

基于协同模型的船舶运动状态预测

刁峰^{1,2}, 周利³, 刘天宇¹, 李费旭⁴, 韩森^{4*}

(1. 深海技术科学太湖实验室 连云港中心, 江苏连云港 222000; 2. 中国船舶科学研究中心, 江苏无锡 214082; 3. 上海交通大学 船舶海洋与建筑工程学院, 上海 200240; 4. 江苏科技大学 船舶与海洋工程学院, 江苏镇江 212003)

摘要: [目的]为解决以物理模型或者神经网络模型的单模式船舶运动状态预测方法适用性和精度不足的问题, [方法]利用物理模型和长短期记忆网络相结合的方法对船舶运动状态进行预测分析, 通过改变物理参数获得不同类型船舶的特性, 融合 Transformer 对混合模型的稳定性和可行性进行验证。[结果]结果表明: 相对于单模式模型, 该协同模型在预测精度方面表现出明显优势, 在模拟数据集下获得了良好的效果, 且在实船数据下表现也较好, 其中预测误差均控制在 5% 以内, 决定系数稳定在 0.85 以上。[结论]研究成果可为船舶运动状态预测提供一定参考。

关键词: 船舶状态预测; 物理模型; 长短期记忆网络; Transformer

中图分类号: U661 **文献标志码:** A **【DOI】** 10.13788/j.cnki.cbge.2026.01.12

Prediction of Ship Motion Based on Collaborative Model

DIAO Feng^{1,2}, ZHOU Li³, LIU Tianyu¹, LI Feixu⁴, HAN Sen^{4*}

(1. Lianyungang Center, Taihu Laboratory of Deep-Sea Technological Science, Lianyungang 222000, Jiangsu, China; 2. China Ship Scientific Research Center, Wuxi 214082, Jiangsu, China; 3. School of Ocean and Civil Engineering, Shanghai Jiao Tong University, Shanghai 200240, China; 4. School of Naval Architecture and Ocean Engineering, Jiangsu University of Science and Technology, Zhenjiang 212003, Jiangsu, China)

Abstract: [Purpose] To address the limitations in applicability and accuracy of single-mode ship motion state prediction methods using physical models or neural network models, [Method] the combination of physical model and long short-term memory network is used to predict and analyze the ship motion state, and the characteristics of different types of ships are obtained by changing the physical parameters, and the stability and feasibility of the method are verified by Transformer. [Result] The results show that compared with the single-mode model, the collaborative model has obvious advantages in prediction accuracy and effect, in which the error percentage is within 5%, and the coefficient of determination is stable above 0.85, [Conclusion] The research results can provide some references for predicting the motion state of ships.

Key words: prediction of ship status; physical model; long short-term memory network; Transformer

0 引言

在全球经济迅速发展的大环境下, 成本效益显著且运输能力强大的海运成为物流领域的首选方案。为了避免碰撞、搁浅等潜在风险, 保障航行安全与效率, 科研及工业领域着手深入研究船舶运动态势。开发精确的动力学模型和稳定的数据驱动模型, 能够对船舶的运动状态进行监测和预测, 保障海上航

行安全。目前, 关于船舶运动状态的预测与分析主要分为模型驱动、数据驱动和协同驱动等3种方法。

基于模型的方法主要通过物理模型制定一个线性回归模型, 采用数值模拟、模型试验或实船数据来确定参数。该方法最大优势在于可以用一个小的数据集来校准, 以参数化的方式找到一个最优函数, 并查看已识别的参数以检查模型的有效性。LANG

收稿日期: 2024-10-05; 修回日期: 2024-11-21

基金项目: 国家重点研发计划项目(2022YFE0107000); 国家自然科学基金面上项目(52171259)。

作者简介: 刁峰(1986—), 男, 博士、高级工程师。研究方向: 船舶总体设计。

通信作者: 韩森(1992—), 男, 博士、讲师。研究方向: 智能船舶运动预测。

等^[1]利用基于速度-功率模型试验的物理信息对静水中船舶的期望航速进行建模,结合极端梯度提升算法估计实际天气条件下的航速。结果表明,当数据量足够时,该方法可以将速度预测的精度提高30%左右;当数据量有限时,也能显著提高预测结果。WANG等^[2]对扩展卡尔曼滤波和Unscented Kalman滤波器等2种模型进行修改,使其能够与离散时间测量兼容,在不同场景下实现了船舶操纵数据的预测。结果表明,扩展卡尔曼滤波与三坐标测量机相结合有不稳定的趋势,而其他情况下更稳定。GAO等^[3]引入了一个物理假设来平衡计算的复杂性和准确性,采用3次样条插值和历史轨迹实现,结合了TPNet和LSTM的优点,不仅易于实现,适合于实时分析,还具有较高的预测精度。同时,通过长江江苏段的一艘渡船数据验证了该方法的有效性。PAPADIMITRAKIS等^[4]利用径向基函数框架进行航迹预测,以实际的船舶自动识别系统(Automatic Identification System, AIS)数据为训练对象,采用模型预测控制器解决了多船控制的问题。

基于数据驱动的方法提供了简约的非参数模型,该方法不依赖于科学知识,但需要比纯物理模型更多的数据进行校准。RONG等^[5]将船舶运动预测分解为横向和纵向进行概率计算,利用连续概率分布对未来船舶航迹位置的不确定性进行了描述。将3个月的AIS数据用于训练和测试概率轨迹预测模型。结果表明,该方法具有较高的预测精度,满足实时应用的要求。LIU等^[6]提出了一种基于长短期记忆(Long Short-Term Memory, LSTM)的智能数据驱动的船舶轨迹预测框架,并对混合损失函数进行了重构,使轨迹预测框架在不同的试验条件下更加可靠和稳健。在此基础上,对实际舰船轨迹进行了定量和定性试验,证明了该方法在精度和鲁棒性方面都能达到较好的轨迹预测效果。LEE等^[7]将长短期记忆网络和卷积神经网络相结合,对一个新的海洋环境进行了确定性预测,并根据输入数据和神经网络结构对测试结果的准确性和可靠性进行了研究。结果表明,该编解码系统能够有效考虑船舶水动力模型中的运动记忆效应和波浪激励,实现船舶运动预测。TANG等^[8]通过长短期记忆模型提出了轨迹预测方法,采用天津港的AIS的数据对所提出的模型进行了训练和测试。试验结果表明,该模型可以准确预测船舶的运动轨迹,适用于自主导航系统。MURRAY等^[9]提出了一种应用机器学习来推断相关轨迹段的方法,采用历史AIS数据来预测船只的未来轨迹,该方法产生了较好的结果,具有较高的分类精度和较低的预测误差。KAWAN等^[10]提出了一种灵活的支持向量回归以解决回归问题,对海量船舶传感器生成的数据集进行敏感性分析,将高度

