

文章编号: 1007-7294(2024)11-1654-12

基于联邦泛化的非平稳船舶 横摇运动预测方法

张 琴, 刘敦康, 李嘉宾, 周福娜, 胡 雄
(上海海事大学 物流工程学院, 上海 201306)

摘要: 船舶易受到风浪干扰而影响海上风力发电机的安装精度和维护安全性, 其中长峰波随机波浪谱下的非平稳横摇运动影响最大。为保证海上作业在复杂海况下的稳定性, 需要提高预测模型的泛化性, 故本文提出基于联邦泛化的非平稳船舶横摇运动预测方法。首先, 利用变模态方法分解非平稳船舶横摇运动为多分量平稳序列, 进而采用注意力机制的长短期记忆神经网络建立本地多维多步预测模型, 并进行误差校正; 其次, 为了提高复杂海况下遇到新类型船舶横摇运动时的预测效果, 在不共享数据的前提下联合多家船舶横摇运动数据持有方进行择优联邦建模; 最后, 使用最大均值差异方法选择特征相似度高的数据进行加权平均联邦训练。实验结果表明, 经过联邦学习后的模型具有更高的预测精度, 以及更好的泛化能力, 有助于风电安装时的波浪补偿稳定控制。

关键词: 船舶横摇运动预测; 变分模态分解; 注意力机制; LSTM; 联邦学习

中图分类号: U661.32+1

文献标识码: A

doi: 10.3969/j.issn.1007-7294.2024.11.003

A federated generalization prediction method for non-stationary ship roll motion

ZHANG Qin, LIU Dun-kang, LI Jia-bing, ZHOU Fu-na, HU Xiong
(School of Logistics Engineering, Shanghai Maritime University, Shanghai 201306)

Abstract: Ships are susceptible to wind and waves causing the declines of installation accuracy and maintenance safety of offshore wind turbines. The most seriously affected case is the non-stationary ship roll motion under long-peaked random wave spectrum. To ensure the stability of offshore operations under complex sea conditions, it is necessary to improve the generalization of the prediction model. In this paper, a preferential feature federation method was proposed. Firstly, the non-stationary ship roll motion was decomposed into multi-component stationary sequences by using the variable modal decomposition method. Then, the long and short-term memory neural network with attention mechanism was used to build a local multi-dimensional multi-step prediction model with error correction. Finally, in order to improve the prediction effect of new type ship motions in complex sea conditions, a federation method was used to combine some ship motion data holders for best model parameters, which were selected with the maximum mean discrepancy method with high similarity for preferential feature federated training. The experimental results show that the federated model has higher prediction accuracy and better generalization ability, which can help the stability control of wave compensation during offshore wind turbines installation.

收稿日期: 2024-05-22

基金项目: 国家自然科学基金资助项目(62373213); 国家高技术研究发展计划项目(2013AA041106)

作者简介: 张 琴(1982-), 女, 博士, 讲师, 硕士生导师;

胡 雄(1962-), 男, 博士, 教授, 通讯作者, E-mail: xionghu@shmtu.edu.cn。

Key words: ship roll motion prediction; variational modal decomposition; attention mechanism; LSTM; federated learning

0 引 言

随着《中国海洋21世纪议程》等相关政策的提出,海上能源尤其是海上风电的发展正呈井喷之势。近年来,海上风电趋向于功率大型化并向深海远洋海域拓展,使得海上风电安装船变得供不应求^[1]。自升式风电安装起重船仅适用于较浅海域的风电安装工作,而具有波浪补偿装置的浮式起重船具有工作水深灵活、移动速度快、工作效率高等优点,能够很好地适用于复杂海况下的海上风电设备的安装和运维工作,其中波浪补偿平台是保证浮吊装置进行海上高精度安全作业的常用设备。随着离岸距离的不断增加和船舶作业海域的不断扩大,海上风浪变化的随机性和多样性也随之增加,船舶运动也愈加复杂,主要呈现出非平稳、非线性的运动形式。为了满足实际作业的需求,保证精确的补偿工作,实时且精准的船舶运动预测方法至关重要。

为此,由简单到复杂,由单一到组合的预测方法不断被提出,为波浪补偿设备的实际应用提供了理论前提。Enochson^[2]于1963年使用历史和实时船舶运动时间序列分析法实现了对船舶横摇运动的预测,该分析法更加适用于实际的船舶海上作业^[3]。唐刚等^[4]采用自回归移动平均模型(Autoregressive Moving Average Model, ARMA)对船舶运动姿态进行了预测,并结合AIC对ARMA参数进行了优化,缩短了船舶运动姿态预测所需时间,但适用于平稳性较高数据的预测分析^[5]。差分整合移动平均自回归模型(Autoregressive Integrated Moving Average Model, ARIMA)是将非平稳数据差分处理为平稳数据再进行预测,从而提升了模型预测效果^[6]。陈倩清等^[7]使用小波分解结合AR算法对船舶的横摇动作进行了预测,预测值能够较好地逼近实际值,能够有效地应对分解过程中产生的模态混叠现象,使得船舶运动数据分解更具体,从而能够有效提升模型的预测精度。孙珽等^[8]提出了一种基于变分模态分解(Variational Mode Decomposition, VMD)和自适应粒子群优化算法优化极限学习机预测方法,实现了对非平稳、非线性船舶运动姿态的预测,可以极好地适用于非线性系统。张泽国等^[9]提出了一种自适应变异粒子群算法与BP神经网络相结合的方法,实现了对船舶横摇运动的较高精度预测,提高了模型的收敛速度和泛化能力^[9]。Liu等^[10]采用长短期记忆神经网络(Long and Short-Term Memory, LSTM)对非线性的船舶运动数据进行预测,且达到理想的预测效果。Zhang等^[11]提出了一种基于多尺度注意力机制的LSTM,通过增加注意力机制的方式,增强了LSTM对历史数据的记忆能力,从而提高了对船舶运动的预测精度。Zhang等^[12]使用双向LSTM结合自适应动态粒子群优化算法,对船舶的运动姿态进行了高精度预测。

