

文章编号: 1007-7294(2026)04-0557-11

基于改进降阶模型的实海域船舶 操纵运动实时预报

陈昌哲^a, 邹璐^{a,b}, 邹早建^{a,b}

(上海交通大学 a. 船舶海洋与建筑工程学院; b. 海洋工程全国重点实验室, 上海 200240)

摘要: 船舶运动的实时预报是保障船舶安全、高效航行的关键技术之一。本文基于高阶动态模态分解 HODMD(Higher Order Dynamic Mode Decomposition)算法, 构建了用于船舶操纵运动实时预报的改进降阶模型 ROM(Reduced-Order Model)。该模型通过将不同频率特征的操纵运动参数分别融入高频输入样本和低频输入样本中, 增强了输入样本中相近频率运动参数间的相关性。利用“育鲲”轮在实海域中的 35°回转运动数据进行了环境影响下的船舶操纵运动预报研究。改进 ROM 与原始 ROM 在预报精度上的比较分析结果显示, 改进 ROM 对于低频运动的预报精度远高于原始 ROM, 而对于高频运动的预报精度也略有提高。

关键词: 实海域中的船舶操纵运动; 实时预报; 高阶动态模态分解; 降阶模型

中图分类号: U661.33 文献标识码: A doi: 10.3969/j.issn.1007-7294.2026.04.005

Real-time prediction of ship maneuvering motion at sea based on improved Reduced-Order Model

CHEN Chang-zhe^a, ZOU Lu^{a,b}, ZOU Zao-jian^{a,b}

(a. School of Ocean and Civil Engineering; b. State Key Laboratory of Ocean Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: The real-time prediction of ship motion is one of the key technologies to ensure safe and efficient navigation of ships. Based on the Higher Order Dynamic Mode Decomposition (HODMD) algorithm, this paper constructs an improved Reduced-Order Model (ROM) for real-time prediction of ship maneuvering motion. The improved ROM enhances the correlation between maneuvering motion parameters of similar frequencies by separately incorporating the parameters into high-frequency and low-frequency input samples according to their frequency features. The prediction of ship maneuvering motion under environmental influences is conducted by using the ship motion data of a 35° turning circle maneuver of the ship YUKUN at sea. The comparative analysis of prediction accuracy between the improved ROM and the original ROM shows that the improved ROM exhibits significantly higher accuracy in predicting low-frequency motion and a slight improvement in predicting high-frequency motion compared to the original ROM.

Key words: ship maneuvering motion at sea; real-time prediction; Higher Order Dynamic Mode Decomposition; Reduced-Order Model

收稿日期: 2025-08-08

基金项目: 上海市船舶工程重点实验室基金项目(SE202303); 国家自然科学基金资助项目(51979164; 51979165); 中央高校基本科研业务费专项资金项目

作者简介: 陈昌哲(1994-), 男, 博士; 邹早建(1956-), 男, 教授, 博士生导师, 通讯作者, E-mail: zjzou@sjtu.edu.cn。

0 引言

船舶运动的实时预报在很多实际应用场景中展现出其独特的价值,例如,船舶在波浪作用下的摇荡运动会造成直升机的起降作业困难;在高海况条件下,母船与无人水面艇 USV(Unmanned Surface Vessel)在进行连接和回收作业时可能会出现对接失败的情况;两船在进行过驳作业时,它们之间的大幅度相对运动会造成货物传输困难,甚至无法实现。因此,需要对船舶运动进行准确、快速的实时预报,通过预测船舶运动的稳定窗口期,或利用船舶运动控制装置(如舵或减摇鳍)进行动态运动补偿控制,以提高船舶在复杂海况条件下的短期作业效率与安全性^[1]。由此可知,船舶运动的实时预报对于保障船舶的航行安全,提高船舶的海上作业效率以及船舶自动化水平具有十分重要的意义。

近年来,随着数据科学和人工智能技术的迅猛发展,数据驱动方法在船舶运动预报领域展现出巨大的潜力,涵盖了横摇^[2]、垂荡^[3]、垂荡和纵摇耦合运动^[4]以及船舶操纵运动^[5]等诸多方面。然而,现阶段训练和优化复杂的数据驱动模型通常需要大量计算资源和时间,难以满足在线建模的实时性要求。