显著的属性作为输入特征,利用非线性函数映射成高维特征,实现船舶运动预测的支持向量回归模型。结果表明,所提出的系统结构能够有效预测不同的船舶运动属性。

基于协同模型的方法结合了基于物理模型的方法和数据驱动的方法。KANAZAWA等^[11]利用机器学习模型补偿基于物理模型所产生的位置误差,并对未来的轨迹进行预测,通过模拟试验和全尺寸试验进行验证。结果表明,基于物理模型的精度和数据量在一定程度上是互补的,预测效果较好。SKULSTAD等^[12]提出了一种基于船舶监督机器学习(Machine Learning, ML)模型与船舶动力学模型相结合的船舶位置预测工具,减少了典型的纯数据驱动预测中遇到的黑箱因素。结果表明,基于数据的ML模型能显著提高预测精度。WANG等^[13]将模型估计的船舶状态集成到校准器中,对信息进行解释和结转,并在Gunnerus号科考船上进行了仿真和全尺寸试验。结果表明,该模型大大提高了科考船的预测能力。SCHIRMANN等^[14]将脊回归和神经网络模型用于船舶状态预测,并使用波浪模型参数作为输入进行了训练和测试。SKULSTAD等^[12]将船舶的监督机器学习ML模型集成到船舶动态模型中来提供位置预测,机器学习模型被用作未建模行为的补偿器,增加了预定知识的数量,减少了纯数据驱动预测器中典型的黑箱因素,并利用Gunnerus的历史数据验证了该方法。结果表明,ML模型的加入显著提高了预测精度。

上述研究推动了船舶运动状态预测领域的发展。对于单独的模型驱动和数据驱动,前者模型中参数识别的实践相当敏感,需要花费大量的时间和成本来构建寻找合理的参数,对数据集的质量要求很高;而纯数据驱动模型没有科学的可解释性,且忽略了基于物理模型中的领域知识。2种方法的结合和协同,是以数据驱动的方式将物理模型所产生的轨迹补偿或映射为真实的轨迹,同时保持了物理模型的稳定性,但这种策略对物理模型和数据集的要求较高,难以同时满足两者的要求。为了解决该问题,本文在物理模型和神经网络模型相结合的基础上,通过约束物理模型中的参数,同时融合Transformer和LSTM,加强了两者的可解释性和可维护性,从而有效增强数据的特征性并提高模型的准确性。

1 船舶运动状态预测方法

1.1 船舶数学模型

考虑到船舶大多处于欠驱动状态,且螺旋桨和方向舵有限,本文只考虑水平面3自由度运动,即横荡、纵荡以及艏摇,并建立船舶3自由度运动响应状态的数学仿真模型。

惯性坐标系建立见图1(a), 坐标系的原点 E 为海平面上某点, α 轴和 β 轴均与地面平行, α 轴正向指向北, β 轴正向指向东, γ 轴与平面 $\alpha E \beta$ 垂直且正向为地心方向。船体坐标系见图1(b), 坐标系原点 O 为船舶的重心位置, x 轴正向为船首方向, y 轴正向为船舶右舷, z 轴垂直于平面 xOy 且正向指向船底。




图1 物理坐标系

Fig. 1 Physical Coordinate System

船舶运动学控制方程可表示为

$$\dot{\boldsymbol{\eta}} = \mathbf{R}(\boldsymbol{\psi}) \cdot \mathbf{v} \quad (1)$$

$$\begin{cases} \dot{\boldsymbol{\eta}} = [x, y, \psi]^T \\ \mathbf{v} = [u, v, r]^T \end{cases} \quad (2)$$

$$\mathbf{R}(\boldsymbol{\psi}) = \begin{bmatrix} \cos(\psi) & -\sin(\psi) & 0 \\ \sin(\psi) & \cos(\psi) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3)$$

式(1)~式(3)中: $\dot{\boldsymbol{\eta}}$ 为船舶在惯性坐标系中的位置矢量; $\mathbf{R}(\boldsymbol{\psi})$ 为惯性坐标系与船体坐标系的坐标转换矩阵; $\mathbf{v}$ 为船舶在船体坐标系中的速度矢量; u 、 v 、 r 分别为纵荡速度、横荡速度和艏摇速度; ψ 为艏向角。

船舶动力学控制方程^[15]可表示为

$$\mathbf{M}_{RB} \dot{\mathbf{v}} + \mathbf{M}_A \dot{\mathbf{v}} + \mathbf{C}_{RB}(\mathbf{v}) \mathbf{v} + \mathbf{C}_A(\mathbf{v}_r) \mathbf{v}_r + \mathbf{D}(\mathbf{v}_r) \mathbf{v}_r = \boldsymbol{\tau}_{wind} + \boldsymbol{\tau}_{wave} + \boldsymbol{\tau}_{current} + \boldsymbol{\tau}_{thr} \quad (4)$$

$$\mathbf{M}_{RB} = \begin{bmatrix} m & 0 & 0 \\ 0 & m & m \\ 0 & mx_g & I_z \end{bmatrix} \quad (5)$$

$$\mathbf{M}_A = \begin{bmatrix} -X_{\dot{u}} & 0 & 0 \\ 0 & -Y_{\dot{v}} & -Y_{\dot{r}} \\ 0 & -N_{\dot{v}} & -N_{\dot{r}} \end{bmatrix} \quad (6)$$

$$\mathbf{C}_{RB}(\mathbf{v}) = \begin{bmatrix} 0 & 0 & -m(x_g r + v) \\ 0 & 0 & mu \\ m(x_g r + v) & -mu & 0 \end{bmatrix} \quad (7)$$