面对复杂海况下更加多变的非平稳、非线性船舶运动,充足的船舶运动数据是保证模型预测精度和泛化能力的重要前提。因此,获取更加全面的船舶运动数据,联合多家相关企业的数据进行模型训练是很好的方法。但随着大数据的蓬勃发展,企业间愈发重视所持数据的安全性和保密性,因此联邦学习的应用便至关重要。基于时间序列的联邦学习,其联邦训练数据常常来自不同的客户端,导致对联邦训练数据的分析和整合极为困难。为此,Liu等^[13]提出连续频率空间中的情景学习,使本地客户端能够访问多源分发而不会泄露隐私。McMahan等^[14]使用Logistic回归模型作为各客户端的初始化模型进行联邦训练,并通过神经网络来融合本地模型,但是由于神经网络模型呈现出非凸函数形式,容易陷入局部最优。针对此问题,Li等^[15]提出了联邦平均算法(FedAvg),通过将模型的权重或梯度进行平均处理来整合多方客户端本地模型,从而达到整合全局模型的目的,但FedAvg加权平均权重值参数的确定却是个难题。Zhang等^[16]提出联邦学习设置下的联邦对抗域泛化(FedADG)方案,使用自适应生成的参考分布和类对齐技术来确保其在目标域上的高性能,但提取源域中的特征分布比较困难。

综上所述,现有研究主要对线性、平稳的运动做出预测,尚未对船舶在海上作业时遇到的随机不确定性的横摇运动及其预测展开研究。因此,针对实时多变海况下的非线性、非平稳船舶横摇运动,

本文提出一种采用联邦泛化的变分模态注意力机制 LSTM 预测方法。

(1) 首先,通过 VMD 算法将非平稳船舶横摇运动数据分解为多个相对平稳的序列分量,进而作为多变量输入到注意力机制的 LSTM 模型中,以实现非平稳非线性船舶运动的高精度预测。

(2) 其次,采用联邦学习多海域模型进行预测泛化,在不共享数据的前提下,通过联合多家船舶运动持有方的择优预测模型进行训练,从而达到提高模型的实用性和泛化能力的目的。

(3) 最后,通过最大均值差异算法对各个客户端的数据特征进行相似度计算,选取合适的联邦客户端并计算在中心联邦的 FedAvg 加权重,可进一步提高联邦训练的性能。

1 改进的 LSTM 预测模型

1.1 VMD 分解

船舶横摇运动是非平稳非线性的,通过 VMD 方法将非平稳的船舶横摇运动数据分解为多个较为平稳的分量^[7],VMD 的每个 IMF 分量拥有独立的稀疏性和中心频率 ω_k 。具体为:

(1) 先将原始横摇运动数据 $X(t)$ 分解为 K 个 IMF 分量,在含有独立同分布高斯噪声的信号中添加惩罚因子 a ,将变分离散问题变得愈发非凸性与非线性,从而确保信号在受到噪声的影响下仍然可以精确分解,可以有效保证信号重建的保真性。

(2) 引入拉格朗日乘法算子 λ ,可确保分解得到每个 IMF 分量带宽的严格最优解,扩展的拉格朗日表达式如式(1)所示:

$$L = \left(\{u_k\}, \{\omega_k\}, \lambda \right) = a \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \left\| X(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), X(t) - \sum_k u_k(t) \right\rangle \quad (1)$$

式中, $\{u_k\} = \{u_1, \dots, u_k\}$ 为分量的调幅调频信号, $\{\omega_k\} = \{\omega_1, \dots, \omega_k\}$ 为各分量中心频率, $u_k(t)$ 经过 Hilbert 变换得到 $(\delta(t) + j/\pi t) \cdot u_k(t)$, 最终对 $\{\hat{u}_k(\omega)\}$ 进行傅里叶变换,得到时域的 IMF 分量集合 $\{u_k(t)\}$ 。

1.2 注意力机制的 LSTM (AM-LSTM)

LSTM 是基于循环神经网络 (Recurrent Neural Network, RNN) 的改进,可以学习并保存输入数据的整个历史信息,且可通过遗忘门、更新门和输出门来选择性地添加或删除历史信息,进而解决训练过程中梯度消失或梯度爆炸的问题,提高预测精度。具体工作过程如下:

$$\begin{aligned} f_t &= \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \\ i_t &= \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \\ \tilde{C}_t &= \tanh(W_c \cdot [h_{t-1}, X_t] + b_c) \\ C_t &= f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \\ h_t &= \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \cdot \tanh(C_t) \end{aligned} \quad (2)$$