动态模态分解 DMD(Dynamic Mode Decomposition)作为一种新颖的数据驱动建模方法,自2008年被提出以来,在众多领域引起了广泛关注^[6]。DMD通过对高维数据进行奇异值分解 SVD(Singular Value Decomposition)降维并提取主导模态的演化规律,建立低维的近似降阶模型 ROM(Reduced-Order Model),从而以较低计算代价重现系统的核心动力学行为。DMD能够将复杂系统精确分解为时空相干结构,并可用于未来状态的短期运动预报和控制^[7]。具体而言,DMD不仅可以将复杂的动态系统分解为具有单一频率和增长率的模态,进而通过模态分析揭示系统的动力学特性,同时,这些分解的模态还可以用于重构系统并实现时序预报。目前,已有学者如 Diez 等^[8]和 Serani 等^[9]采用全阶标准 DMD 算法对船舶在波浪中的操纵运动进行了分析和时序预报。Chen 等^[10]采用降阶标准 DMD 算法重构和时序预报了船舶在静水中的 Z 形和回转操纵运动,结果表明,尽管采用标准 DMD 算法预报船舶操纵运动的效率很高,但其预报精度仍有待进一步提高,这主要是因为标准 DMD 算法的 Koopman 假设在空间复杂度小于频谱复杂度的系统中并不完全适用^[11]。

为了克服这一局限性,Le Clainche 和 Vega^[12]于2017年提出了高阶动态模态分解 HODMD(Higher Order Dynamic Mode Decomposition),通过将 Koopman 假设扩展到高阶情形,HODMD 在处理低维、多频系统时的重构与预报精度明显优于标准 DMD。近年来,HODMD 已在多个工业领域^[13-17]得到了成功应用。本文作者首次将 HODMD 应用于船舶运动预报,分别对船舶在规则波中的航向保持运动^[18]以及回转操纵运动^[19-20]进行了时序预报,验证了该方法的有效性和准确性。然而,前期研究中基于 HODMD 的预报方法仅针对船模在规则波中的运动,而对于实海域中的实船操纵运动是否适用,仍有待探究。

为此,本文利用“育鲲”轮在实海域中的 35°回转操纵运动数据进行实际海况下的五自由度船舶运动预报研究。首先,基于 HODMD 算法构建了用于船舶运动实时预报的改进 ROM。然后,分别采用原始 ROM 和改进 ROM 对实海域中的实船 35°回转操纵运动进行了实时预报。最后,比较分析原始 ROM 和改进 ROM 在预报精度和计算效率上的差异。

1 研究对象

选取“育鲲”轮为研究对象,该船是大连海事大学的专用航海训练船,有着丰富的实船海试数据。该船的主要参数如表 1 所示。

采用的船舶操纵运动数据源自北京时间 2012 年 8 月 24 日 08:00 至 14:00 进行的“育鲲”轮海试。试验中充分记录了“育鲲”轮的五自由度操纵运动时历数据,即:纵向位移 x 、横向位移 y 、横摇角 ϕ 、纵摇角 θ 以及首向角 ψ 。海试地点位于黄海西北部,距离大连港约 14 海里。海试期间的海况条件稳定,

约为2至3级；风速约为2.1~7.8 m/s，对应蒲福风级3至4级，风向为偏东风；流速约为0.1~1.2 m/s。更多海试的详细信息见文献[21]。

表1 “育鲲”轮的主要参数

Tab.1 Main parameters of the ship YUKUN

主要参数/单位	数值	主要参数/单位	数值
总长 (L_{oa}) /m	116	型深 (D_1) /m	8.35
垂线间长 (L_{pp}) /m	105	吃水 (D_2) /m	5.4
型宽 (B) /m	18	排水量 (∇) /t	5735.5

选取其中进行35°回转操纵运动的海试数据作为研究对象。选取的海试数据时长总计340 s，“育鲲”轮在整个操纵运动过程中保持35°舵角，其运动轨迹如图1所示。从图中可以看出，在海试过程中，“育鲲”轮的轨迹呈现出向西漂移的趋势，说明海试过程中环境因素（风、浪以及海流）对船舶运动产生的漂移力是不可忽视的。