$$\mathbf{C}_A(\mathbf{v}) = \begin{bmatrix} 0 & 0 & Y_{\dot{v}} u_r + 0.5(N_{\dot{v}} + Y_{\dot{r}})r \\ 0 & 0 & -X_{\dot{u}} u_r \\ -Y_{\dot{v}} u_r - 0.5(N_{\dot{v}} + Y_{\dot{r}})r & X_{\dot{u}} u_r & 0 \end{bmatrix} \quad (8)$$

$$\mathbf{D}(\mathbf{v}) = \begin{bmatrix} -X_u - X_{|u|u} |u_r| - X_{uuu} u_r^2 & 0 & 0 \\ 0 & -Y_v - Y_{|v|v} |v_r| - Y_{|r|v} |r| & -Y_r - Y_{|r|r} |v_r| - Y_{|r|r} |r| \\ 0 & -N_v - N_{|v|v} |v_r| - N_{|r|v} |r| & -N_r - N_{|r|r} |v_r| - N_{|r|r} |r| \end{bmatrix} \quad (9)$$

式(4)~式(9)中: $\mathbf{M}_{RB}$ 为刚体质量矩阵; $\mathbf{M}_A$ 为附加质量矩阵; $\mathbf{C}_{RB}(\mathbf{v})$ 为刚体Coriolis-Centripetal矩阵; $\mathbf{C}_A(\mathbf{v})$ 为附加质量Coriolis-Centripetal矩阵; $\mathbf{D}(\mathbf{v}_r)$ 为阻尼矩阵; $\mathbf{v}_r$ 为相对速度矢量, $\mathbf{v}_r = \mathbf{v} - \mathbf{v}_c$; $\mathbf{v}_c$ 为当前速度矢量; $\boldsymbol{\tau}_{wind}$ 为风力向量; $\boldsymbol{\tau}_{wave}$ 为波浪力向量; $\boldsymbol{\tau}_{thr}$ 为推进器力矢量; m 为船体质量; I_z 为偏航旋转的转动惯量; $X_{(\cdot)}$ 、 $Y_{(\cdot)}$ 和 $N_{(\cdot)}$ 为流体动力导数。

推进器力矢量 $\boldsymbol{\tau}_{thr}$ 通过推进器指令和船速计算得到, 计算式为

$$\boldsymbol{\tau}_{thr} = f_{thr}(\mathbf{v}, n_p, \delta_p, n_s, \delta_s) \quad (10)$$

式中: n_p 和 n_s 分别为左右舷方位推进器的推进器转数;

δ_p 和 δ_s 分别为左右侧推进器的推力角度; f_{thr} 为推力器函数。

1.2 环境干扰模型

风浪流对船舶的运动状态产生干扰, 导致位置、加速度和航向等信息发生改变, 需要构建对应的环境模型以获得准确的船舶运动状态信息。

1) 风模型

风载荷 $\boldsymbol{\tau}_{wind}$ ^[16]的计算式为

$$\boldsymbol{\tau}_{wind} = \frac{1}{2} \rho_a V_{rw}^2 = \begin{bmatrix} C_x \gamma_{rw} A_{Fw} \\ C_y \gamma_{rw} A_{Lw} \\ C_n \gamma_{rw} A_{Lw} L_{oa} \end{bmatrix} \quad (11)$$

$$\begin{cases} V_{rw} = \sqrt{u_{rw}^2 + v_{rw}^2} \\ \gamma_{rw} = -\arctan 2(u_{rw}, v_{rw}) \\ u_{rw} = u - V_w \cos(\beta_w - \psi) \\ v_{rw} = v - V_w \sin(\beta_w - \psi) \end{cases} \quad (12)$$

式(11)和式(12)中: ρ_a 为空气密度; C_x 、 C_y 、 C_n 为水平运动风系数; L_{oa} 为船长; A_{Fw} 和 A_{Lw} 分别为正面和侧面投影区; V_{rw} 为相对风速; γ_{rw} 为相对船首的迎风角; V_w 为风速; β_w 为风向。

2) 波浪模型

波浪载荷 $\tau_{wave}^{[17]}$ 的计算式为

$$\tau_{wave} = \frac{1}{2} \rho g L \xi_w^2 \begin{bmatrix} C_1 \cos \chi \\ C_2 \sin \chi \\ C_3 \cos \chi \end{bmatrix} \quad (13)$$

$$\begin{cases} C_1 = 0.05 - 0.20 \left(\frac{\lambda}{L} \right) + 0.75 \left(\frac{\lambda}{L} \right)^2 - 0.51 \left(\frac{\lambda}{L} \right)^3 \\ C_2 = 0.46 - 6.83 \left(\frac{\lambda}{L} \right) - 15.65 \left(\frac{\lambda}{L} \right)^2 + 8.84 \left(\frac{\lambda}{L} \right)^3 \\ C_3 = -0.11 + 0.68 \left(\frac{\lambda}{L} \right) - 0.79 \left(\frac{\lambda}{L} \right)^2 + 0.21 \left(\frac{\lambda}{L} \right)^3 \end{cases} \quad (14)$$

式(13)和式(14)中: ρ 为海水密度; λ 为波长; χ 为波浪的遭遇角; L 为船舶纵向长度; ξ_w 为平均波浪幅值; C_1 、 C_2 和 C_3 分别为3自由度的波浪载荷系数。

3) 流载荷模型

流载荷的计算方式有2种: 1) 通过模型试验、计算流体力学(Computational Fluid Dynamics, CFD)的方法或者经验公式得到^[18-20]; 2) 通过运动方程的相对流速, 以阻尼的方式表达流的作用。本文采用第2种方式来考虑流载荷的影响, 通过相对流速表征海流与船舶运动状态之间的关系。

通过风、浪、流干扰模型、推进器推力以及船体数学模型, 计算了船体上的总力和力矩, 并得出加速度矢量。

1.3 长短期记忆网络

传统的循环神经网络(Recurrent Neural Network, RNN)网络存在梯度消失以及爆炸的问题。作为RNN的变式, 长短期记忆网络(Long-Short Term Memory, LSTM)能够有效解决该问题。长短期记忆网络结构见图2, 每个门结构由黄色矩阵表示的线性层和蓝色圆圈代表的逐点乘法运算组成, 该网络通过3个门结构将信息删除或添加到“细胞状态”中, “细胞状态”由橙线传递。

