/j.issn.1000-4653.2025.04.005

## Identification modeling based on deep convolutional neural network for AUV 6-DOF motion

LI Chenyu<sup>1</sup>, MEI Bin<sup>1</sup>, BAI Xiang'en<sup>2</sup>, ZHANG Jie<sup>1</sup>, WANG Heng<sup>1</sup>

(1. Navigation College, Dalian Maritime University, Dalian 116026, China;

2. Merchant Marine College, Shanghai Maritime University, Shanghai 201306, China)

**Abstract:** To address the challenges in dynamic modeling of Autonomous Underwater Vehicle (AUV), this paper proposes a black-box identification method for nonlinear systems based on deep convolutional neural networks, taking into account the nonlinear characteristics of the AUV's six-degree-of-freedom (6-DOF) motion. First, the frequency corresponding to the maximum amplitude of the rudder signal is extracted and used as a threshold for Variational Mode Decomposition (VMD) denoising. This reduces noise in the experimental data of the AUV model and resolves the issue of difficult parameter tuning in VMD decomposition. Then, a black-box model for the nonlinear system is constructed using Bidirectional Long Short-Term Memory (BiLSTM) and Attention mechanisms, with the Adam optimization algorithm employed to solve the AUV 6-DOF motion model. Finally, the AUV model data are used for model training and predictive validation, and the results are compared with modeling methods such as CNN-LSTM, CNN-BiLSTM, and CNN-LSTM-Attention to analyze the velocity, Euler angles, and trajectory of AUV motion. Experimental results show that, compared to the CNN-LSTM model, the proposed method improves the Root Mean Square Error (RMSE), the coefficient of determination ( $R^2$ ), and the Symmetric Mean Absolute Percentage Error (SMAPE) by 79.29%, 3.84%, and 74.41%,

收稿日期:2024-10-01

基金项目:辽宁省教育厅 2022 年度基本科研项目(LJKMZ20220373);中央高校基本科研业务费专项(3132024135)资助

第一作者:李辰宇(1999—),男,硕士生,研究方向为船舶运动建模。E-mail:lichenyu251@mails.ucas.ac.cn

通信作者:梅斌(1991—),男,博士,研究方向为船舶运动建模。E-mail:meibindmu@163.com

引用格式:李辰宇,梅斌,白响恩,等.基于深度卷积神经网络 AUV 六自由度运动辨识建模[J].中国航海,2025,48(4):36-46.

LI C Y, MEI B, BAI X E, et al. Identification modeling based on deep convolutional neural network for AUV 6-DOF motion[J]. Navigation of China, 2025, 48(4): 36-46. (in Chinese)

respectively, validating the feasibility and effectiveness of the proposed dynamic modeling approach. This method provides an alternative strategy for precise obstacle avoidance and autonomous navigation of underwater vehicles.

**Key words:** Adaptive VMD; BiLSTM; Attention mechanism; AUV Model experiments

水下航行器的智能化发展是当前的热门方向,随着自主技术的不断进步,水下航行器研究取得显著进展,特别是在海洋学、海洋搜救和近海矿物勘探等水下作业方面<sup>[1]</sup>。水下航行器主要包括遥控水下航行器、载人潜水和自主水下航行器(Autonomous Underwater Vehicle, AUV)等3种类型。在深海环境中搜救巡航时,人员难以抵达特殊的地理位置,如海底、海峡等复杂海域。AUV 凭借自主性、灵活性和适应性,可有效地替代人工执行搜救任务,从而降低人员巡航风险,提高勘查效率。运动模型是 AUV 自主避碰与导航的理论基础,对 AUV 运动建模的研究显得尤为重要。

AUV 辨识建模是建立动力学模型的关键。随着 AUV 技术的广泛应用,无论是操纵运动研究还是控制系统的设定,均与动力学建模相关。而辨识建模是解决上述问题的方法之一。常见的辨识建模类型有黑箱模型、白箱模型和灰箱模型<sup>[2]</sup>。人工智能技术的发展使神经网络、决策树、随机森林和支持向量机(Support Vector Machine, SVM)逐渐应用到船舶运动辨识建模领域,有学者提出 GRBF-FNN<sup>[3]</sup>、PSO + LS-SVM<sup>[4]</sup> 和 CV +  $\nu$ -SVM<sup>[5]</sup> 等混合算法。XUE 等<sup>[6]</sup> 提出一种基于贝叶斯非线性船舶操纵辨识方法,通过 Z 形试验和旋回试验验证该方法具有良好的抗噪声性能。WANG 等<sup>[7]</sup> 提出一种  $\nu$ -SVR 的非参数识别方法用于船舶操纵运动建模,试验结果表明  $\nu$ -SVR 方法能自动调整支持向量的数量,实现高效率计算。SHEN 等<sup>[8]</sup> 提出一种非参数和鲁棒性相结合的(S-LS-SVM)的模型,提高模型的辨识精度。JIANG 等<sup>[9]</sup> 提出一种长短期记忆(Long Short Term Memory, LSTM)神经网络的方法构建的水面船舶运动模型,比传统的神经网络更容易训练。

辨识算法是水下航行器运动辨识建模的主要研究内容之一。杨柯<sup>[10]</sup> 为获得精确的动力学模型,采取 Kane 方法进行动力学建模,通过仿真验证该方法的有效性。周怡等<sup>[11]</sup> 提出基于最小二乘准则和自适应粒子群优化算法的 AUV 水动力参数辨识方法,并利用仿真检验方法的可行性。蒋志龙<sup>[12]</sup> 针对 AUV 建模过程中存在的水动力参数辨识问题,通过计算流体力学进行仿真获取水动力参数辨识,并验证模型参数的有效性。聂为彪等<sup>[13]</sup> 在水平方向建立航行器动力学模型,研究水下航行器的水平面操

纵性,且对试验进行仿真模拟。边靖伟等<sup>[14]</sup> 应用粒子群参数寻优建立水下航行器黑箱模型,以新型四旋翼水下航行器的2种空间运动进行试验验证。目前,利用卷积神经网络进行 AUV 运动辨识建模的方法较少,因而提出的建模方法缺乏一定的参考性。