式中, σ 表示 sigmoid 函数, W 为门权重, b 为门偏置。首先,遗忘门 f_t 经由 $t-1$ 时刻的输出 h_{t-1} 和 t 时刻的输入 X_t 两个参数,输出一个 $[0, 1]$ 之间的数值给细胞状态 C_{t-1} ,其中 1 表示“全部保留”,0 表示“完全舍弃”;由一个 sigmoid 层来决定要更新的信息 i_t ,对输入的信息进行有选择性地记忆;然后,通过 \tanh 函数创建待添加信息 \tilde{C}_t ,再将旧的细胞状态 C_{t-1} 与 f_t 相乘,确定需要丢掉的信息,综合完成细胞状态的更新;接着由 sigmoid 层来确定 h_{t-1} 和 X_t 的输出部分,最后通过 \tanh 函数将细胞状态 C_t 处理成一个 $[-1, 1]$ 之间的值,并将其与 sigmoid 的结果相乘,得到最终的神经元输出 h_t 。

LSTM模型的输入步长越长,需要挖掘的信息也就越多,而在输入数据较多时,LSTM仍然会出现梯度爆炸或梯度消失的问题。因此,需要能够尽可能地保留对历史输入数据的记忆。在此使用注意力机制(Attention Mechanism, AM)来对 LSTM 模型进行优化,能够从输入数据中获取重点关注区域,以投入更多的注意力,从而获得更加重要的历史信息。主要分为两个计算步骤:

(1) 计算注意力分布

假定 LSTM 在 t 时刻的隐藏层的最后一个状态 h_t 设为 s_t , 然后需要计算 s_t 和 t 时刻每个状态 $h_i (i=1, 2, 3 \dots n)$ 的相关性, 如式(3)所示, \tilde{a}_i 为 t 时刻 h_i 对应的权值, 共有 n 个 \tilde{a} 。

$$\tilde{a}_i = a(h_i, s_t) \tag{3}$$

式(3)中非线性函数 $a(\cdot)$ 为对齐模型, 可以用来衡量数据间的相似度, 相似度越高, 注意力机制的权重越大。归一化权重, 对 \tilde{a}_i 进行 softmax 变换:

$$a_i = \text{softmax}(\tilde{a}_i) = \frac{\exp(\tilde{a}_i)}{\sum_{i=1}^n \exp(\tilde{a}_i)} \tag{4}$$

(2) 根据注意力分布来计算输入信息的加权平均值:

$$c_t = \sum_{i=1}^n a_i h_i \tag{5}$$

通过式(5)对 t 时刻权重 a 所对应的 n 个 LSTM 状态进行加权平均得到 c_t 。注意力机制层将 LSTM 所有时刻的输出结合起来, 通过对其加权平均的方式得到最终的输出, 加强输入与所有输出数据之间长距离的关系, 可有效保证模型对历史数据的记忆能力。

1.3 多维多步 VMD-AM-LSTM-EC 预测模型

将 VMD 分解横摇运动后的所有 IMF 分量作为变量 $\{[u_1], [u_2] \dots [u_k]\}$ 输入到 AM-LSTM 预测模型, 即实现多维输入; 然后根据补偿时间的需求, 实现多步输出预测数组 $\{[\hat{Y}_1], [\hat{Y}_2] \dots [\hat{Y}_k]\}$ ($\hat{Y}_1 = [\hat{y}_{11}, \hat{y}_{12}, \dots]$), 最后取每个预测数组 \hat{Y} 的最后一个数据相加得到最终结果 Y_x 。为了进一步提升模型的预测精度, 本文将误差校正(Error Correct, EC)与 VMD-AM-LSTM 模型相结合, 计算预测误差 e :

$$e = X' - Y_x \tag{6}$$

再将预测误差 e 输入到 AM-LSTM 模型进行预测, 获得预测误差值 Y_e :

$$\begin{aligned} Y_e &= \text{AM-LSTM}[e] \\ Y &= Y_x + Y_e \end{aligned} \tag{7}$$

将预测值 Y_x 和预测误差值 Y_e 相加得到最终船舶横摇运动的预测结果 Y , 如图 1 所示, 而通过添加误差校正模块, 可进一步提高 VMD-AM-LSTM 模型的预测精度。

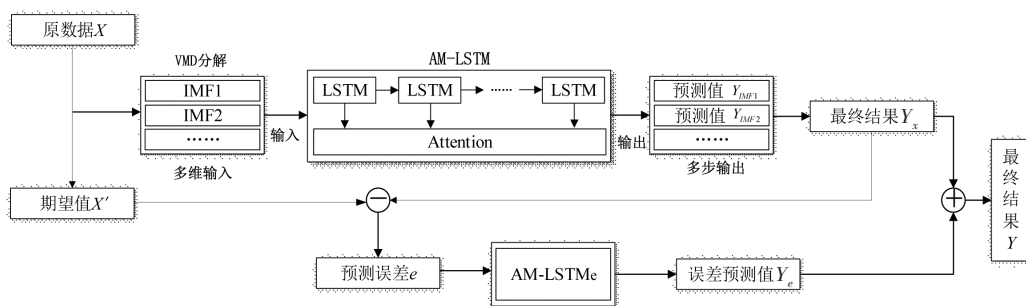


图 1 VMD-AM-LSTM-EC 的多维多步模型图

Fig.1 Multi-dimensional and multi-step model of VMD-AM-LSTM-EC

2 优化联邦泛化模型

在实际船舶作业中时,参与训练的数据在很大程度上决定了预测模型的好坏,训练数据的特征越

全面,模型的适应性和泛化能力就越强。本文采用联邦学习方法联合多客户端训练模型,提高预测模型的泛化能力。

2.1 择优联邦

由于单个船舶横摇运动数据的持有方很难拥有全面的运动数据,故需要多家企业的数据进行联合。但是随着大数据的飞速发展,数据的隐私性和保密性越来越重要,导致联合多个持有方的数据进行预测模型的训练变得难上加难。为了解决数据孤岛的问题,谷歌团队在 2016 年提出了能够在进行大数据交换时保证信息安全且合法合规的方法,称之为联邦学习(Federated Learning, FL),可以在多个参与方之间进行高效率的机器学习。即在各个数据持有端(公司/企业/机构等,后称为客户端)的数据不直接共享的前提下,通过联邦学习中加密算法的支持,在不违背数据的隐私性原则的条件下,联合各个客户端的数据训练一个全局的共享模型,训练好的模型在各自客户端只为本地数据服务。