1) 通过遗忘门读取当前输入 x_t 和前神经元信息 h_{t-1} , 丢弃函数 f_t 决定丢弃的信息, 计算式见式(15)。输出1表示“完全保留”, 0表示“完全丢弃”。

$$f_t = \sigma[W_i(h_{t-1}, x_t) + b_i] \quad (15)$$

式中: σ 为激活函数; b_i 为单元值; W_i 为遗忘门限的递归连接权重。

2) 该单元由2层组成, Sigmoid层充当“输入门层”, 确定将更新的值 i_t ; tanh层创建一个新的候选值 $\tilde{C}_t$ 替换需要忘记的旧信息, 计算式为

$$\begin{cases} i_t = \sigma[W_i(h_{t-1}, x_t) + b_i] \\ \tilde{C}_t = \tanh[W_c(h_{t-1}, x_t) + b_c] \end{cases} \quad (16)$$

式中: W_c 为输入门限的递归连接权重; b_i 和 b_c 分别为遗忘门单元值和输入门单元值。

3) 将 C_{t-1} 更新为 C_t , 并将旧状态乘 f_t , 丢弃不需要的信息, 最后根据决定更新每个状态来添加新的候选值 $\tilde{C}_t$, 计算式为

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (17)$$

式中: C_t 为当前神经元状态记忆; C_{t-1} 为前神经元状态记忆。

4) 先运行一个Sigmoid层确定输出的细胞状态, 再通过tanh处理单元状态, 并将其与Sigmoid门的输出相乘得到需要的部分, 计算式为

$$\begin{cases} o_t = \sigma[W_o(h_{t-1}, x_t) + b_o] \\ h_t = o_t \tanh C_t \end{cases} \quad (18)$$

式中: o_t 为控制当前时刻 C_t 中的信息是否流入当前隐藏状态; h_t 为当前神经元信息; b_o 为输出单元值; W_o 为输出门限的递归连接权重。




图2 长短期记忆网络结构

Fig. 2 Structure of Long Short-Term Memory Network

1.4 Transformer 模型

Transformer利用编码器、解码器和自注意力机制来处理模型结构中输入输出之间的复杂关系, 由Google团队在2017年提出, 其将循环神经网络中顺序结构变换为并行化结构, 同时不丢失全局信息, 对时间序列处理领域有很好的效果。该模型结构的编码器和解码器由多层堆叠而成的, 每层由多头注意力机制层(Multi-Head Attention)和全连接前馈神经网络层(Feed Forward Network)组成, 其结构示意图见图3, 主要由位置编码、多头注意力机制、掩码多头注意力机制、全连接前馈网络、残差及标准化组成。




图3 Transformer 结构

Fig. 3 Structure of Transformer

1.4.1 位置编码

输入的每个变量都是单独计算相似度, 在计算时不会改变变量的顺序, 这导致Transformer具有位置不变性, 而位置编码的引入能够有效解决这个问题。在偶数位置用正弦函数进行编码, 在奇数位置用余弦函数进行编码, 计算式为

$$P_{p_{os}, 2i} = \sin\left(\frac{p_{os}}{10000^{\frac{2i}{d}}}\right) \quad (19)$$

$$P_{p_{os}, 2i+1} = \cos\left(\frac{p_{os}}{10000^{\frac{2i}{d}}}\right) \quad (20)$$

式(13)和式(14)中: $P_{p_{os}, 2i}$ 为偶数位置编码; $P_{p_{os}, 2i+1}$ 为奇数位置编码; p_{os} 为当前值在序列中的位置; i 为向量中每个值的索引; d 为变量的维度。

1.4.2 多头注意力机制及掩码多头注意力机制

多头注意力机制由多个自注意力组合而成, 而自注意力机制是对传统注意力机制的改进, 能够减少对外部信息的依赖, 更擅长捕捉数据的内在关系, 其结构示意图4。自下而上第1层为输入层, 中间为注意力全连接层, 最后为输出层。自注意力机制是利用数据特征内部固有的信息进行注意力交互, 核心是通过查询键 Q 和推导键 K 计算得到注意力权重, 然后再作用于输出值 V 得到整个权重和输出, 具体计算过程为

$$\begin{cases} Q_i = W_Q a_i \\ K_i = W_K a_i \\ V_i = W_V a_i \end{cases} \quad (21)$$

式中: Q_i 为各查询键; K_i 为各推导键; V_i 为各输出值; W_Q 、 W_K 和 W_V 分别为 Q 、 K 和 V 对应的权重; a_i 为各特征。




图4 自注意力机制结构

Fig. 4 Structure of Self-Attention Mechanism

得到各查询键 Q_i 、推导键 K_i 和输出值 V_i 之后, 计算各特征 a_i 关于其余特征的相关性 $a_{1,i}$, 再根据式(22)计算得到对应的输出 y_{output} 。

$$\begin{cases} a_{1,i} = Q_i K_i \\ y_{\text{output}} = \sum a_{1,i} V_i \end{cases} \quad (22)$$

最后根据式(21)和式(22)得到自注意力公式。

$$S_{\text{elfAtten}}(Q, K, V) = S_{\text{softmax}}\left(\frac{QK}{d_k}V\right) \quad (23)$$

式中: d_k 为 K 的维度; S_{elfAtten} 为自注意力函数; S_{softmax} 为将查询与键的相似度得分转换为注意力权重的函数。

Transformer模型中的多头注意力机制由多个注意力头组成, 并行地对输入进行注意力计算。每个头学习不同的查询、键和值的映射, 从而可以学习到不同的语义信息。掩码多头注意力子层是在进行自注意力计算时, 为了避免信息泄露, 需要将未来位置的信息通过掩码处理屏蔽掉, 一般通过设置负无穷将注意力值变成极小的数以达到效果。