AUV 运动数据的降噪是参数辨识前的重要环节。在水下航行器运动模型的数据采集与处理研究中,试验数据存在不确定性和随机性,对水下航行器的运动模型建模产生影响。常见的数值降噪处理方法包括小波去噪、傅里叶变换、奇异值分解和经验模态分解(Empirical Mode Decomposition, EMD)等。ZHANG 等<sup>[15]</sup> 基于小波基函数和小波分解层数对仿真试验数据进行降噪,并指出不同小波基函数在相同降噪方法下存在最佳分解层数。HUANG 等<sup>[16]</sup> 提出 EMD,其是一种处理非平稳非线性信号的方法。在此基础上,WU 等<sup>[17]</sup> 提出一种新的集成经验模态分解 EEMD。DRAGOMIRETSKIY 等<sup>[18]</sup> 提出变分模态分解(Variational Mode Decomposition, VMD)。唐贵基等<sup>[19]</sup> 利用参数优化变分模态分解方法对仿真和实测信号进行分析。研究表明 VMD 方法在噪声分离方面具备显著的优越性和有效性<sup>[20]</sup>,但 VMD 方法分解信号的层数是研究关键。受到上述启发,本文提出自适应 VMD 方法处理 AUV 数据中的噪声。

为解决船模试验数据包含噪声的问题,本文提出一种自适应 VMD 的 AUV 运动数据降噪方法,该方法利用舵信号频率自主确定 AUV 船模数据分解层数。同时,AUV 具有非线性、强耦合且易受外界干扰等特点<sup>[21]</sup>,为解决 AUV 六自由度深度耦合问题而建立 AUV 六自由度运动模型,确保建模的精度,设计一种深度卷积神经网络的非线性 AUV 黑箱运动模型。

## 1 船模试验数据降噪

使用 AUV 船模数据开展辨识建模,数据的处理是必要的。数据的采集是最初始的过程,包括纵摇速度  $u$ 、横摇速度  $v$ 、艏摇角速度  $r$ 、横摇角  $\phi$ 、纵倾角  $\theta$ 、转艏角  $\Psi$  和控制变量  $\delta$ 。由于数据较多且存在噪声干扰,需对采集到的运动状态数据进行滤波以提高模型辨识精度。本文采用自适应 VMD 方法进行处理,数据降噪流程示意图 1。

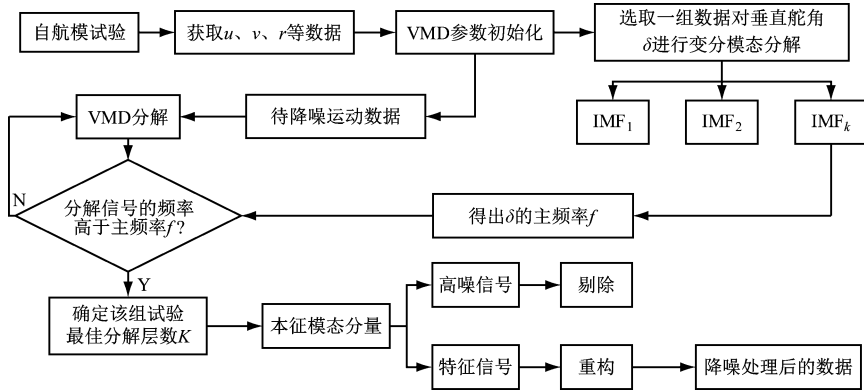


图1 自适应VMD降噪流程示意

Fig. 1 The adaptive VMD noise reduction process

### 1.1 VMD原理


VMD是一种能将信号分解成各种固有模式函数的自适应分解方法。本文将 $u, v, r, p, q, w$ 等信号分解成各自固有的模态分量,利用希尔伯特变换计算频谱,将指数 $E^{-j\omega t}$ 融合到每个对应的模式中,通过使用高斯平滑度来得到每个带宽的估计值。然后求解约束变分问题,使本征模态分量(Intrinsic Modal Fraction, IMF)所估计的带宽之和最小化。利用约束目标函数将信号分解为 $k$ 个有限带宽的分量IMF,所有IMF的总和为原始信号 $f$ ,即:

$$\left\{ \begin{array}{l} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] E^{-j\omega_k t} \right\|_2^2 \right\} \\ \sum_{k=1}^K u_k = f \end{array} \right. \quad (1)$$


式(1)中: $u_k$ 为分解获得的第 $k$ 个IMF分量; $\omega_k$ 为第 $k$ 个IMF中心频率; $\delta$ 为狄拉克分布; $*$ 为卷积符号; $\partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right]$ 为希尔伯特变换; $j = -1$ ;  $\|\cdot\|_2$ 为 $L2$ 范数; $\partial_t$ 为 $t$ 时刻的偏导; $f$ 为原数据序列。

引入二次惩罚项 $\alpha$ 和拉格朗日乘法算子 $\lambda$ ,将有约束问题变为无约束问题,然后采用交替方向乘子算法迭代更新IMF中心频率和带宽,更新拉格朗日乘法算子 $\lambda$ 为


$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left[ \hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega) \right] \quad (2)$$




(a) 舵角原始数据



(b) 舵角频谱



(c) 横向速度原始数据



(d) 模向速度频谱

$$\frac{\sum_{k=1}^K \|\hat{u}_k^{n+1}(\omega) - \hat{u}_k^n(\omega)\|_2^2}{\|\hat{u}_k^n(\omega)\|_2^2} < \varepsilon \quad (3)$$

式(2)和(3)中: $\tau$ 为更新参数; $\varepsilon$ 对分解结果影响很小,一般取 $1 \times 10^{-6} \sim 1 \times 10^{-5}$ 。

当满足式(3)条件时,迭代停止,保证收敛。

### 1.2 VMD分解层数确定方法

确立 $K$ 值是VMD算法的关键。若 $K$ 值过大则导致VMD过度分解,产生虚假信息。若 $K$ 值过小,则造成分解层数不够,噪声分离效果不明显。为避免该问题,以垂直舵角 $\delta$ 信号主频率为自适应VMD算法的阈值。 $\delta$ 为所有数据来源的控制变量,通过利用VMD方法对 $\delta$ 进行层数分解,来获取AUV运动状态信号的主成分频率。

垂直舵角和横向速度噪声信号VMD分解图和频谱图见图2。以 $20^\circ/20^\circ Z$ 形试验为例,通过对垂直舵信号 $\delta$ 进行VMD分解,从图2频谱得出该组试验 $\delta$ 的主成分所在层,对应频率 $f$ 为 $3.29 \times 10^{-4}$ 。当运动状态信号的IMF频率高于此频率,则被认定为干扰信号,应当剔除。图2中:以横向速度为例,对该信号进行VMD分解,分解为5层信号时,横向速度IMF信号低于 $\delta$ 的主频率 $f$ 的只有一层,表明该信号的最佳分解层数 $K$ 应为2。