图1 “育鲲”轮35°回转操纵的运动轨迹

Fig.1 Trajectory of the 35° turning circle maneuver of the ship YUKUN

2 基于HODMD的船舶操纵运动实时预报

2.1 原始ROM

当船舶在海域中航行时，由于外界环境（如风、浪和海流）以及船舶控制器（如舵角和螺旋桨转速）状态的时变性影响，必须随时更新包含船舶运动信息的输入样本，以实现在线建模，进而对船舶操纵运动进行实时预报。原始ROM的输入样本包含了研究范围内的全部船舶运动信息，主要步骤如下。

步骤1：通过物理试验、数值模拟或工程实际测量，获取前 K 个时刻的输入样本矩阵 $\mathbf{V}_1^K = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_K]$ 。应当注意的是，本文以 $\mathbf{V}_{k_1}^{k_2}$ 表示从第 k_1 个样本矢量到第 k_2 个样本矢量组成的样本矩阵，而对于幂指数的表示，以括号加上标作为区分。对于船舶操纵运动预报问题，输入样本矩阵的第 k 个样本 $\mathbf{v}_k (k=1, 2, \dots, K)$ 所包含的变量具有灵活性，可以包含第 k 个时刻船舶在各个自由度上的速度分量，也可以包含与船舶运动紧密相关的其他变量，如舵角、舵力、螺旋桨转速或推力。需要特别注意的是， $\mathbf{v}_k$ 中变量的相关性对预报精度有着直接影响。一般来说，输入样本中变量间的相关性越强，HODMD的预报精度就越高。对于本文研究的“育鲲”轮五自由度操纵运动预报，输入样本矩阵 $\mathbf{V}_1^K$ 为

$$\mathbf{V}_1^K = \begin{bmatrix} x_1 & x_2 & \cdots & x_K \\ y_1 & y_2 & \cdots & y_K \\ \psi_1 & \psi_2 & \cdots & \psi_K \\ \phi_1 & \phi_2 & \cdots & \phi_K \\ \theta_1 & \theta_2 & \cdots & \theta_K \end{bmatrix} \quad (1)$$

步骤 2: 为了确保船舶运动预报的精度, 必须对输入样本矩阵进行预处理。首先, 为了增加输入样本矩阵的维度, 使得 HODMD 更适用于非线性系统, 采用四阶有限差分格式计算 $\mathbf{v}_k$ 中每个变量的一阶和二阶时间导数, 并将这些导数信息增补到样本中^[8]。然后, 对样本中的每个变量及其时间导数进行 Z-Score 标准化处理, 使其具有零均值和单位标准差。Z-Score 标准化的目的是将样本中不同量级和单位的变量统一缩放到相同的数据区间和范围内, 从而提高数据间的可比性, 并确保后续预测的准确性。对于 $\mathbf{v}_k$ 中的任意变量或其时间导数 ζ_{jk} , Z-Score 标准化可表示为

$$\hat{\zeta}_{jk} = \frac{\zeta_{jk} - \bar{\zeta}_j}{S_j}, j = 1, 2, \dots, J; k = 1, 2, \dots, K \quad (2)$$

式中: $\hat{\zeta}_{jk}$ 为标准化后的变量或其时间导数; $\bar{\zeta}_j$ 和 S_j 分别为 ζ_{jk} 的时间平均值和标准差, 其中 S_j 表示为

$$S_j = \sqrt{\frac{\sum_{k=1}^K (\zeta_{jk} - \bar{\zeta}_j)^2}{K}}, j = 1, 2, \dots, J \quad (3)$$

步骤 3: 采用 HODMD^[11] 对经过预处理的输入样本矩阵进行模态分解, 进而提取出若干相关模态, 并得到对应模态的振幅、增长率和频率。

HODMD 的主要功能是将任意时空耦合数据分解表示为 N 个模态的叠加, 其表达式为

$$\mathbf{v}_k = \sum_{n=1}^N a_n \mathbf{u}_n e^{(\delta_n + i\omega_n)(k-1)\Delta t}, k = 1, 2, \dots, K \quad (4)$$