1.4.3 全连接前馈网络

该网络被用于对每个位置的隐藏层表示进行非线性的转换, 将多头注意力层的输出映射到另一维度空间, 从而提升模型的表达能力和预测准确率。 F_{NN} 通常由2个全连接层组成, 第1个全连接层使用激活函数来增强模型的非线性表达能力, 第2个全连接层一般不使用激活函数, 计算式为

$$F_{\text{NN}}(x) = \max(0, xW_1 + B_1)W_2 + B_2 \quad (24)$$

式中: x 为输入变量; W_1 和 W_2 为权重矩阵; b_1 和 b_2 为偏置向量。

1.4.4 残差及标准化

残差和标准化对整个算法的性能提升非常重要。在Transformer模型中, 每一个子层之后都会接一个残差模块, 里面包含残差连接和标准化。在基于随机梯度下降的网络训练过程中, 误差信号的多层反向传播极易引发“梯度爆炸”和“梯度弥散”, 残差网络的引入可以弥补因反向传播引起的梯度问题, 具体公式为

$$y = F(x, w) + x \quad (25)$$

式中: $F(x, w)$ 为残差函数。

在实际的数据处理过程中, 会出现数据分布不均匀且数据量大小不统一的情况。为了消除量纲, 使数据的分布变得更加集中, 采用层标准化 (Layer Normalization, LN) 在每一个样本上计算均值和方差以加速训练过程, 增强模型的泛化能力, 提高模型的性能。 σ_X 和 μ_X 分别是 X 的每个元素沿最后一维的均值和标准差, 处理过程为

$$L_{\text{ayerNorm}}(X) = \alpha \odot \frac{X - \mu}{\sigma} + \beta \quad (26)$$

$$\mu_X = \frac{1}{n} \sum_{i=1}^n x_i \quad (27)$$

$$\sigma_X = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu_X)^2 + \varepsilon} \quad (28)$$

式 (26) ~ 式 (28) 中: α 和 β 为可学习的参数向量, 维度与 X 的最后一维相同; $\odot$ 为按元素相乘符号; ε 为一个小常数, 为了数值稳定性而添加。

1.5 输入特征及输出变量

船舶物理模型的输入特征决定了船舶运动状态的准确性, 应谨慎选择输入, 以避免因缺少重要信息而遭受损失, 从而确保后续预测模块中进行有效训练。基于船舶动力学理论选择输入特征, 该理论认为未来轨迹由船舶的惯性、水动力参数、船舶的初始状态、推进器提供的力以及环境干扰决定。通过改变船体参数、环境参数以及推进力等参数获取船舶的运动状态数据。

根据物理模型输出的不同船舶运动状态参数建立数据集, 具体有位置坐标、航向、航速和加速度等自身状态参数以及风浪流等环境参数。设定主次变量, 以自身状态参数为主要变量, 以环境参数为次要变量, 建立船舶运动状态数据集, 并按 4:1 的比例将时间序列数据划分为训练集与测试集, 其中采样间隔为 5 ms。在数据集构建过程中, 模型训练采用离线方式进行; 模型预测则采用连续预测的形式, 即模型以步长 20 逐步预测下一步数据, 确保时间序列的连续性和准确性。

2 协同模型建立

2.1 模型构建

本文构建的协同模型能够对船舶的运动状态 (具体包括位置、加速度和对地航向等) 进行预测, 以保障船舶航行安全, 其建模流程见图 5。船舶运动状态预测的本质是神经网络的回归问题, 通过物理模型和实测数据构建运动状态数据集。基于物理模型生成模拟数据集, 具体将船舶模型和风浪流模型相结合进行物理参数的定义与调整, 并结合船舶尺

寸及环境特征, 获得多种环境下不同类型船舶的运动数据; 实测数据则来源于某船实际航行过程中通过监测设备获取的真实数据。将船舶的位置、加速度和对地航向 3 种运动状态的历史数据以及当前特征作为目标预测序列的网络输入, 将风、浪、流和推进力的历史数据和当前特征作为辅助预测序列的网络输入, 将未来某时刻的 3 种船舶运动状态数据作为网络输出, 完成数据预处理并划分测试集和训练集。在训练过程中对比预测模型与历史数据集中的真实值, 并不断纠正中间值的误差以达到最优效果。根据获取的信息数据建立多种情况下船舶历史运动状态与未来运动状态之间的特征数据关系, 实现对船舶运动状态的预测。




图 5 建模流程

Fig. 5 Flowchart of Modeling

2.2 参数设置与优化

协同模型的网络结构见图 6。具体工作流程是在输入层对输入的监测数据进行分类, 然后在输入序列加上位置编码, 为模型提供序列顺序信息; 位置编码完成后, 通过多层编码器层学习输入序列的特征表示, 通过多头自注意力模块提取输入序列的相关性特征; 在前馈全连接网络对特征进行非线性转换, 堆叠多个编码器层让模型学习层级表示, 输出编码器特征; 然后通过解码器, 基于编码器的输出, 解码预测目标序列; 使用掩码多头注意力机制防止信息泄露, 利用 LSTM 模块学习序列历史的连续性, 再经过一个前馈层生成最终预测结果。




图 6 协同模型的网络结构

Fig. 6 Network Structure of the Collaborative Model

Transformer负责学习输入表示,LSTM负责序列预测,二者通过Attention机制相结合,发挥各自的优势,实现更好的序列建模。其中,多头自注意力机制学习输入序列的全局依赖特征;编码器输出特征表示并进行高级抽象表示;LSTM模型学习时间序列数据的连续性,存储历史信息并为当前时间步的预测提供上下文信息;Attention模块连接编码器和解码器,允许解码器关注输入序列的相关部分,基于内容地址提取相关特征,指导解码器生成输出。模型参数设置见表1,设置每层的LSTM网络神经元数目为10,激活函数选择Relu;Dense神经元个数为8,Dropout值为0.2。

表 1 模型参数设置

Tab. 1 Parameter Settings of the Model

参数	数值
LSTM 层数	3
Transformer 层数	6
批次大小	200
学习率	0.01
Warm up 轮数	200
总训练轮数	2 000

2.3 输入特征及输出变量

船舶物理模型的输入特征决定了船舶运动状态的准确性,对输入必须仔细选择,避免因缺少重要信息而遭受损失,从而导致在后续预测模块中出现无效训练。基于船舶动力学理论选择输入特征,该理论认为未来轨迹由船舶的惯性、水动力参数、船舶的初始状态、推进器提供的力以及环境干扰决定的。通过改变船体参数、环境参数以及推进力等参数获取船舶的运动状态数据。