### 1.3 降噪试验

在应用自适应VMD方法后,对含噪声的信号进行重构,实现信号的降噪。以2个Z形试验和4个旋回试验的横向速度为例,各个试验的自适应

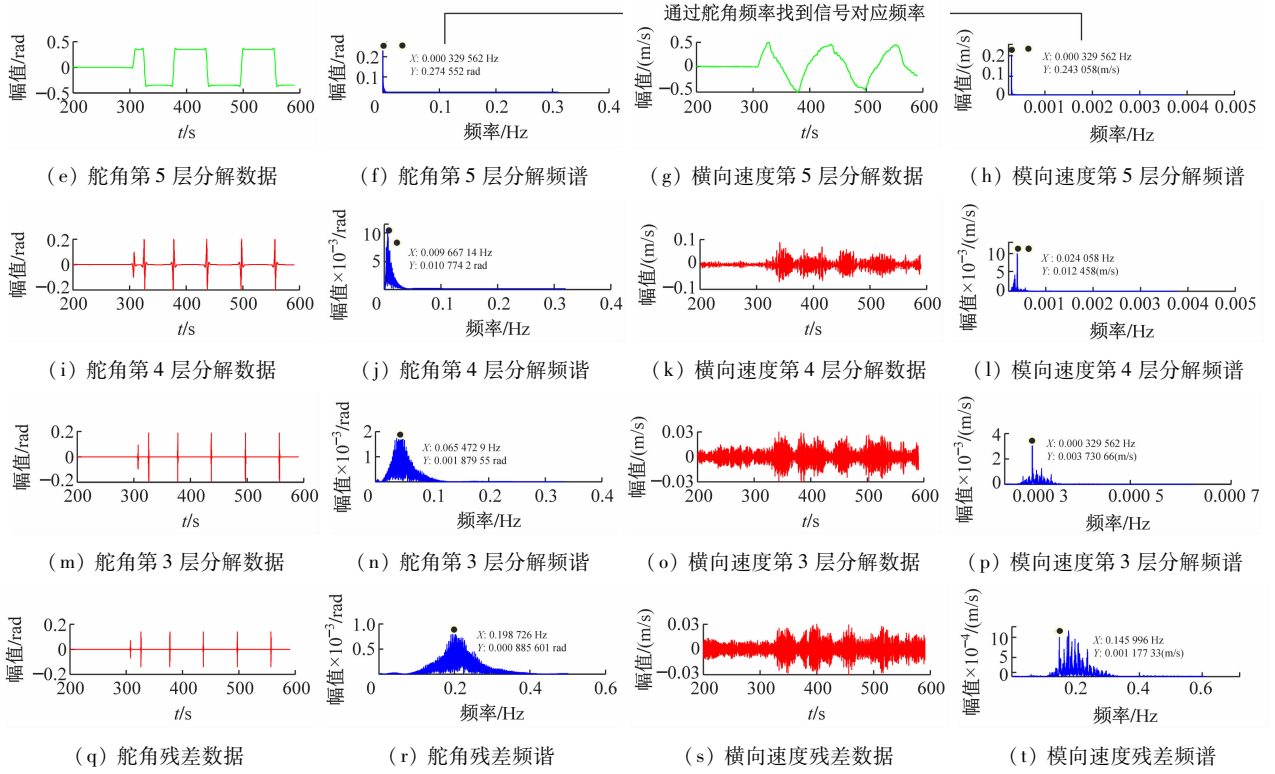


图2 垂直舵角和横向速度噪声信号VMD分解图和频谱图

Fig. 2 VMD decomposition and spectrum of vertical rudder angle and sway velocity noise signal

VMD分解参数见表1。经横向速度VMD重构后,部分横移速度的降噪对比示意图3。为降噪对比

经过对比后,发现降噪效果明显。随着试验类型的不同,当 $\delta$ 逐渐增大时,所需的 $f$ 逐渐降低。

表1 AUV 横向速度的自适应VMD分解参数

Tab.1 Adaptive VMD parameters of AUV sway velocities

试验类型	10°/10°	-20°/-20°	10°	-15°	20°	-30°	
	Z形试验	Z形试验	旋回试验	旋回试验	旋回试验	旋回试验	
分解频率	$f \times 10^{-4}/\text{Hz}$	5.03	4.17	3.73	1.82	1.08	9.41
分解层数	K/层数	2	2	2	2	2	3

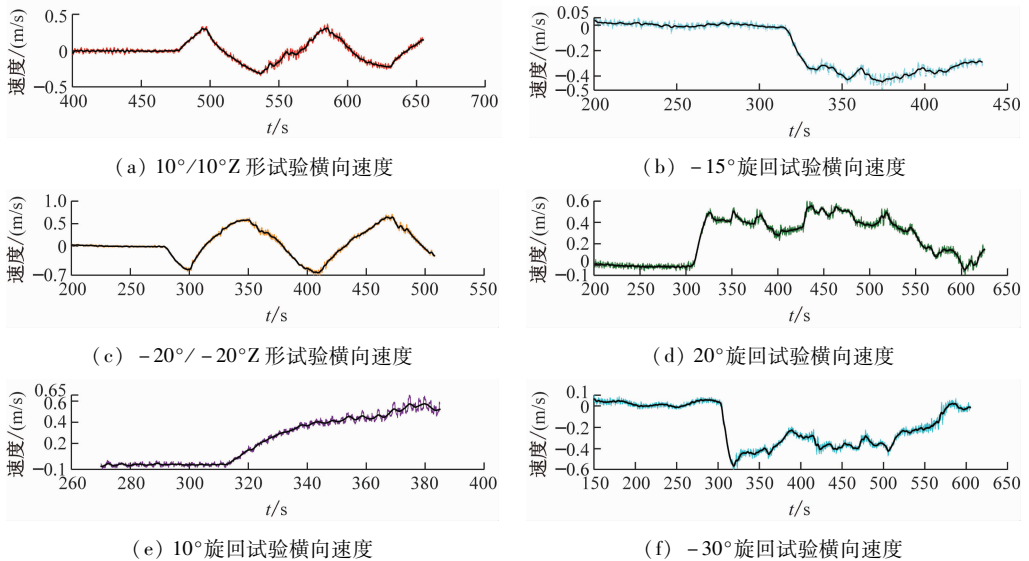


图3 部分横移速度的降噪对比示意

Fig. 3 Comparison of noise reduction for sway velocity

## 2 AUV 辨识模型的构建

本节通过 AUV 运动方程构建非线性深度卷积

神经网络模型。网络模型结构示意图 4, 使用 AUV 模型获取试验数据; 采用自适应的 VMD 方法开展数据去噪, 用于模型训练。




图4 深度卷积神经网络模型结构示意图

Fig. 4 The structure of Deep-CNN model

### 2.1 AUV 运动模型

为描述 AUV 操纵运动, 采用 2 种右手坐标系见图 5。

1) 对于惯性坐标系  $o_0-X_0Y_0Z_0$  和  $o_0-X_0Y_0$  设为无扰动自由面;  $o_0X_0$  轴指向正北,  $o_0Y_0$  轴指向正东,  $o_0Z_0$  轴垂直向下。