式中: Δt 为相邻两个样本的时间间隔; a 、 $\mathbf{u}$ 、 δ 和 ω 分别为未知的模态振幅、DMD 模态、增长率和频率。

为了求解式(4)中的未知项, 通过 SVD 将预处理后的输入样本矩阵 $\mathbf{V}_1^K$ 分解为空间模态 $\mathbf{U}$ 、奇异值矩阵 $\mathbf{S}$ 和时间模态 $\mathbf{T}$, 即

$$\mathbf{V}_1^K \approx \mathbf{U} \mathbf{S} \mathbf{T}^H = \mathbf{U} \hat{\mathbf{V}}_1^K \quad (5)$$

式中: $\hat{\mathbf{V}}_1^K$ 为降阶样本矩阵, $(\cdot)^H$ 代表复共轭转置矩阵。

需要注意的是, 在式(5)中应用了降维处理以消除原始数据中的空间冗余或噪声, 降维后仅保留 N 个空间模态(或 N 个奇异值), 其中 N 是满足下列不等式的最小正整数。

$$\sqrt{\frac{(\sigma_{N+1})^2 + (\sigma_{N+2})^2 + \cdots + (\sigma_R)^2}{(\sigma_1)^2 + (\sigma_2)^2 + \cdots + (\sigma_R)^2}} < \varepsilon_{\text{SVD}} \quad (6)$$

式中: σ 为按降序排列于对角矩阵 $\mathbf{S}$ 上的奇异值, R 为输入样本矩阵的秩, ε_{SVD} 为可调参数, 代表 SVD 的截断程度。

使降阶样本矩阵满足以下高阶 Koopman 假设

$$\hat{\mathbf{V}}_{d+1}^K = \hat{\mathbf{R}}_1 \hat{\mathbf{V}}_1^{K-d} + \hat{\mathbf{R}}_2 \hat{\mathbf{V}}_2^{K-d+1} + \cdots + \hat{\mathbf{R}}_d \hat{\mathbf{V}}_d^{K-1} \quad (7)$$

式中: d 为可调参数, 代表高阶 Koopman 假设的阶数; $\hat{\mathbf{R}}$ 为降阶 Koopman 矩阵。 $\hat{\mathbf{R}}$ 并非直接通过式(7)求解, 而是将式(7)改写为以下形式

$$(\mathbf{V}^*)_2^{K-d+1} = \mathbf{R}^* (\mathbf{V}^*)_1^{K-d} \quad (8)$$

式中: $\mathbf{R}^*$ 和 $\mathbf{V}^*$ 分别为增广 Koopman 矩阵和增广样本矩阵, 定义如下

$$\mathbf{R}^* = \begin{bmatrix} 0 & \mathbf{I} & 0 & 0 & 0 & 0 \\ 0 & 0 & \mathbf{I} & 0 & 0 & 0 \\ \cdots & \cdots & \cdots & \mathbf{I} & 0 & 0 \\ 0 & 0 & 0 & 0 & \mathbf{I} & 0 \\ \hat{\mathbf{R}}_1 & \hat{\mathbf{R}}_2 & \hat{\mathbf{R}}_3 & \cdots & \hat{\mathbf{R}}_{d-1} & \hat{\mathbf{R}}_d \end{bmatrix}, \quad (\mathbf{V}^*)_1^{K-d+1} = \begin{bmatrix} \hat{\mathbf{V}}_1^{K-d+1} \\ \hat{\mathbf{V}}_2^{K-d+2} \\ \cdots \\ \hat{\mathbf{V}}_{d-1}^{K-1} \\ \hat{\mathbf{V}}_d^K \end{bmatrix} \quad (9)$$

式中: $\mathbf{I}$ 为单位矩阵。

通过计算增广 Koopman 矩阵 $\mathbf{R}^*$ 的特征值和特征向量, 可获得式(4)中的 DMD 模态 $\mathbf{u}$ 、增长率 δ 和频率 ω 。另外, 通过最小二乘拟合确定式(4)中的模态振幅 a 。

步骤 4: 根据模态对系统贡献的重要性进行排序, 从中筛选出重要性最高的 $\tilde{N}$ 个模态, 这些模态被称为主导模态, 并将被用于系统的重构。本文采用文献[22] 中提出的一种模态排序准则。

步骤 5: 基于式(4), 将选取的主导模态对系统进行重构, 并通过外推方法预报未来 K_p 个时刻的船舶运动状态

$$\tilde{\mathbf{v}}_k = \sum_{n=1}^{\tilde{N}} a_n \mathbf{u}_n e^{(\delta_n + i\omega_n)(k-1)\Delta t}, k = 1, 2, \cdots, K + K_p \quad (10)$$