具体步骤如下:

(1) 首先中心服务器向各客户端发送建模请求,拥有相关海况数据的客户端对其进行响应。在达成联邦学习协议之后,中心服务器向 A、B 等各客户端发送初始化模型 g 和初始化权重 w_0 。各个客户端的 LSTM 模型及权重如下:

$$g(w_{A0}) = g(w_{B0}) = \dots = g(w_0) \tag{8}$$

(2) 客户端 i 利用初始化后的模型对本地数据进行训练,将训练好后的模型权重 w_i ($t=1, 2, \dots$) 加密后上传到中心服务器。为了避免传统联邦学习的过拟合训练,本文添加了式(9)的模型择优过程, $g(w_{i}^*)$ 为训练好后的模型权重,具体步骤如下:

$$g(w_{i}^*) = \min(g(w_i), g(w_{i-1})) \tag{9}$$

如图 2 所示,当客户端本地每完成一轮联邦训练后,使用本地数据对预测模型进行评估,然后根据式(9)选取最优的模型 w_i^* 上传到联邦中心服务器进行联邦训练。在上传本地模型梯度之前,进行多次本地梯度下降迭代,对自然生成的不平衡和非独立同分布等数据具有很好的鲁棒性,并且能够在通讯次数较少的情况下更好地收敛,训练出高质量的模型,大大降低通讯成本。

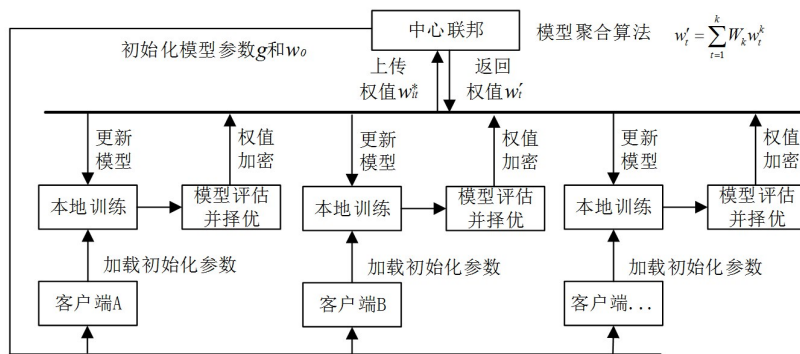


图 2 添加择优步骤的联邦学习步骤

Fig.2 Federated learning steps with optimization process

(3) 中心服务器接收到所有客户端上传的权重后,对其进行联邦平均算法 FedAvg 模型聚合处理,按每个客户端本地所加入训练的样本数,对其所上传模型权值进行加权平均:

$$w'_t = \sum_{i=1}^k W_k w_i^k \tag{10}$$

式中, w'_t 为联邦平均后的权值; k 为客户端的数量; W_k 为第 k 个客户端模型权值对应的权重; w_i^k 为第 k 个客户端模型的权值,最后将聚合后的权重 w'_t 返回各客户端。

(4) 当各客户端收到中心服务器返回的模型参数后,对本地的模型进行更新,并继续根据本地的数据对模型进行训练得到式(11),再将训练好的模型权重上传到服务器进行聚合。

$$\begin{cases} g(w_{A2}) = g(w'_1) \\ g(w_{B2}) = g(w'_1) \\ \dots \end{cases} \quad (11)$$

(5) 将步骤(3)和(4)进行多次迭代,当模型收敛后结束训练,此时可得到各客户端的泛化预测模型。经过择优联邦能够剔除训练过程中较差模型对训练的负面影响,从而保证联邦训练过程中的稳定性。

2.2 基于 MMD 的特征联邦

在联邦学习中最为关键的参数为 FedAvg 的加权平均的权重值 W_k ,其需要选择合适的客户端才能进行有效联邦。由于参与模型训练的样本数直接影响模型的预测效果,参与训练的样本数量越多,模型的预测效果通常会更好。但船舶横摇运动数据通常只能按照海况等级来划分样本,无法辨别船舶横摇运动局部的变化情况^[18],体现不出非平稳、非线性船舶横摇运动变化的丰富程度,因此无法通过样本数对 FedAvg 的权重 W_k 进行赋值。而船舶横摇运动数据的局部变化特征,能够在一定程度上表征数据的丰富程度。因此,本文采取最大均值差异方法(Maximum Mean Discrepancy, MMD)对船舶横摇运动的变化特征进行统计,以此来更加明确地设定 FedAvg 的权重 W_k 。

最大均值差异 MMD 通常用于描述两个数据集间概率分布的差异度,其可以在不考虑初始密度函数的情况下测量数据间的分布差异。通过给定再生核希尔伯特空间中的非线性映射函数 $H(\cdot)$,并引入高斯内核运算 $K(\cdot)$,重构得到联邦学习源域 X_S 和目标域 X_T 之间的 MMD 为

$$MMD_e(X_S, X_T) = \frac{1}{n_S^2} \sum_{i=1}^{n_S} \sum_{j=1}^{n_S} K(x_S^i, x_S^j) + \frac{1}{n_T^2} \sum_{i=1}^{n_T} \sum_{j=1}^{n_T} K(x_T^i, x_T^j) + \frac{1}{n_S n_T} \sum_{i=1}^{n_S} \sum_{j=1}^{n_T} K(x_S^i, x_T^j) \quad (12)$$