2) 对于附体坐标系  $o-X_bY_bZ_b$ , 原点  $o$  位于艏部;  $oX_b$  轴指向船头,  $oY_b$  轴指向右舷,  $oZ_b$  轴指向下方。在附体坐标系下, AUV 的平移运动为前进、横移、垂向; 旋转运动有横倾、纵倾和回转。




图5 AUV 坐标系示意图

Fig. 5 AUV coordinate system

采用文献[22]提出的水下航行器 AUV 六自由度水动力模型为

$$\begin{cases} \dot{\boldsymbol{\eta}} = \mathbf{J}_k(\boldsymbol{\eta})\boldsymbol{v} \\ \mathbf{M}\dot{\boldsymbol{v}} = -\mathbf{C}(\boldsymbol{v})\boldsymbol{v} - \mathbf{D}(\boldsymbol{v})\boldsymbol{v} - \mathbf{g}(\boldsymbol{\eta}) + \boldsymbol{\tau} \end{cases} \quad (4)$$

$$\begin{cases} \boldsymbol{v} = [\boldsymbol{v}_1^T \ \boldsymbol{v}_2^T]^T; \boldsymbol{v}_1 = [u \ v \ w]^T; \boldsymbol{v}_2 = [p \ q \ r]^T \\ \boldsymbol{\eta} = [\boldsymbol{\eta}_1^T \ \boldsymbol{\eta}_2^T]^T; \boldsymbol{\eta}_1 = [x \ y \ z]^T; \boldsymbol{\eta}_2 = [\phi \ \theta \ \psi]^T \\ \boldsymbol{\tau} = [\boldsymbol{\tau}_1^T \ \boldsymbol{\tau}_2^T]^T; \boldsymbol{\tau}_1 = [X \ Y \ Z]^T; \boldsymbol{\tau}_2 = [K \ M \ N]^T \end{cases} \quad (5)$$

$$\begin{cases} \mathbf{M} = \mathbf{M}_{RB} + \mathbf{M}_A \\ \mathbf{C}(\boldsymbol{v}) = \mathbf{C}_{RB}(\boldsymbol{v}) + \mathbf{C}_A(\boldsymbol{v}) \\ \mathbf{D}(\boldsymbol{v}) = \mathbf{D} + \mathbf{D}_n(\boldsymbol{v}) \end{cases} \quad (6)$$

根据式(4)可得出

$$\boldsymbol{\eta}_{k+1} = h(\mathbf{J}_k(\boldsymbol{\eta}_k)\boldsymbol{v}_k) + \boldsymbol{\eta}_k \quad (7)$$

$$\boldsymbol{v}_{k+1} = \boldsymbol{v}_k + \mathbf{M}^{-1}h(-\mathbf{C}(\boldsymbol{v}_k)\boldsymbol{v}_k - \mathbf{D}(\boldsymbol{v}_k)\boldsymbol{v}_k - \mathbf{g}(\boldsymbol{\eta}_k) + \boldsymbol{\tau}_k) \quad (8)$$

式(4)~式(8)中:  $m$  为 AUV 的质量;  $u$ 、 $v$  和  $w$  分别为 AUV 在  $x$ 、 $y$  和  $z$  方向的速度分量;  $\phi$ 、 $\theta$  和  $\psi$  为横摇角、纵摇角和转艏角;  $p$ 、 $q$ 、 $r$  为横摇角速度、纵摇角速度、转艏角速度;  $\mathbf{M}$  为  $6 \times 6$  惯性矩阵;  $\mathbf{J}_k(\boldsymbol{\eta})$  为固定坐标系到运动坐标系的速度转换矩阵;  $\mathbf{M}_{RB}$  为刚体惯性矩阵;  $\mathbf{M}_A$  为附加质量矩阵;  $\mathbf{C}(\boldsymbol{v})$  为科氏和离心矩阵;  $\mathbf{C}_{RB}(\boldsymbol{v})$  为 AUV 船体质量的科氏和离心矩阵;  $\mathbf{C}_A(\boldsymbol{v})$  为 AUV 周围水体的科氏和离心矩阵;  $\mathbf{D}(\boldsymbol{v})$  为阻尼矩阵;  $\mathbf{g}(\boldsymbol{\eta})$  为重力和浮力矩阵;  $h$  为时间步长。

### 2.2 深度卷积神经网络模型的构建

AUV 运动数据是多维时间序列, 某一时刻的运动状态是一维向量, 该向量作为卷积神经网络的输入。因此, 卷积核高度设置为  $k$  ( $k \leq$  输入最大特征向量数)、宽度为 1。文中卷积核设置为  $1 \times 1$ , 该卷积核为一维卷积, 也可视为宽度为 1 的特殊的二维卷积。

本文选取压缩和激励网络 (Squeeze and Excitation Networks, SENet) 注意力机制模型。SENet 模型示意图 6, SENet 注意力机制能将卷积层捕获的 AUV 运动的特征向量施加不同通道的权重, 有效拟合关键的特征向量并减少 AUV 模型预报的时间。双向长短期记忆 (Bidirectional long-and short-term memory, BiLSTM) 是一种以 LSTM 为基础的双向 LSTM 神经网络, 一个是前向 LSTM 层, 另一个是反向 LSTM 层, 分别按照时间正向顺序和反向顺序排列。




图6 SENet 模型示意

Fig. 6 SENet model

深度神经网络结构参数见表 2。模型中采用 mini-batch 训练技术将整组训练样本分成小子集,每个小子集包含 128 个训练样本。深度神经模型参数影响模型的训练时长和预报性能。学习率反映出对 AUV 时序空间特征的捕获能力,数值过大会导致预测结果不准确,数值过小会导致训练时间过长,并且容易陷入局部最优,出现过学习现象<sup>[23]</sup>。神经元个数能防止神经网络模型过拟合,使 AUV 预测结果更平滑,数值过小效果不明显,数值过大会导致欠拟合<sup>[24]</sup>。训练轮数能对 AUV 时间序列的建模能力产生影响,轮数过低,会造成模型训练不佳,轮数过高,模型的泛化能力不强。本文构建深度神经网络模型结构参考部分学者的研究,epoch 数设置为 500,学习率为 0.001 0,300 轮后学习率变为 0.000 1。