式中: $\tilde{\mathbf{v}}_k$ 为所有重构的运动数据, $[\tilde{\mathbf{v}}_1, \tilde{\mathbf{v}}_2, \cdots, \tilde{\mathbf{v}}_K]$ 是在样本采样段进行重构后的运动数据, $[\tilde{\mathbf{v}}_{K+1}, \tilde{\mathbf{v}}_{K+2}, \cdots, \tilde{\mathbf{v}}_{K+K_p}]$ 是外推后预报的运动数据。

步骤 6: 数据后处理。在重构段内, 重构的运动数据与真实值之间的误差会逐渐累积, 这种累积误差在预报段内会导致预报结果与真实值之间产生一个显著的常值误差。随着实时预报的进行, 这种常值误差会逐渐累积, 使预报结果明显偏离真实值。由于前 K 个输入样本是已知的, 并且前 K 个重构样本也可以计算得到。因此, 上述常值误差可以通过第 K 个输入样本与第 K 个重构样本之间的差值来计算。为了消除这一误差, 需要对预报的运动数据进行后处理

$$\tilde{\mathbf{v}}_k^* = \tilde{\mathbf{v}}_k - (\tilde{\mathbf{v}}_K - \mathbf{v}_K), k = K + 1, K + 2, \cdots, K + K_p \quad (11)$$

式中: $\tilde{\mathbf{v}}_k^*$ 为后处理后的预报结果。

步骤 7: 将输入样本沿着时间序列向前推进 K_p 个样本 (K_p 步前向预报), 然后重复步骤 1~6。这样, 可以预报得到第 $K+K_p+1$ 到第 $K+2K_p$ 个样本的数据。通过不断迭代这个过程, 直到完成所有样本的预报。

2.2 改进 ROM

显然, 原始 ROM 中将研究的所有船舶运动信息纳入同一输入样本的做法存在一定的局限性。如前文所述, 输入样本中变量间的相关性对 HODMD 方法的预报精度具有显著影响。将相关性较弱的变量置于同一样本中可能会降低 HODMD 的预报效果。分析本文研究的“育鲲”轮纵向位移 x 、横向位移 y 、横摇角 ϕ 、纵摇角 θ 以及首向角 ψ 这些五自由度运动特征可以发现, x 、 y 及 ψ 的变化主要源于螺旋桨推力、舵力以及二阶波浪力的共同作用, 展现出低频变化的特性。同时, 这三个自由度的运动可以通过三自由度船舶操纵运动方程进行描述, 因此它们之间具有较高的相关性。相对而言, ϕ 和 θ 的变化则主要由高频波浪力引起, 呈现出高频变化的特征; 这两个自由度的运动可以通过横摇-纵摇耦合运动方程来描述, 因此它们之间也具有较高的相关性。因此, 本文提出一种改进 ROM: 将 x 、 y 和 ψ 这三个低频变化的变量整合到同一样本中, 命名为“低频样本”, 而将 ϕ 和 θ 这两个高频变化的变量纳入另一样本中, 命名为“高频样本”。因此, 对于改进 ROM, 输入为低频样本矩阵 $(\mathbf{V}_1^K)_L$ 和高频样本矩阵 $(\mathbf{V}_1^K)_H$, 其表达形式分别如下

$$(\mathbf{V}_1^K)_L = \begin{bmatrix} x_1 & x_2 & \cdots & x_K \\ y_1 & y_2 & \cdots & y_K \\ \psi_1 & \psi_2 & \cdots & \psi_K \end{bmatrix}, \quad (\mathbf{V}_1^K)_H = \begin{bmatrix} \phi_1 & \phi_2 & \cdots & \phi_K \\ \theta_1 & \theta_2 & \cdots & \theta_K \end{bmatrix} \quad (12)$$

改进 ROM 通过将这两个样本矩阵分别独立地用于实时预报, 以提高预报的准确性, 而其他的预报步骤与原始 ROM 一致。基于这种改进 ROM 的实时预报流程如图 2 所示。