根据物理模型输出的不同船舶运动状态参数建立数据集,具体有位置坐标、航向、航速和加速度

等自身状态参数以及风浪流等环境参数。设定主状态变量,以自身状态参数为主要变量,以环境参数为次要变量,建立船舶运动状态数据集。

2.4 评价指标

通过决定系数和平均绝对百分比误差分析模型性能,其中决定系数也称为拟合优度,表示自变量引起的变动占总变动的比例,取值为0~1。拟合优度越大,自变量对因变量的解释程度越高,若决定系数超过0.8,平均绝对百分比误差低于5%,则表示模型较好。此外,使用最大相对误差、最小相对误差、平均绝对百分比误差和相对误差标准差4个指标来评估算法。具体来说,使用预测值与实际值之间的差值来获得最大值和平均值,然后进行误差分析。计算式见式(29)~式(33)。

1) 绝对系数 R^2

$$R^2 = 1 - \frac{\sum (p_i - r_i)^2}{\sum (p_i - a)^2} \quad (29)$$

2) 平均绝对百分比误差 X_{MAPE}

$$X_{MAPE} = \frac{1}{m} \sum_{i=1}^m \left(\frac{|p_i - r_i|}{r_i} \right) \times 100\% \quad (30)$$

3) 均方根误差 X_{RMSE}

$$X_{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (p_i - r_i)^2} \quad (31)$$

4) 相对误差 δ

$$\delta = \frac{p_i - r_i}{r_i} \times 100\% \quad (32)$$

5) 相对误差标准差 σ_e

$$\sigma_e = \sqrt{\frac{1}{m} \sum_{i=1}^m (r_i - a)^2} \quad (33)$$

式(29)~式(33)中: i 为数据集中序列个数; r_i 为实际值; p_i 为预测值; a 为实际数据的平均值; m 为预测的各参数序列长度。

3 验证与分析

3.1 数据预处理

3.1.1 归一化与集成化

对获得的数据集进行数据集成,将所有数据源中的数据结合,存放在一个一致的数据仓库中,即把加速度、对地航向和位置数据读取存储在一个数据库中,检测冗余。在统一合并时,保持规范化、去重,对集成之后的数据集进行归约表示,保持原数据的完整性,便于后续预测任务,避免预测过程出现误差和中断等情况。

完成数据集成后进行归一化处理,避免因学习能力低导致预测结果与实际值之间出现较大误差,将数据归一化到0~1。经过归一化处理的数据可以加快训练网络的收敛性,提高训练精度,消除不同数据之间的影响,处理后的数据仍会保留原来数据中存在的关系。预测完成后需要将真实值与模型预测值进行反归一化,使其具有实际意义并方便后续比较。本文采用的归一化转换方式为

$$x^* = \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}} \quad (34)$$

式中: $x_{\max}$ 为样本数据最大值; $x_{\min}$ 为样本数据最小值; x_0 为原始训练数据; x^* 为归一化数据。

3.1.2 多变量权重设置

采用随机森林法对多变量参数进行权重设置,利用Gini指数进行特征的重要性评分,以衡量某个

特征被用来划分数据集时能够提供的“纯度”提升程度。“纯度”指样本集中属于同一类别样本的比例,得分越高说明该特征在树的分支判断规则中具有更好的区分能力。首先在决策树节点处计算拆分前后的GINI指数,节点的GINI指数减少量为特征的重要性得分贡献值;然后对每个决策树指定特征的重要性评分进行累加求和;最后将所有决策树的得分再取平均,即为最终的特征重要性得分。

假设有 m 个特性,且随机森林中的数目为 n ,则系数计算公式以及特征 X_j 的特征重要性评分计算公式为

$$\begin{cases} G_q = \sum_{k=1}^{|K|} \sum_{k' \neq k} P_{qk} P_{qk'} = 1 - \sum_{k=1}^{|K|} P_{qk}^2 \\ V_j = \sum_{i=1}^n \sum_{q \in M} V_{jq} = G_q - G_l - G_r \end{cases} \quad (35)$$

式中: k 为类别个数; P_{qk} 为节点 q 中类别 k 所占的比例; M 为特性 X_j 在决策树 i 中出现的节点集合; G_q 为分枝前节点的Gini系数; G_l 和 G_r 分别为分枝前后2个节点的Gini数; V_j 和 V_{jq} 为特征重要性评分。

目标序列是指船舶位置、加速度以及航向,数据集中其余变量(航速、风浪流和推进力等)作为辅助变量。由于特性重要性得分具有一定随机性,需要多次训练取平均值以获得准确和稳定的特征排序,最终结果见表2。

表2 辅助变量权重

Tab. 2 Weight of Auxiliary Variables

轮次	航速	推进力	风	浪	流
1	0.328 4	0.158 7	0.273 6	0.121 7	0.117 6
2	0.337 1	0.187 6	0.258 5	0.131 7	0.085 1
3	0.290 7	0.213 4	0.249 2	0.146 5	0.100 2
4	0.305 3	0.220 7	0.257 9	0.123 0	0.093 1
5	0.351 5	0.154 7	0.290 9	0.123 6	0.079 3
6	0.267 9	0.160 8	0.115 0	0.320 5	0.135 8
7	0.320 1	0.137 9	0.273 3	0.159 9	0.108 8
8	0.256 1	0.174 7	0.137 2	0.278 8	0.153 2
9	0.305 3	0.220 7	0.257 9	0.123 0	0.093 1
10	0.285 9	0.205 1	0.231 3	0.153 8	0.123 9
平均	0.310 2	0.196 6	0.244 4	0.152 3	0.096 5

3.2 训练表现

加速度数据集、轨迹及航向数据集分别见图7和图8。其中,图7(a)和图7(c)分别为沿 x 方向和 y 方向

的加速度数据,图7(e)为沿 z 方向的艏摇加速度数据,图8为 x - y 轴的模拟轨迹数据以及对地航向数据,使用的数据集均已进行了异常的识别与修复。




图 7 加速度数据集

Fig. 7 Acceleration Dataset




图 8 轨迹及航向数据集

Fig. 8 Trajectory and Heading Datasets

本文试验的硬件环境为RTX3050 (GPU), 试验平台为TensorFlow2.4版本的上层框架Keras, 语言为python。通过数据集训练1 000轮来获得训练阶段的损失值, 见图9, 损失值表示预测值与真实值的差异程度, 损失值在0~400个训练周期内快速收敛, 在401~1 000个训练周期内缓慢收敛, 最后在损失值为0.001 306时停止训练, 将训练好的模型作为预测任务的网络模型。