为应对目标函数中梯度的不同大小和方向,跳出局部最优解,本文采用 Adam 优化方法训练深度卷积神经网络模型<sup>[25]</sup>,避免在不平衡训练数据集导致的目标函数难以收敛。深度卷积神经网络模型示意图 7,仅描述一层卷积层示意。由于 AUV 运动不同于传统水面船舶。AUV 流体动力是非线性的,特别是在高速或变速运动下,升力、阻力和控制力是 AUV 速度和角速度的非线性函数<sup>[26]</sup>。由于各自由度运动之间存在耦合关系,某个方向的运动预报误差会加剧其他方向的误差,增加建模的难度和不确定性<sup>[27]</sup>。本文在模型构建的部分结构参数上不同于文献[25]和文献[28]中的方法,采用多输入单输




图 7 深度卷积神经网络模型示意

Fig. 7 Deep-CNN model

### 3 AUV 模型辨识试验过程

#### 3.1 AUV 模型训练设置

对于船模数据,采用荷兰海事研究所进行的自航试验,该试验使用 AUV 在静水域进行旋回试验和 Z 形试验,速度控制在约 10 kn。AUV 船型参数见表 3。

根据 AUV 的船模试验,得到旋回试验和 Z 形试验数据,利用自适应的 VMD 进行降噪处理后,对船模数据进行训练,训练集参数见表 4。

表 2 深度神经网络结构参数

Tab. 2 Specific parameters of Deep-CNN

深度卷积神经网络	设置	输出大小
输入层	-	$7 \times 1$
卷积层 1	一维卷积核数量 = 32	$7 \times 32 \times 1$
Relu1	-	$7 \times 32 \times 1$
卷积层 2	一维卷积核数量 = 64	$7 \times 64 \times 1$
Relu2	-	$7 \times 64 \times 1$
池化注意力层	一维全局池化	$1 \times 32 \times 1$
	第一次全连接层	$1 \times 16 \times 1$
	Relu3	$1 \times 16 \times 1$
池化注意力层	第二次全连接层	$1 \times 64 \times 1$
	Sigmoid	$1 \times 64 \times 1$
Multiplication	-	$7 \times 64 \times 1$
Flatten	-	$448 \times 1 \times 1$
BiLSTM 层	隐藏元个数 = 50	$50 \times 1$
Dropout	0.3	$50 \times 1$
Fullconnect	-	$1 \times 1$
回归输出层	-	$1 \times 1$

出的这种构建方法用于捕捉 AUV 特性,与 AUV 非线性特性和强耦合自由度<sup>[21]</sup>相符合。每次深度卷积神经网络输出 1 个参数,针对本文辨识的参数一共需使用 6 次深度卷积神经网络。

表 3 AUV 船型参数

Tab. 3 Specific parameters of AUV

AUV 尺度	符号	全尺度	缩比模型
长度/m	$L_{oa}$	70.2	3.826 00
宽度/m	B	9.6	0.523 20
螺旋桨直径/m	$D_p$	5	0.273 00
排水量/ $m^3$	$\nabla$	4 440	0.701 20
重心距离艏部位置/m	$x_{CG}$	32.31	1.761 00
重心距离艉轴高度/m	$x_{CG}$	0.043 3	0.002 40
浮心高度/m	$z_{CB}$	0.444 3	0.024 21

表4 训练集参数

Tab.4 Specific parameters of the train test

序号	试验类型	舵角/°	船向/°	采样时长/s	采样频率/Hz
1	Z形试验	10	10	178.3	25
2	Z形试验	-20	-20	229.5	25
3	旋回试验	5	-	104.1	25
4	旋回试验	-5	-	68.6	25
5	旋回试验	10	-	72.7	25
6	旋回试验	-10	-	62.2	25
7	旋回试验	-15	-	120.2	25
8	旋回试验	20	-	209.6	25
9	旋回试验	30	-	62.8	25
10	旋回试验	-30	-	152.9	25

将20°/20°Z形试验、15°旋回试验作为模型的验证集,检验模型的泛化能力。最后分别和 CNN-LSTM<sup>[9]</sup>、CNN-BiLSTM<sup>[29]</sup>和 CNN-LSTM-Attention<sup>[30]</sup>作比较,验证所提出模型的效果。

对水下航行器操纵运动建模时,需使用所构造的训练样本集对构建的模型进行训练,得到非线性模型,并通过损失函数对训练结果进行验证。只用某一时刻的实际运动数据来预测 AUV 的运动。根据式(4)将运动变量定义为状态向量  $\mathbf{x}_k = [u_k \ v_k \ r_k \ p_k \ q_k \ w_k]$ ,指令垂直舵角  $\delta$  为外部输入,水动力和力矩为状态向量与外部输入的非线性函数。则运动方程可改写为非线性函数  $F$ ,即对式(7)的映射。

$$\begin{cases} \mathbf{x}_k = [u_k \ v_k \ r_k \ p_k \ q_k \ w_k] \\ \mathbf{x}_{k+1} = F(\mathbf{x}_k, \delta_k) = h(\mathbf{J}_k(\boldsymbol{\eta}_k) \mathbf{v}_k) + \boldsymbol{\eta}_k \end{cases} \quad (9)$$

通过拟合非线性系统的输入输出数据,建立非线性模型的非参数辨识方法是当前黑箱辨识的主要形式。一旦得到非线性函数  $F$  的深度卷积神经网络模型,就可根据输入特征预测 AUV 的操纵运动。先要确定训练样本的数据集,包括输入和输出数据。根据式(9)输入数据包含状态向量  $\mathbf{x}$  和垂直舵角  $\delta$ ,输出数据是前进、横移、转舵角速度、横摇角速度、纵摇角速度和垂向速度运动状态变量下一时刻的数值。

### 3.2 AUV 验证试验结果及分析

1) 20°/20°水平Z形试验的6自由度运动状态预报结果见图8。图8为线速度、角速度和姿态角的预报结果。

① 在278s的试验周期内,垂直舵出现5次反压舵角,转舵角速度、横向速度和横摇角速度在舵角响应时间点出现5个极值,表明转舵角速度、横向速度与横摇角速度耦合性较强,都随着垂直舵出现Z形变化。

② 水平Z形试验的超越角随着时间的变化,误差逐渐增大。

③ 由于水平Z形试验对垂向速度影响较小,导致垂向速度变化范围较小。0~110s内,纵向速度从5.05m/s逐渐减少1.38m/s,纵向速度的降低幅度小于后续的水平旋回试验。Z形试验的线速度和角速度在反压舵角时会出现急剧变化,模型误差在此时会增大的现象,表明运动状态急剧变化会增加建模难度,影响预报精度。