图2 基于改进 ROM 的实时预报流程图

Fig.2 Flowchart of real-time prediction based on the improved ROM

3 实时预报

3.1 算法设置

为验证改进 ROM 的有效性,选取 340 s 的海试数据作为研究对象。该数据集包含了 340 个样本,相邻样本之间的时间间隔 Δt 为 1.0 s。输入样本的数量 K 为 40,即在预报过程中,每次仅采用 40 个样本进行特征提取与重构预报。预报样本的数量 K_p 则分别设为 1、5 和 10。实时预报过程按照以下步骤进行:首先预报 K_p 个样本,随后将输入样本和预报样本均向前移动 K_p 个(即 K_p 步前向预报),接着继续预报接下来的 K_p 个样本,直到所有样本均完成预报。以 5 步前向预报为例,图 3 给出了实时预报过程中的输入样本和预报样本变化。

在改进 ROM 中,将 x 、 y 和 ψ 选为低频样本,将 ϕ 和 θ 选为高频样本。HODMD 算法中的可调参数参照文献[20] 设置如下:奇异值分解截断系数 ε_{SVD} 为 0.002,主导模态截断系数 ε_{DMD} 为 0.02。经过预研究,选择了计算精度最高时的高阶 Koopman 假设阶数 d ,具体如下:对于原始 ROM,1 步、5 步和 10 步前向预报对应的 d 分别为 7、10 和 16;对于改进 ROM,在计算低频样本时,1 步、5 步和 10 步前向预报对应的 d 分别为 3、2 和 2,而在计算高频样本时, d 则分别为 11、5 和 5。

3.2 预报结果

为了评估预报结果与海试数据之间的相对误差,分别定义低频运动的相对均方根误差 RRMSE_L (Relative Root Mean Square Error of low-frequency motion) 和高频运动的相对均方根误差 RRMSE_H (Relative Root Mean Square Error of high-frequency motion) 如下




图 3 输入样本和预报样本（5 步前向预报）

Fig.3 Input and predicted samples (5-step ahead prediction)

$$\text{RRMSE}_L(k) = \sqrt{\frac{\|(\mathbf{v}_k)_L - (\tilde{\mathbf{v}}_k^*)_L\|_F^2}{\|(\mathbf{v}_k)_L\|_F^2}} \quad (13)$$

$$\text{RRMSE}_H(k) = \sqrt{\frac{\|(\mathbf{v}_k)_H - (\tilde{\mathbf{v}}_k^*)_H\|_F^2}{\|(\mathbf{v}_k)_H\|_F^2}} \quad (14)$$

式中: $k = K+1, K+2, \dots, K+K_p$, $\|\cdot\|_F$ 为 Frobenius 范数, $(\mathbf{v}_k)_L$ 和 $(\mathbf{v}_k)_H$ 分别为低频样本和低频样本的真实值, $(\tilde{\mathbf{v}}_k^*)_L$ 和 $(\tilde{\mathbf{v}}_k^*)_H$ 分别为低频样本和低频样本的预报值。RRMSE_L 和 RRMSE_H 越小, 代表预报精度越高。

图 4~6 分别给出了 35° 回转操纵运动的 1 步、5 步以及 10 步前向预报结果, 预报结果均为 Z-score




图 4 35° 回转操纵运动的 1 步前向预报 (Z-score 标准化结果)

Fig.4 1-step ahead prediction of 35° turning circle maneuver (Z-score normalization)




图5 35°回转操纵运动的5步前向预报 (Z-score 标准化结果)

Fig.5 5-step ahead prediction of 35° turning circle maneuver (Z-score normalization)




图6 35°回转操纵运动的10步前向预报 (Z-score 标准化结果)

Fig.6 10-step ahead prediction of 35° turning circle maneuver (Z-score normalization)

标准化处理后的, 因此为无因次量。从图中可以看出, 随着预报样本的数量 K_p 的增加, 两种 ROM 的预报结果均与海试数据差距增大, 预报精度均呈现显著下降的趋势。在所有的工况中, 改进 ROM 预报的低频运动(x 、 y 和 ψ)均与海试数据吻合很好, 且得到的 $RRMSE_L$ 明显小于原始 ROM 得到的, 因此改进 ROM 对于低频运动的预报精度远高于原始 ROM。在 1 步前向预报中, 无论是原始 ROM 还是改进 ROM, 其预报的高频运动(ϕ 和 θ)都与海试数据保持了良好的一致性; 但在 5 步和 10 步前向预报中, 两种 ROM 预报的高频运动与试验数据均存在较大的偏差。在所有工况中, 改进 ROM 得到的 $RRMSE_H$ 都略小于原始 ROM 得到的, 因此改进 ROM 对于高频运动的预报精度略高于原始 ROM。