式中, n_S 表示源域样本数量, n_T 表示目标域样本数量, $x_S^i \in X_S$ 和 $x_T^i \in X_T$ 。 MMD_e 衡量联邦客户端源域 X_S 和目标域 X_T 之间的差异性, MMD_e 越小说明联邦的两个客户端船舶横摇运动规律越相似。

由于在联邦学习过程中,无法直接使用 MMD 对各个客户端的数据进行相似性计算,故本文通过提取原始数据的最大最小值来对原始数据进行表征,然后对各组数据的特征进行 MMD 计算,以此来判断数据间的相关性。但是采集到的数据里包含多种海况、多种浪向角下的船舶横摇运动数据,若使用整组的数据计算 MMD(Max&min),往往会忽略数据局部的特征相关性,从而无法挖掘出数据中存在的特殊船舶横摇运动情况。在此,本文提出基于 MMD 的分段特征联邦学习方法,对多客户的原始数据按时间窗分为 n 段,分别提取最大最小特征值后上传至中心联邦;设分段特征源域为 C_{X_S} 和目标域为 C_{X_T} ,计算并比较其 MMD(Max&min),选择分段差异小的客户端进行联邦。在充分挖掘各分段特征值的基础上,进一步分段比较特征的差异性,选择相似度最高的客户端联邦能全面提高模型的泛化能力。分段特征联邦学习过程中的 MMD 计算过程如图 3 所示。




图 3 基于 MMD 的分段特征联邦示意图

Fig.3 Schematic diagram of segmented feature federation based on MMD

图 3 所示的基于 MMD 的分段特征联邦学习的具体步骤如下:

- (1) 首先,将客户端 A 和 B 的数据按照时间窗 t 进行分割,时间窗内应包含多个周期的数据,使得

$X_{A,1} \cup X_{A,2} \cup \dots \cup X_{A,n-1} = X_A$; 并计算各段数据的最大值和最小值, 并且按照时间顺序进行排列, 得到特征数组 C_A 和 C_B ;

(2) 其次, 将其加密上传到联邦中心服务器后, 在特征数组 C_A 和 C_B 中以时间窗 t_2 进行分段, 选取源域为 $X_{S(C_{A,i}^*)}$, 其余特征作为目标域 $X_{T(C_{A,i}^*)}$ 和 $X_{T(C_{B,i}^*)}$, 分别计算与源域之间的 MMD 值, 得到相应的 MMD 数组 MMD_A 和 MMD_B 。

(3) 然后, 分析 MMD_A 和 MMD_B 的关系, 全部的 MMD_A 和 MMD_B 特征差异记为 $MMD_{A \cup MMD_B}$, 相同的特征差异值记为 $MMD_{A \cap MMD_B}$, 由上述特征值集可以得到的 MMD_A 、 MMD_B 两组数组的相似性程度 $\rho = \frac{Num(MMD_A \cap MMD_B)}{Num(MMD_A \cup MMD_B)}$, 判断两客户端能否进行联邦训练。

(4) 最后, 根据客户端的特征差异多样性, 即 $MMD_A - (MMD_A \cap MMD_B)$ 和 $MMD_B - (MMD_A \cap MMD_B)$, 由客户端 A 和 B 特征差异值的不同值个数 Num, 确定中心联邦聚合算法式(10)中的权重 $W_k = \frac{Num(MMD_A - (MMD_A \cap MMD_B))}{\sum_k Num(MMD_k - (MMD_A \cap MMD_k))}$, 其中 k 表示第 k 个客户端, n 为参与联邦训练的客户端

的数量。

上述特征的源域和目标域, 均能表征船舶横摇运动的局部变化特性, MMD 值越小, 则说明船舶横摇运动变化越相似; 当 MMD 值越大且数量较多, 说明数据集中的船舶横摇运动变化越丰富。因此可以通过计算去重后所得的 MMD 值的数量, 对 FedAvg 的权重进行重新设定, 在挖掘体现船舶横摇运动的局部非平稳、非线性特征的同时, 中心联邦为目标域选择合适的聚合源域, 高质量提高预测模型的泛化能力。

3 实验与分析

3.1 船舶横摇运动仿真

海浪在海上受到多变的海风的影响, 海面上会产生复杂的波浪, 称之为随机海浪, 不规则的长峰波随机海浪可表示为

$$\zeta(t) = \sum_{i=1}^{\infty} \zeta_{\omega_i} \cos(k_i \xi \cos \mu + k_i \eta \sin \mu - \omega_i t + \varepsilon_i) \tag{13}$$

式(13)即为 Longuet-Higgins 长峰波随机海浪模型^[9]。其中 ζ_{ω_i} 代表第 i 个谐波的幅值; k_i 为 i 个谐波的波数; ω_i 为谐波的角频率; ε_i 是初相角, 其取值为 $0 \sim 2\pi$ 之间的随机数。长峰波随机海浪谱下的船舶横摇运动数据的波动较为复杂, 在局部呈现非平稳性。本文模拟船舶在长峰波随机海浪谱下的六自由度运动, 可通过调节船型、风浪等级、浪向角、吃水、航速等参数来模拟不同工况下的船舶横摇运动。三级以下海浪不大, 四~五级海况是大浪, 六级狂浪不易开展海上作业, 四级海况出现的概率有 40.19%, 故本文模拟船舶处于四级海况、吃水 6 m、浪向角 60° 、航速 0 km/h 的情况下, 基于长峰波随机海浪谱生成的船舶横摇运动姿态数据, 仿真数据如图 4 所示。