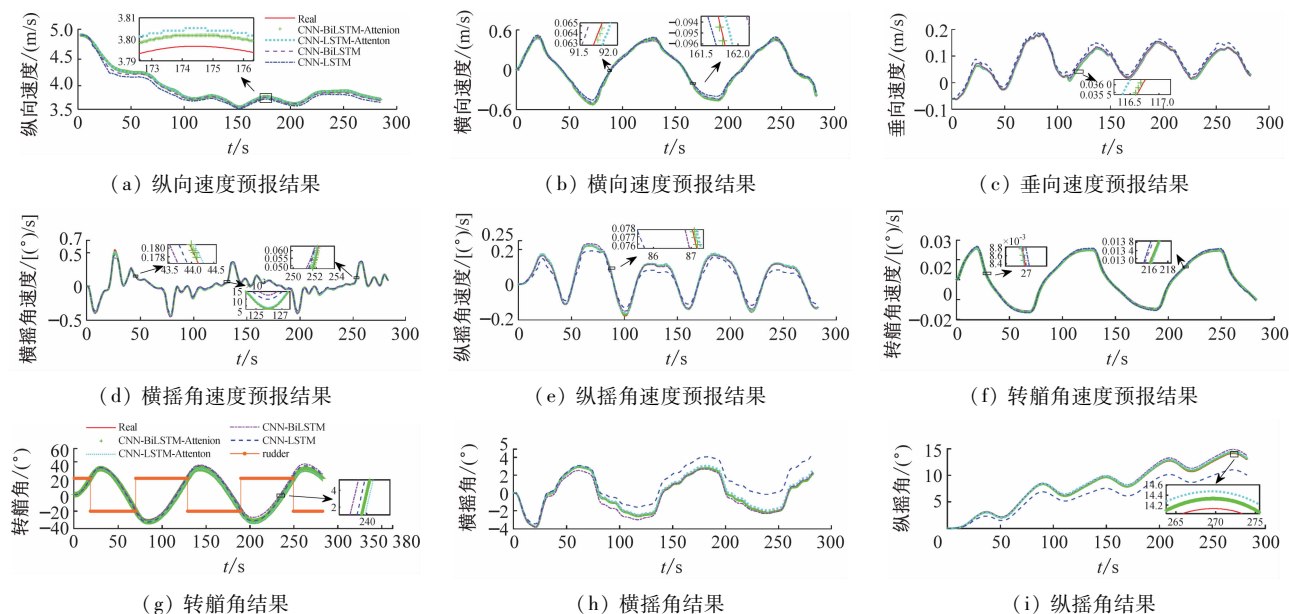


图8 20°/20°水平Z形试验预报结果

Fig.8 The validation of 20°/20° zigzag test


2) 15°旋回试验的6自由度运动状态预报结果见图9。图9为线速度、角速度和姿态角的预报结果。

① 旋回试验表明纵向速度在70 s内降低了1.8 m/s, 偏离初始速度达30.7%, 因此, 旋回试验因15°舵角而呈现显著的非线性特征。


② 水动力 $\tau$ 本身是非线性的, $\tau$ 并不是AUV运动状态向量 $\mathbf{x}_k$ 的精确线性函数。

20°/20°水平Z形试验、15°水平旋回试验的轨


迹图见图10~图11。本文构建的深度卷积神经网络所预测的轨迹与原始轨迹最贴合。相比于其他模型所训练的结果, 泛化性更强。因此, 深度神经网络建立的非线性AUV运动模型具有一定的可行性。与Z形试验相比, 旋回试验具有较强的非线性特征, 导致AUV近似定常旋回阶段速度和角速度的预报精度低于初始阶段。在此基础上, 姿态角的累计误差在近似定常旋回阶段迅速增大, 轨迹误差也具有相同的现象。




(a) 纵向速度预报结果




(b) 横向速度预报结果




(c) 垂向速度预报结果




(d) 横摇角速度预报结果




(e) 纵摇角速度预报结果




(f) 转艏角速度预报结果



(g) 转艏角结果



(h) 横摇角结果



(i) 纵摇角结果

图9 15°旋回试验预报结果

Fig. 9 The validation of a 15° turning test

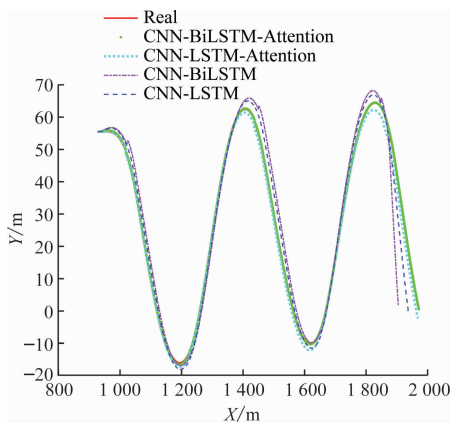


图10 20°/20°Z形试验轨迹

Fig. 10 The trajectories of 20°/20°ZigZag test

### 3.3 误差评判指数

将预报结果与船模数据进行对比, 验证所提出的模型精度。为能准确地评估模型的性能和精度, 使用均方根误差(Rat Mean Square Error, RMSE)、平均绝对百分比误差(Synthesis Mean Absolute Percentage Error, SMAPE)和 $R^2$ 来评判检验结果<sup>[31]</sup>。RMSE和SMAPE越低, 预测精度越高。 $R^2$ 的取值越高, 预测性能越好, 通常取值在0~1之间。




图11 15°旋回试验轨迹

Fig. 11 The trajectories of 15° turning test

### 3.4 AUV 验证试验分析

根据船模试验数据, 对20°/20°Z形试验和15°旋回试验的数据做进一步分析。通过分析试验数据的小提琴示意图12, 以试验中的纵向速度为例, 本文模型预报数据与原始数据的形状高度匹配, 误差中位数和平均数分别为 $3.7 \times 10^{-3}$ 和 $5.3 \times 10^{-3}$ , 接近原始数据。将横摇角速度的变化用山峰图绘制见图13, 所提出的模型预报误差均值为 $6.2 \times 10^{-4}$ , 其他方法分别为 $1.1 \times 10^{-3}$ 、 $5.2 \times 10^{-3}$ 、 $7.1 \times 10^{-3}$ 。在预测精度方面, 深度卷积神经网络模型优于CNN-