3.3 计算效率分析

所有计算均在一台笔记本电脑(AMD Ryzen CPU 5 4500U, 主频 2.38 GHz, 8 GB 内存)上进行。为直接对比不同 ROM 模型的计算时间, 每种 ROM 的平均计算时间均通过运行程序一百次后取平均值获得。图 7 展示了原始 ROM 和改进 ROM 的平均计算时间。可以看出, 随着 d 的增加, 平均计算时间均先增加后减小。当 d 较小时, 原始 ROM 和改进 ROM 的平均计算时间相差不大; 当 d 较大时, 改进 ROM 的平均计算时间比原始 ROM 的长。两种 ROM 的平均计算时间(小于 3 s)远小于预报的实际时间(300 s), 满足实时预报的要求。




图7 原始 ROM 和改进 ROM 的平均计算时间

Fig.7 Average computational times of the original and improved ROMs

4 结 论

本文将 HODMD 算法应用于实海域船舶操纵运动的实时预报, 验证了 HODMD 在预报复杂、非线性船舶动态行为方面的能力。通过持续引入新的观测数据并不断地更新预报模型, 构建了两种 ROM, 实现了对实船操纵运动的实时预报。主要结论如下:

(1)对于本文基于HODMD算法构建的两种ROM均可实现对实海域船舶运动的实时预报。

(2)通过比较分析原始ROM和改进ROM在预报精度上的差异可知,改进ROM在低频运动预报方面的精度远高于原始ROM,在高频运动预报方面的精度也略有提高。

(3)基于HODMD构建的两种ROM均展现出很高的计算效率,其平均计算时间远小于预报的实际时间,满足实时预报的要求。

本文以船舶操纵运动相关的时间序列历史数据作为输入样本矩阵中的变量,应用HODMD方法构建船舶未来运动的预报模型所建立的模型已充分计入历史数据所反映的船舶动力学特征,可以对未来船舶操纵运动进行准确预报。然而,由于建模时并未将后续时刻的船舶控制变量和外界环境作为输入,所以当船舶控制变量(如舵角和螺旋桨转速)和外界环境(如风、浪和海流)发生显著变化时,所建立模型对未来船舶操纵运动的预报精度可能会明显下降,预报结果也很难为船舶运动控制策略提供有效参考。为了提高船舶运动预报和控制的精度与效率,后续研究可考虑将船舶控制变量和外界环境因素作为输入引入建模过程。带控制的DMDc(Dynamic Mode Decomposition with control)^[23-24]为实现这一研究思路提供了可能。

参 考 文 献:

- [1] 段文洋, 张亚晖, 王 战, 等. 船舶运动安稳期预报技术综述[J]. 中国舰船研究, 2015, 10(4): 1-6+15.
Duan W Y, Zhang Y H, Wang Z, et al. Review on the technique of the ship motion quiescent period prediction[J]. Chinese Journal of Ship Research, 2015, 10(4): 1-6+15. (in Chinese)
- [2] 彭秀艳, 刘长德. 基于格型递归最小二乘算法的船舶运动极短期预报[J]. 船舶力学, 2012, 16(1-2): 44-51.
Peng X Y, Liu C D. Extreme short time prediction of ship motion based on lattice recursive least square[J]. Journal of Ship Mechanics, 2012, 16(1-2): 44-51. (in Chinese)
- [3] Guo X X, Zhang X T, Tian X L, et al. Probabilistic prediction of the heave motions of a semi-submersible by a deep learning model[J]. Ocean Engineering, 2022, 247: 110578.
- [4] Guo X X, Zhang X T, Tian X L, et al. Predicting heave and surge motions of a semi-submersible with neural networks[J]. Applied Ocean Research, 2021, 112: 102708.
- [5] D'agostino D, Serani A, Stern F, et al. Time-series forecasting for ships maneuvering in waves via recurrent-type neural networks[J]. Journal of Ocean Engineering and Marine Energy, 2022, 8: 479-487.
- [6] Schmid P J. Dynamic mode decomposition and its variants[J]. Annual Review of Fluid Mechanics, 2022, 54: 225-254.
- [7] Kutz J N, Brunton S L, Brunton B W, et al. Dynamic mode decomposition: Data-driven modeling of complex systems[M]. Society for Industrial and Applied Mathematics, 2016.
- [8] Diez M, Serani A, Campana E F, et al. Time-series forecasting of ships maneuvering in waves via dynamic mode decomposition[J]. Journal of Ocean Engineering and Marine Energy, 2022, 8: 471-478.
- [9] Serani A, Dragone P, Stern F, et al. On the use of dynamic mode decomposition for time-series forecasting of ships operating in waves[J]. Ocean Engineering, 2023, 267: 113235.
- [10] Chen C Z, Liu S Y, Zou Z J, et al. Time series prediction of ship maneuvering motion based on dynamic mode decomposition[J]. Ocean Engineering, 2023, 286: 115446.
- [11] Vega J M, Le Clainche S. Higher order dynamic mode decomposition and its applications[M]. New York: Academic Press, 2020.
- [12] Le Clainche S, Vega J M. Higher order dynamic mode decomposition[J]. SIAM Journal on Applied Dynamical Systems, 2017, 16(2): 882-925.
- [13] Kou J Q, Le Clainche S, Zhang W W. A reduced-order model for compressible flows with buffeting condition using higher order dynamic mode decomposition with a mode selection criterion[J]. Physics of Fluids, 2018, 30(1): 016103.
- [14] Cheng C, Ding J, Zhang Y. A Koopman operator approach for machinery health monitoring and prediction with noisy and low-dimensional industrial time series[J]. Neurocomputing, 2020, 406: 204-214.

- [15] Groun N, Villalba-orero M, Lara-pezzi E, et al. Higher order dynamic mode decomposition: From fluid dynamics to heart disease analysis[J]. *Computers in Biology and Medicine*, 2022, 144: 105384.
- [16] Lu Z W, Li F, Cao S C, et al. Crack localization in operating rotors based on multivariate higher order dynamic mode decomposition[J]. *Sensors*, 2022, 22: 6131.
- [17] Jones C N S, Utyuzhnikov S V. Application of higher order dynamic mode decomposition to modal analysis and prediction of power systems with renewable sources of energy[J]. *International Journal of Electrical Power and Energy Systems*, 2022, 138: 107925.
- [18] Chen C Z, Zou Z J, Zou L, et al. Time series prediction of ship course keeping in waves using higher order dynamic mode decomposition[J]. *Physics of Fluids*, 2023, 35(9): 097139.
- [19] 陈昌哲, 邹早建, 邹璐, 等. 基于高阶动态模态分解的波浪中船舶操纵运动时序预报[J]. *中国造船*, 2023, 64(6): 216–224.
- Chen C Z, Zou Z J, Zou L, et al. Time series prediction of ship maneuvering motion in waves based on higher order dynamic mode decomposition[J]. *Shipbuilding of China*, 2023, 64(6): 216–224. (in Chinese)
- [20] Chen C Z, Liu S Y, Zou Z J, et al. Real-time prediction of ship maneuvering motion in waves based on an improved reduced-order model[J]. *Ocean Engineering*, 2024, 312: 119244.
- [21] Mei B, Sun L C, Shi G Y. Full-scale maneuvering trials correction and motion modelling based on actual sea and weather conditions[J]. *Sensors*, 2020, 20: 3963.
- [22] Kou J Q, Zhang W W. An improved criterion to select dominant modes from dynamic mode decomposition[J]. *European Journal of Mechanics B-Fluids*, 2017, 62: 109–129.
- [23] Proctor J L, Brunton S L, Kutz J N. Dynamic mode decomposition with control[J]. *SIAM Journal on Applied Dynamical Systems*, 2016, 15(1): 142–161.
- [24] Palma G, Bardazzi A, Lucarelli A, et al. Analysis, forecasting, and system identification of a floating offshore wind turbine using dynamic mode decomposition[J]. *Journal of Marine Science and Engineering*, 2025, 13: 656.