图9 损失值曲线

Fig. 9 Curve of Loss Value

3.3 预测结果分析


采用训练好的模型对加速度、对地航行、位置信息进行预测分析。加速度预测结果见图10。对地航向预测结果见图11。时程曲线预测结果见图12。位移轨迹预测结果见图13。

由图10可知, 在 x 、 y 、 z 等3个方向上, 加速度的预测值与样本真实值的总体振幅和极值点相对吻合, 从局部放大图中可看出没有出现明显的大幅度偏差。


由图11可知, 不同预测时间段内, 对地航向的预测值与样本真实值的极值点吻合度都较高, 过程中没有出现明显偏差。

由图12可知, x 和 y 等2个方向位移的预测值与样本真实值没有出现不规律振荡, 随着时间误差范围可以接受。


由图13可知, 预测曲线与真实值曲线之间的差值较小, 随时间误差没有出现明显变大的趋势。




(a) x 方向



(b) x 方向局部放大




(c) y 方向




(d) y 方向局部放大

图10 加速度预测结果

Fig. 10 Prediction Results of Acceleration




(e) z 方向




(f) z 方向局部放大

图 10 加速度预测结果 (续)

Fig. 10 Prediction Results of Acceleration (Continued)




(a) 直航




(b) 回转

图 11 对地航向预测结果

Fig. 11 Prediction of Ground Heading



(a) x 方向位移



(b) y 方向位移

图 12 时程曲线预测结果

Fig. 12 Prediction Results of the Time-History Curve




图 13 位移轨迹预测结果

Fig.13 Prediction Results of Displacement Trajectory

图14为通过协同模型对加速度、对地航向以及位置三类数据预测之后的RMSE和 σ 结果柱状图。由图14可知,加速度的RMSE和 σ 在 x 方向最高,且分别低于 0.02 m/s^2 和 0.14 m/s^2 ;对地航向的RMSE和 σ 分别在 0.2° 和 0.8° 上下浮动;位置坐标的RMSE和 σ 都低于 8 m ,3类数据均未出现明显的误差。

协同模型预测效果见表3。由表3可知,加速度、对地航向和位置信息的平均MAPE保持在5%以内,相对误差均未超过5%,且未出现大幅度的数据波动, R^2 分数均超过0.8,模型性能稳定。




图 14 协同模型下多数据 RMSE 结果

Fig. 14 Multi-Data RMSE Results of the Collaborative Model

表 3 协同模型预测效果

Tab. 3 Prediction Effect of Collaborative Model

变量		MAPE/%	$\delta/^\circ$	R^2
加速度/(m/s^2)	x	5.70	1.86	0.986 3
	y	5.89	1.08	0.978 0
	z	3.31	1.12	0.991 7
	平均	4.97	1.35	0.985 3
对地航向/($^\circ$)	直航	0.24	1.32	0.903 1
	回转	0.13	2.35	0.967 4
	平均	0.19	1.84	0.935 3
位置/m	x	1.72	4.84	0.883 1
	y	1.37	4.96	0.812 3
	$x-y$	0.75	2.29	0.851 6
	平均	1.28	4.03	0.879 1

3.4 不同模型对比

LSTM模型和物理模型加速度预测结果见图15。图15中,图15(a)~图15(f)为LSTM模型结果,图

15(g)~图15(l)为物理模型结果。由图15可知,LSTM模型和物理模型对部分极值点的预测效果较差,某些点出现完全相反的结果。




图 15 LSTM 模型和物理模型加速度预测结果

Fig. 15 Acceleration Prediction Results of LSTM and Physical Models





(i) y 方向 (物理模型)(j) y 方向局部放大 (物理模型)(k) z 方向 (物理模型)(l) z 方向局部放大 (物理模型)

图 15 LSTM 模型和物理模型加速度预测结果 (续)


Fig. 15 Acceleration Prediction Results of LSTM and Physical Models (Continued)

LSTM模型和物理模型对地航向预测结果见图16。由图16可知，LSTM模型预测结果振幅较小，极值与原数据匹配性差；该物理模型容易出现滞后和平移的现象，且规律性不强，最终结果趋于直线。


LSTM模型和物理模型位移预测结果见图17。由

图17可知，2种模型在预测后期均会出现预测值与真实轨迹差值较大的偏差情况，且后期变换趋势会不断增大。

不同模型轨迹预测结果对比见图18。由图18可知，协同模型的轨迹预测结果均与真实轨迹最吻合。



(a) 直航 (LSTM)



(b) 直航 (物理模型)

图 16 LSTM 模型和物理模型对地航向预测结果

Fig. 16 Ground Heading Prediction Results of LSTM and Physical Models




图 16 LSTM 模型和物理模型对地航向预测结果 (续)

Fig. 16 Ground Heading Prediction Results of LSTM and Physical Models (Continued)




图 17 LSTM 模型和物理模型位移预测结果

Fig. 17 Direction Prediction Results of LSTM and Physical Models




图 18 不同模型轨迹预测结果对比

Fig. 18 Comparison of Trajectory Prediction Results Among Different Models

不同类型数据集误差比较见图19。由图19可知，LSTM模型在预测前期就存在较大的误差，且存在不规矩的波动起伏情况；物理模型在修复时间段内存在误差较小的情况，也会出现较大误差的情景，波动较大不稳定；相对上述2种模型，协同模型误差

较小且较为稳定，不会出现较大偏差。

3种模型在不同类型数据集上的箱线图比较结果见图20。由图20可知，协同模型的中位数、平均值、极值在3类数据类型中均为最优，且稳定性高。




图 19 不同类型数据集误差比较

Fig. 19 Error Comparison of Different Types of Datasets




图 20 误差箱线图比较

Fig. 20 Comparison of Error Boxplots

为了验证模型方法的可行性，进一步针对同种类型不同情况下数据集的预测结果进行分析对比。同种类型不同情况预测结果误差对比结果见图21。

由图21可知，协同组合模型在同一位置的预测效果最好，且误差最低，在不同位置的预测效果也是三者中最优。




图 21 同种类型不同情况预测结果误差对比

Fig. 21 Comparison of Prediction Errors of the Same Type and Different Situations