LSTM-Attention, 后者又优于 CNN-BiLSTM。RMSE、 $R^2$  和 SMAPE 误差评判指数见表 5。同时,对几种模型的旋回圈运动学参数见表 6,运动学参数表明本文方法精度最优。

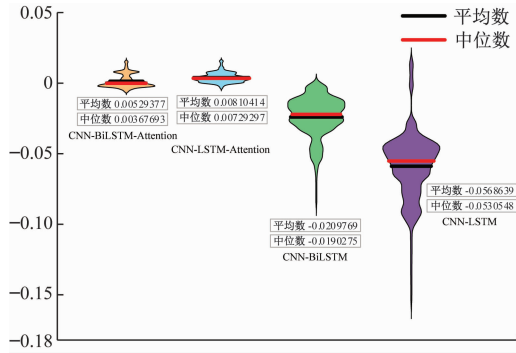


图 12 20°/20°Z 形试验小提琴示意

Fig. 12 Violin plot of 20°/20° ZigZag test

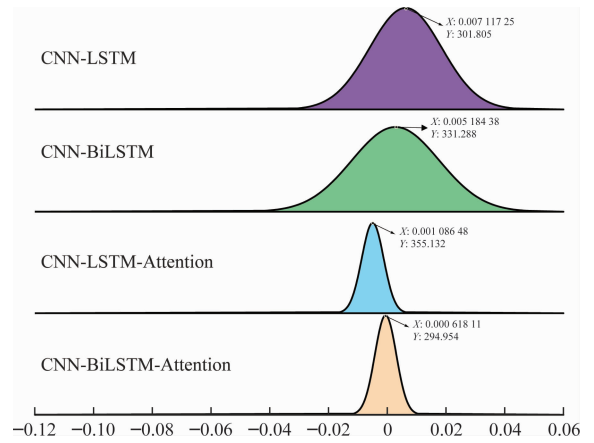


图 13 20°/20°Z 形试验山峰示意

Fig. 13 Ridgeline of 20°/20° ZigZag test

表 5 数据误差结果

Tab. 5 Data error results

不同模型指标对比	RMSE						$R^2$						SMAPE					
	u	v	r	p	q	w	u	v	r	p	q	w	u	v	r	p	q	w
1 CNN-LSTM	0.017	0.037	0.008	0.018	0.029	0.016	0.960	0.988	0.996	0.981	0.989	0.955	0.783	11.49	6.937	24.94	20.20	15.18
2 CNN-BiLSTM	0.014	0.023	0.007	0.017	0.015	0.008	0.984	0.996	0.997	0.984	0.971	0.990	1.089	8.856	5.582	17.75	15.11	11.26
3 CNN-LSTM-Attention	0.008	0.013	0.004	0.006	0.006	0.002	0.982	0.998	0.997	0.997	0.995	0.999	0.965	6.032	4.791	8.323	7.553	8.976
4 深度卷积神经网络	0.004	0.010	0.003	0.004	0.003	0.001	0.999	0.999	0.999	0.999	0.999	0.999	0.193	5.978	2.646	4.192	3.052	1.812
4 相比 1 提高率	79.29%						3.84%						74.41%					
4 相比 2 提高率	70.86%						1.24%						65.32%					
4 相比 3 提高率	33.08%						0.39%						39.96%					

表 6 验证试验旋回圈运动学参数误差分析

Tab. 6 The kinematic parameters of turning circle in validation data

15° 旋回	原始数据	CNN-LSTM	CNN-BiLSTM	CNN-LSTM-Attention	深度卷积神经网络
纵距/m	215.83	230.62	230.36	205.75	223.83
误差率/%	-	6.85	6.73	5.02	3.70
横距/m	131.55	127.44	127.59	129.62	130.35
误差率/%	-	-3.12	-3.09	-1.46	-0.91
战术直径/m	281.93	292.04	288.87	274.83	278.04
误差率/%	-	3.67	2.46	-1.45	-1.38
最大艏向角/(°)	353.21	333.18	339.39	344.36	345.75
误差率/%	-	-5.67	-3.92	-2.50	-2.11

在深度卷积神经网络的训练和验证案例中,卷积神经网络能有效提取水下航行器运动的特征向量,注意力机制将这些特征向量施加不同通道的权

重,优化特征向量的时序表征。特别是在进行 AUV 运动操纵试验中,舵角的变化引起加速度的显著变动,深度卷积神经网络模型能精确捕捉并分析这些

变化的动态过程,提取关键特征向量。由于自适应 VMD 降低船模试验噪声,使深度卷积神经网络能捕捉 AUV 的非线性特性,解决建模强耦合问题。因此,该模型不仅能对 AUV 的运动数据进行准确的时间序列预测,还展现出良好的泛化能力。

## 4 结束语

本文针对 AUV 船模试验数据因噪声影响导致预报精度低,提出一种基于自适应 VMD 去噪的深度卷积神经网络识别的建模方法,经过含噪声的 AUV 船模数据检验,证明该方法是有效可行的,并将其应用于 AUV 操纵运动模型参数辨识。通过模拟试验可以得出以下结论。

1) 利用自适应 VMD 降噪方法,能降低 AUV 数据中的噪声,自动调整信号分解层数,精确计算  $K$  值。

2) 在降噪船模数据的基础上,利用 BiLSTM 和 Attention 机制提高模型的预测精度,解决非线性 AUV 运动的强耦合问题。

3) 试验结果表明,该模型在建立 AUV 辨识建模时,纵向速度的误差比其他方法小,证明该方法具有有效的建模能力。

本文研究表明,深度卷积神经网络为水下航行器运动提供一种有效的建模策略。尽管本文提出的黑箱模型并不能对每个水动力导数进行解释,但获取的黑箱模型精度较高。未来将借助黑箱模型解释白箱模型参数概率范围、促进黑箱模型白箱化。同时,在考虑海流中 AUV 运动辨识、螺旋桨转速、最佳采样频率等方面进行进一步研究。