图 4 四级海况下长峰波随机海浪谱船舶横摇运动数据图
Fig.4 Data chart of ship rolling motion with long peak wave random wave spectrum under Class 4 sea state

从图 4 中可以看出, 通过长峰波随机海浪谱仿真出来的数据更加复杂多变, 且没有明显的规律性。对其进行 ADF 检验, 全局数据计算所得 P 值均为 0, 可知长时间的横摇运动序列表现为平

稳状态,且数据均能保持在零点上下波动。但船舶横摇运动局部数据的 P 值均存在大于0.05的情况,因此存在局部非平稳性。

3.2 VMD-AM-LSTM-EC 实验

VMD 分解的效果受分解尺度 K 的影响较大,大量的分析和实验研究表明, K 值取6时能使原始信号充分分解。设置 VMD 分解的惩罚系数 a 为2000,分解尺度 K 设为6。本文在客户端实验中选择总样本1250个,选取80%用于训练,20%用于测试,即训练集有1000个数据,验证集有250个数据,来验证 VMD-AM-LSTM-EC 模型的预测效果。

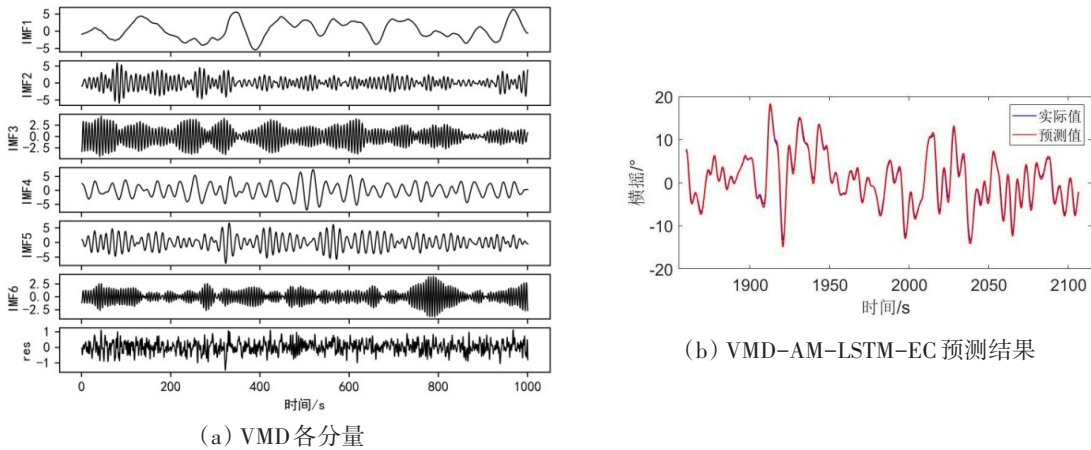


图5 VMD-AM-LSTM-EC 的多维多步模型预测图

Fig.5 Multi-dimensional and multi-step model prediction diagram of VMD-AM-LSTM-EC

从图5可以看出,经过VMD分解的所有IMF分量预测结果不再存在时延问题,加入误差校正模块的VMD-AM-LSTM模型能够达到很好的预测效果,预测值均能较好地逼近实际值。为了更加直接地看出各模型的预测效果,分别计算各个模型的预测误差并进行比较,如表1和图6所示。

表1 不同模型预测结果对比

Tab.1 Comparison of prediction results with different models

模型种类	LSTM	AM-LSTM	VMD-AM-LSTM	VMD-AM-LSTM-EC
均方根误差	2.950	2.244	1.851	0.593
平均绝对误差	2.352	1.776	1.457	0.340
最大误差	9.913	7.671	6.240	1.752




图6 不同模型误差对比图

Fig.6 Error comparison of different models

如表1所示,经过VMD分解过后的AM-LSTM模型的RMSE值,相比于AM-LSTM模型提升了18%,而加入误差校正模块后模型的预测更加突出, RMSE能够达到0.593, MAE值的变化与RMSE的

变换相似。从图 6 可以看出,添加误差校正模块的模型,其预测结果的误差值相比其他模型有极为显著的减小。因此可以看出,VMD-AM-LSTM-EC 模型的预测精度提升较大,效果更加理想。

3.3 基于特征联邦的船舶横摇运动实验

3.3.1 MMD 特征联邦实验

本文通过长峰波随机海浪谱程序仿真,生成了四级海况不同浪向角下的连续船舶横摇运动情况,其中浪向角分别为 15°、30°、45°、60°、75°和 90°,具体的船舶横摇运动变化曲线图如图 7 所示。

从图 7 中可以看出,包含多种浪向角变化的船舶横摇数据的幅值变化,相比于单一浪向角下的变化更加丰富多变,直接计算 3000 s 的最大最小特征时无法反映 15°和 30°的运动情况。根据上述所示步骤,使用图 7 所示的四级海况多个浪向角下船舶横摇数据进行实验,具体实验步骤如下:






图 7 四级海况下多浪向角变化的数据图
Fig.7 Data chart of multi-wave direction angle change under Level 4 sea state