不同模型预测效果对比结果见表4。由表4可知，LSTM模型的决定系数和平均绝对百分比误差都未达到稳定模型的标准，物理模型虽然达到了稳定性的要求，但协同模型更优，且平均相对误差最低。

表 4 不同模型预测效果对比

Tab. 4 Comparison of Different Models on

Prediction Effects				
参数		MAPE/%	δ /%	R^2
协同模型	加速度	4.97	1.35	0.985 3
	位置	1.28	4.03	0.879 1
	对地航向	0.19	1.84	0.935 3
LSTM	加速度	6.05	2.96	0.871 7
	位置	5.10	5.36	0.605 3
	对地航向	3.65	1.64	0.638 2
物理模型	加速度	6.70	1.61	0.468 1
	位置	5.42	5.36	0.605 3
	对地航向	5.51	2.86	0.511 3

3.5 实船数据验证

将某实船的加速度、对地航行以及位置数据信息输入到协同模型进行训练，相同时间内的预测结果见图22。由图22中可知，该方法得出的预测值与真实值较为吻合，误差较小。实船数据误差指标见表5。由表5可知，MAPE和相对误差均低于3%，且模型得分都高于0.85。




图 22 实船数据预测结果

Fig. 22 Prediction Results of Real Ship Data

表 5 实船数据误差指标

Tab. 5 Error Index of Real Ship Data

参数	MAPE/%	δ /%	R^2
加速度	1.713 4	0.764 1	0.976 1
位置	0.061 1	0.569 4	0.885 1
对地航向	0.096 3	0.097 2	0.982 3

4 结论

本文将数据集通过融合Transformer的LSTM模型开展离线学习,提出了一种基于船舶数学模型融合神经网络的协同模型,预测船舶的加速度、对地航向以及位置等运动信息,得出以下结论:

1) 相较于单独的LSTM模型和物理模型,协同模型能够解决梯度消失、预测滞后和部分预测点不稳定的问题,且决定系数最高,平均百分比误差最低,保持在5%以内。

2) 协同模型在多数环境下能够有效预测不同情况下的多种运动数据,模型性能较好,鲁棒性较强。

3) 本文采用随机森林法对输入的辅助数据参数进行权重设置与优化,避免人为设置的不确定性和低效。结果表明,该方法能够准确快速获取权重大小,提高预测效率。

未来可采用强化学习进行模型整合优化提升预测精度,同时考虑更多的环境和工况因素,利用现有的成果对数据进行训练学习和科学约束,建立更加完善的网络架构。

参考文献:

- [1] LANG X, WU D, MAO W G. Physics-Informed Machine Learning Models for Ship Speed Prediction[J]. Expert Systems with Applications, 2024, 238: 121877.
- [2] WANG Y F, PERERA L P, BATALDEN B M. Kinematic Motion Models Based Vessel State Estimation to Support Advanced Ship Predictors[J]. Ocean Engineering, 2023, 286: 115503.
- [3] GAO D W, ZHU Y S, ZHANG J F, et al. A Novel MP-LSTM Method for Ship Trajectory Prediction Based on AIS Data[J]. Ocean Engineering, 2021, 228: 108956.
- [4] PAPADIMITRAKIS M, STOGIANNOS M, SARIMVEIS H, et al. Multi-Ship Control and Collision Avoidance Using MPC and RBF-Based Trajectory Predictions[J]. Sensors, 2021, 21(21): 6959.
- [5] RONG H, TEIXEIRA A P, GUEDES SOARES C. Ship Trajectory Uncertainty Prediction Based on a Gaussian Process Model[J]. Ocean Engineering, 2019, 182: 499-511.
- [6] LIU R W, LIANG M H, NIE J T, et al. Intelligent Data-Driven Vessel Trajectory Prediction in Marine Transportation Cyber-Physical System[C]// 2021 IEEE International Conferences on Internet of Things (iThings). 2021.
- [7] LEE J H, LEE J, KIM Y, et al. Prediction of Wave-Induced Ship Motions Based on Integrated Neural Network System and Spatiotemporal Wave-Field Data[J]. Physics of Fluids, 2015, 35(9): 165-178.
- [8] TANG H, YIN Y, SHEN H. A Model for Vessel Trajectory Prediction Based on Long Short-Term Memory Neural Network[J]. Journal of Marine Engineering & Technology, 2022, 21(3): 136-145.
- [9] MURRAY B, PERERA L P. Ship Behavior Prediction via Trajectory Extraction-Based Clustering for Maritime Situation Awareness[J]. Journal of Ocean Engineering and Science, 2022, 7(1): 1-13.
- [10] KAWAN B, WANG H, LI G Y, et al. Data-Driven Modeling of Ship Motion Prediction Based on Support Vector Regression[J]. Engineering, Computer Science, 2017, 22: 153-168.
- [11] KANAZAWA M, WANG T T, SKULSTAD R, et al. Knowledge and Data in Cooperative Modeling: Case Studies on Ship Trajectory Prediction[J]. Ocean Engineering, 2022, 266: 112998.
- [12] SKULSTAD R, LI G Y, FOSSEN T I, et al. A Hybrid Approach to Motion Prediction for Ship Docking-Integration of a Neural Network Model into the Ship Dynamic Model[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 2501311.
- [13] WANG T T, LI G Y, HATLEDAL L I, et al. Incorporating Approximate Dynamics into Data-Driven Calibrator: a Representative Model for Ship Maneuvering Prediction[J]. IEEE Transactions on Industrial Informatics, 2022, 18(3): 1781-1789.
- [14] SCHIRMANN M L, COLLETTE M D, GOSE J W. Data-Driven Models for Vessel Motion Prediction and the Benefits of Physics-Based Information[J]. Applied Ocean Research, 2022, 120: 102916.
- [15] 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.
- [16] YASUKAWA H, YOSHIMURA Y. Introduction of MMG Standard Method for Ship Maneuvering Predictions[J]. Journal of Marine Science and Technology, 2015, 20(1): 37-52.

(下转第 167 页)