## 参 考 文 献

- [1] CHEN S, LIU F. Multi-objective shape optimization of underwater vehicles based on an adaptive sampling algorithm[J]. *Applied Ocean Research*, 2024, 146: 1-18.
- [2] 梅斌. 基于自航试验的船舶操纵运动灰箱辨识建模[D]. 大连:大连海事大学, 2020.
- MEI B. Grey box identification modeling for ship manoeuvring motion based on free running test [D]. Dalian:Dalian Maritime University, 2020. (in Chinese)
- [3] WANG N, ER M J, HAM M. Large tanker motion model identification using generalized ellipsoidal basis function-based fuzzy neural networks [J]. *IEEE Transactions on Cybernetics*, 2015, 45(12):2732-2743.
- [4] XU H, SOARES C G. Vector field path following for surface marine vessel and parameter identification based on LS-SVM [J]. *Ocean Engineering*, 2016, 113: 151-161.
- [5] WANG Z, ZOU Z, SOARES C G. Identification of ship manoeuvring motion based on nu-support vector machine [J]. *Ocean Engineering*, 2019, 183:270-281.
- [6] XUE Y, LIU Y, JI C, et al. Hydrodynamic parameter identification for ship manoeuvring mathematical models using a Bayesian approach [J]. *Ocean Engineering*, 2020, 195:1-11.
- [7] WANG Z, XU H, XIA L, et al. Kernel-based support vector regression for nonparametric modeling of ship maneuvering motion [J]. *Ocean Engineering*, 2020, 216:1-12.
- [8] SHEN W, YAO J, HU X, et al. Ship dynamics model identification based on Semblance least square support vector machine [J]. *Ocean Engineering*, 2023, 287: 1-10.
- [9] JIANG Y, HOU X R, WANG X G, et al. Identification modeling and prediction of ship maneuvering motion based on LSTM deep neural network [J]. *Journal of Marine Science and Technology*, 2022, 27(1):125-137.
- [10] 杨柯. 基于 Kane 动力学的十字舵型欠驱动 AUV 建模与仿真[J]. *水下无人系统学报*, 2023, 31(6):885-890.
- YANG K. Modeling and simulation of cross-rudder underactuated AUV based on Kane dynamics [J]. *Journal of Underwater Unmanned Systems*, 2023, 31(6):885-890. (in Chinese)
- [11] 周怡, 王俊雄. 自适应粒子群算法在 AUV 水动力参数辨识中的应用[J]. *舰船科学技术*, 2021, 43(21):90-95.
- ZHOU Y, WANG J X. Application of adaptive particle swarm optimization algorithm in AUV hydrodynamic parameter identification [J]. *Ship Science and Technology*, 2021, 43(21):90-95. (in Chinese)
- [12] 蒋志龙. 欠驱动 AUV 水动力参数辨识及跟踪控制算法研究[D]. 哈尔滨:哈尔滨工程大学, 2021.
- JIANG Z L. Research on hydrodynamic parameter identification and tracking control algorithm of underactuated AUV [D]. Harbin: Harbin Engineering University, 2021. (in Chinese)
- [13] 聂为彪, 钱治强, 吴铭, 等. 水下航行器横向操纵性运动预报设计与仿真[J]. *舰船科学技术*, 2021, 43(增刊1):22-26.
- NIE W B, QIAN Z Q, WU M, et al. Design and simulation of horizontal maneuvering motion prediction for the underwater vehicle [J]. *Ship Science and Technology*, 2021, 43(Suppl.1):22-26. (in Chinese)
- [14] 边靖伟, 寇立伟, 项基. 应用 PSO 和 SVM 的水下航

- 行器黑箱建模[J]. 哈尔滨工业大学学报, 2019, 51(10):55-82.
- BIAN J W, KOU L W, XIANG J. Black-box modeling based on PSO and SVM for underwater vehicles [J]. Journal of Harbin Institute of Technology, 2019, 51(10):55-82. (in Chinese)
- [15] ZHANG X, ZOU Z. Application of wavelet denoising in the modeling of ship manoeuvring motion[J]. Journal of Ship Mechanics, 2011, 15(6):616-622.
- [16] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A, 1998, 454:903-995.
- [17] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method Adv[J]. Advances in Adaptive Data Analysis, 2009, 1(1), 1-41.
- [18] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.
- [19] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报, 2015, 49(5):73-81.
- TANG G J, WANG X L. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of rolling bearing [J]. Journal of Xi'an Jiaotong University, 2015, 49(5):73-81. (in Chinese)
- [20] PANG B, ZHANG H, CHENG T, et al. Spectral variational mode extraction and its application in fault detection of rolling bearing [J]. Structural Health Monitoring, 2023, 22(1):449-471.
- [21] 房萍萍. 计及侧向流影响的自治水下航行器 6-DOF 运动仿真[D]. 天津:天津大学, 2014.
- FANG P P. 6-DOF motion simulation of autonomous underwater vehicles considering the influence of lateral flow [D]. Tianjin: Tianjin University, 2014. (in Chinese)
- [22] SAGATUN S I, FOSSEN T I. Lagrangian formulation of underwater vehicles' dynamics [C]//Conference Proceedings 1991 IEEE International Conference on Systems, Man, and Cybernetics. New York: IEEE, 1991:1029-1034.
- [23] 白伟伟. 基于局部加权学习的船舶操纵运动辨识建模[D]. 大连:大连海事大学, 2018.
- BAI W W. Identification modeling for ship manoeuvring motion based on locally weighted learning [D]. Dalian: Dalian Maritime University, 2018. (in Chinese)
- [24] 张钊. 基于非参数方法的船舶操纵运动辨识建模 [D]. 大连:大连海事大学, 2024.
- ZHANG Z. Non-parametric methods for ship maneuvering motion identification modeling [D]. Dalian: Dalian Maritime University, 2024. (in Chinese)
- [25] 李伟中. 基于深度学习的船舶运动辨识和预报[D]. 大连:大连海事大学, 2023.
- LI W Z. Ship motion identification and prediction based on deep learning [D]. Dalian: Dalian Maritime University, 2023. (in Chinese)
- [26] FOSSEN T I. Handbook of marine craft hydrodynamics and motion control[M]. Chichester: John Wiley, 2011.
- [27] VIGNESH D, ASOKAN T, VIJAYAKUMAR R. Performance analysis of a caudal fin in open water and its coupled interaction with a biomimetic AUV [J]. Ocean Engineering, 2024, 291:1-16.
- [28] WANG N, KONG X J, REN B Y, et al. SeaBil: self-attention-weighted ultrashort-term deep learning prediction of ship maneuvering motion [J]. Ocean Engineering, 2023, 287:1-9.
- [29] WEI Y Y, CHEN Z Z, ZHAO C, et al. A BiLSTM hybrid model for ship roll multi-step forecasting based on decomposition and hyperparameter optimization [J]. Ocean Engineering, 2023, 242:1-11.
- [30] LEI D, WANG H D, LOU J K. An attention mechanism model based on positional encoding for the prediction of ship maneuvering motion in real sea state[J]. Journal of Marine Science and Technology, 2024, 29(1):136-152.
- [31] XU D X, YIN J C. An enhanced hybrid scheme for ship roll prediction using support vector regression and TVF-EMD[J]. Ocean Engineering, 2024, 307: 1-12.