(a) 客户端 A 数据



(b) 客户端 B 数据

图 8 客户端 A 和 B 的本地数据

Fig.8 Local data of Clients A and B

(1) 从图 7 所示的数据中选取两段数据作为客户端 A 和客户端 B 的数据,如图 8 所示,其中客户端 A 的数据包含 15°至 60°的船舶横摇运动数据,客户端 B 的数据包含 45°至 90°的船舶横摇运动数据。将两组数据按照 50 秒数据长度进行分割,并计算每段数据的最大值和最小值,分别记为 C_A 、 C_B 。

(2) 选取 C_A 的首个 100 s 内的特征值作为源域,并以 100 s 的时间窗分割 C_A 和 C_B 其余部分作为目标域,计算 MMD 值,记为 MMD_A 、 MMD_B 。

(3) 分别计算数组 MMD_A 和 MMD_B 的差异情况来统计两数组中相同和不同的部分,并分别统计各个数组中元素的个数。

经上述步骤计算后,所得结果如表 2 所示。

表 2 联邦 MMD 值统计

Tab.2 Statistical table of federal MMD values

	最大均值差异 MMD						个数 Num
$MMD_A \cup MMD_B$	0.18	0.42	0.60	0.61	0.63	...	81
$MMD_A \cap MMD_B$	1.53	1.73	1.57	1.79	1.81	...	28
$MMD_A - (MMD_A \cap MMD_B)$	0.18	0.42	0.60	0.61	0.63	...	31
$MMD_B - (MMD_A \cap MMD_B)$	2.01	2.49	2.81	2.60	2.69	...	22

如表 2 所示, MMD_A 和 MMD_B 相同差异值个数为 28 个, MMD_A 和 MMD_B 的全部特征差异值个数共 81 个。计算相似度比为 $\rho=28/81=34.6\%$, 当此值较大时,说明客户端 A 和 B 间的数据相似度较大,

即可联邦。同时,根据 MMD_A 和 MMD_B 的特征差异值的不同个数,可计算式(14)中 FedAvg 的权重 W_k ,即

$$\begin{cases} W_{kA} = \frac{31}{53} = 0.58 \\ W_{kB} = \frac{22}{53} = 0.42 \end{cases} \quad (14)$$

此时中心联邦优化的权值为

$$w'_i = 0.58 \cdot w_{A_{i-1}} + 0.42 \cdot w_{B_{i-1}} \quad (15)$$

综上所述,可根据相似度比值 ρ 的大小,来判断两组数据是否能参与联邦训练;同时,可以根据客户端的不同差异值的数量对 FedAvg 的权重进行标定,进而得到中心联邦优化后的模型权值 w'_i 。

3.3.2 择优联邦实验

采用上述实验数据进行联邦学习仿真,图9为客户端 A 在经过 MMD 设定 FedAvg 权重后,采用传统联邦和择优联邦训练模型结果的 RMSE 值。

从图9中可以看出,在联邦训练前期,两者的 RMSE 变化较为相似,都随联邦学习训练次数的增加而减小,能够快速收敛。但经过 5 轮联邦训练之后,传统联邦训练模型的 RMSE 值逐渐增大,联邦优化效果变差。而添加模型择优后的联邦训练模型预测结果仍然能够保持平稳的状态,模型持续收敛,最终收敛到 0.4 附近,相比传统联邦模型训练过程更加稳定。




图9 添加择优步骤后的结果对比图

Fig.9 Comparison of results after adding the optimization step

综上所述,通过选择最优模型并通过 MMD 值进行加权联邦后的模型具有更优的效果,图 10 为客户端 A 和 B 对测试集和验证集的预测结果。

从图 10 中可以看出,进行联邦训练之后的模型对两个客户端的测试集和验证集均能达到较好的预测效果,且模型预测均能在第三轮联邦训练之后达到相对稳定。比较本地训练模型和择优联邦后的模型预测效果,如表 3 所示。

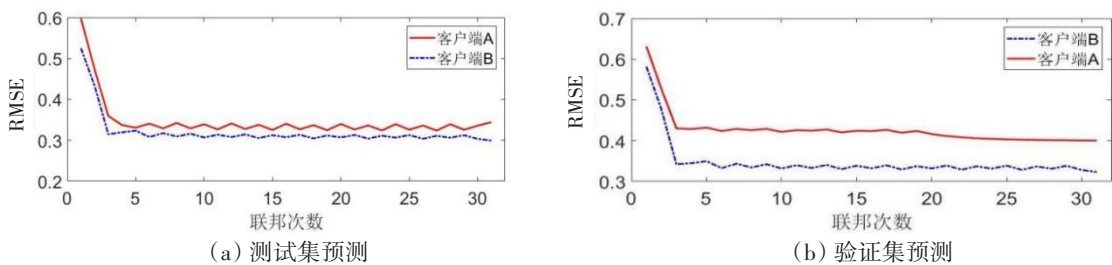


图10 联邦学习后两客户端的预测效果

Fig.10 Predicted results for two clients after federated learning

表 3 联邦前后模型预测结果对比表

Tab.3 Prediction results for different models before/after federated learnings

RMSE	本地训练模型_A	择优联邦模型_A	本地训练模型_B	择优联邦模型_B
测试集	0.538 15	0.323 80	0.496 04	0.303 41
验证集	0.627 88	0.400 23	0.549 84	0.313 54

从表中所示的客户端 A 和 B 模型预测 RMSE 值可以看出,相比于本地训练的模型,经过联邦训练

优化之后的模型预测效果至少提升了36%。经过择优模型上传进行MMD加权平均后的模型,具有更好的预测效果和更快的收敛速度,且联邦模型精度更高,具有更好的泛化能力。

4 结 语

根据海上作业波浪补偿的需求,针对非平稳、非线性船舶横摇运动的精准预测模型泛化较难问题,本文提出了一种基于联邦泛化的VMD-AM-LSTM-EC预测模型。首先通过VMD将非平稳性船舶横摇运动数据分解成多组较为平稳的数据分量,再使用注意力机制AM改进的LSTM网络进行模型训练,最后采用误差校正进一步提高本地模型的预测精度。考虑联邦多海域客户端进一步泛化多海况船舶横摇运动预测模型,通过计算各个客户端对应的MMD值,对FedAvg的加权参数进行标定,并选取最优模型进行联邦训练。实验表明,择优的特征联邦学习具有更高的收敛速度,经过联邦训练之后的模型具有更高的预测精度和更好的泛化能力。因此,本文方法为船舶横摇运动预测更好地为海上风电安装运维等领域服务提供了新思路。

参 考 文 献:

- [1] 张海亚,郑 晨. 海上风电安装船的发展趋势研究[J]. 船舶工程, 2016, 38(1): 1-7.
Zhang Haiya, Zheng Chen. Research on the development trend of offshore wind power installation ships[J]. Marine Engineering, 2016, 38(1): 1-7. (in Chinese)
- [2] Ehoehson L D. Prediction of time series using multiple regression techniques and seakeeping applications[J]. Engineering Environmental Science, 1963: 1-48.
- [3] 彭秀艳. 船舶运动姿态在线预报及仿真技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2006.
Peng Xiuyan. Research on online prediction and simulation technology of ship motion attitude[D]. Harbin: Harbin Engineering University, 2006. (in Chinese)
- [4] 唐 刚,姚小强,胡 雄. 基于Newton法优化ARMA模型参数的船舶升沉运动预测研究[J]. 海洋工程, 2020, 38(2): 27-38.
Tang Gang, Yao Xiaoqiang, Hu Xiong. Research on the prediction of ship heave motion based on the optimization of ARMA model parameters by Newton method[J]. Offshore Engineering, 2020, 38(2): 27-38. (in Chinese)
- [5] Peng X, Zhao X, Xu L. Real-time prediction algorithm research of ship attitude motion based on order selection with corner condition[C]//1st International Symposium on Systems and Control in Aerospace and Astronautics, ISSCAA 2006, 2006.
- [6] Romanuke V. Arima model optimal selection for time series forecasting[J]. Maritime Technical Journal, 2022, 224(1): 28-40.
- [7] 陈倩清,郑 淑,李 明,等. 船舶横摇运动预测误差研究[J]. 船舶工程, 2021, 43(2): 42-47.
Chen Qianqing, Zheng Shu, Li Ming, et al. Research on prediction error of ship rolling motion[J]. Marine Engineering, 2021, 43(2): 42-47. (in Chinese)
- [8] 孙 珽,徐东星,尹 勇,等. 基于VDM与APSO优化极限学习机的船舶运动姿态预报[J]. 船舶工程, 2019, 41(11): 89-97.
Sun Lian, Xu Dongxing, Yin Yong, et al. Ship motion attitude prediction based on VDM and APSO optimized limit learning machine[J]. Marine Engineering, 2019, 41(11): 89-97. (in Chinese)
- [9] 张泽国,尹建川,柳 成. 基于自适应变异PSO-BP算法的船舶横摇运动预测[J]. 舰船科学技术, 2016, 38(23): 69-73.
Zhang Zeguo, Yin Jianchuan, Liu Cheng. Prediction of ship rolling motion based on adaptive mutation PSO-BP algorithm[J]. Ship Science and Technology, 2016, 38(23): 69-73. (in Chinese)
- [10] Liu Y, Duan W, Huang L, et al. The input vector space optimization for LSTM deep learning model in real-time prediction of ship motions[J]. Ocean Engineering, 2020, 213: 107681.
- [11] Zhang T, Zheng X Q, Liu M X. Multiscale attention-based LSTM for ship motion prediction[J]. Ocean Engineering, 2021, 230: 109066.

- [12] Zhang G, Tan F, Wu Y. Ship motion attitude prediction based on an adaptive dynamic particle swarm optimization algorithm and bidirectional LSTM neural network[J]. *IEEE Access*, 2020, 8: 90087–90098.
- [13] Liu Q, Chen C, Qin J, et al. FedDG: Federated domain generalization on medical image segmentation via episodic learning in continuous frequency space[C]//arXiv, 2021.
- [14] McMahan H B, Moore E, Ramage D, et al. Communication-efficient learning of deep networks from decentralized data[C]//arXiv: 1602.05629, 2016.
- [15] Li S, Cheng Y, Liu Y, et al. Abnormal client behavior detection in federated learning[C]//arXiv: 1910.09933 2019, 2019.
- [16] Zhang L, Lei X, Shi Y, et al. Federated learning with domain generalization[C]//arXiv, 2021.
- [17] 宋航帆. 基于非线性模态分解的滚动轴承故障诊断研究[D]. 郑州: 郑州大学, 2021.
Song Hangfan. Research on rolling bearing fault diagnosis based on nonlinear modal decomposition[D]. Zhengzhou: Zhengzhou University, 2021. (in Chinese)
- [18] Meng C, Xu C, Lei Q, et al. Balanced joint maximum mean discrepancy for deep transfer learning[J]. *Analysis and Applications*, 2021, 19(3): 491–508.
- [19] Wu G, Liu C, Liang Y. Computational simulation and modeling of freak waves based on Longuet-Higgins model and its electromagnetic scattering calculation[J]. *Complexity*, 2020, 1.