

文章编号: 1007-7294(2025)03-0388-12

基于神经网络的流体晃荡波高和压强的预测研究

金鑫¹, 王宇圣¹, 张福贵¹, 陈健², 李登松³, 樊昌元¹, 刘名名⁴

(1. 成都信息工程大学 电子工程学院, 成都 610225; 2. 中国电建集团 河北省电力勘测设计研究院有限公司, 石家庄 050031; 3. 成都信息工程大学 自动化学院, 成都 610225; 4. 聊城大学 建筑工程学院, 山东 聊城 252000)

摘要: 基于 Navier-Stokes 方程的数值模型和物理模型实验研究流体晃荡现象存在计算效率低和经济成本高的不足。为此, 本文通过构建神经网络模型对数值和实验结果进行时序重构, 预测流体晃荡的压强和波高。以数值和实验的总压强和自由表面高程数据作为训练样本, 将神经网络中表征能力强的 CNN、RNN、LSTM 用于重演流体晃荡响应的时演化过程。在模型训练过程中, 系统地调节神经网络的内部结构参数, 分析预测结果与实际值之间的误差和相关性。结果表明, RNN 和 LSTM 的重构误差低于 4%, 相关性达到 0.88, 整体优于 CNN; LSTM 的整体性能最佳, 可以作为预测长序列数据的首选。整体来讲, 三种代理模型均可以较好地复现流体晃荡的波高和压强, 在流体晃荡研究方面具有良好的应用前景。

关键词: 流体晃荡; 神经网络; 数值模拟; 预测

中图分类号: O351.2 **文献标识码:** A **doi:** 10.3969/j.issn.1007-7294.2025.03.005

Predictions of wave height and pressure induced by liquid sloshing based on neural network

JIN Xin¹, WANG Yu-sheng¹, ZHANG Fu-gui¹, CHEN Jian², LI Deng-song³,
FAN Chang-yuan¹, LIU Ming-ming⁴

(1. College of Electronic Engineering, Chengdu University of Information Technology, Chengdu 610225, China;
2. PowerChina Hebei Electric Power Engineering Co., Ltd., Shijiazhuang 050031, China; 3. School of Automation,
Chengdu University of Information Technology, Chengdu 610225, China; 4. School of Architecture and
Engineering, Liaocheng University, Liaocheng 252000, China)

Abstract: Numerical modelling based on Navier-Stokes equations and model experiment for studying liquid sloshing have the limits of low computational efficiency and high economic cost. Therefore, to predict the hydrodynamic pressure and wave height, the time-histories to numerical and experimental results were reconstructed in this paper through the neural network model. The total numerical and experimental pressures and free surface elevations were taken as training samples, and CNN, RNN and LSTM with strong repretational ability were used to reproduce the sloshing responses. The internal structural parameters of the

收稿日期: 2024-09-25

基金项目: 四川省科技厅重点研发计划项目(2022YFS0541; 2024YFHZ0173); 四川省自然科学基金青年项目(2022NSFSC0976; 2022NSFSC1066); 四川省区域创新合作基金项目(2023YFQ0111); 国家自然科学基金青年项目(52109096); 教育部产学研合作协同育人项目(230806521252005); 科技部第二次青藏高原科学考察-极端天气气候事件与灾害风险(2019QZKK0104)

作者简介: 金鑫(1988-), 男, 博士, 副教授;

刘名名(1986-), 男, 博士, 研究员, 通讯作者, E-mail: liumingming_dlut@163.com。

neural network were systematically adjusted, besides, the errors and correlations between the predicted and actual values were analyzed. The results show that the error is lower than 4% and the correlations of both RNN and LSTM reach 0.88, which is in general superior to CNN, and that LSTM is optimal in predicting the long sequence data. Overall, three surrogate models can well predict the sloshing wave height and pressure, and are promising in the study of liquid sloshing.

Key words: liquid sloshing; neural network; numerical simulation; prediction

0 引言

流体晃荡作为流体力学的一个重要分支,与人类生活和工业生产息息相关,在海洋工程、航空航天、化工材料等领域具有重要的作用^[1-3]。近年来,基于非线性势流理论和 Navier-Stokes 方程的数值模型广泛用于流体晃荡的研究。李裕龙等^[4]基于非线性势流理论的数值模型,研究三舱内液体晃荡对船体运动的影响。Xue 等^[5]采用 OpenFoam 模拟了水平激励下不同形状储罐内流体的晃荡模式,并分析了流体载荷的频域特性。Takami 等^[6]基于光滑粒子流体力学(SPH)预测了矩形储罐做不规则旋转运动时流体的极限压力。尽管上述数值手段可以准确地分析流体晃荡现象,但也存在不足,例如其计算较为耗时,通常要数小时甚至几天^[7],且涉及复杂的离散网格和边界条件等问题^[8]。因此,使用替代方法在短时间内重构流体晃荡的基本特征十分必要。

随着人工智能(AI)的兴起,基于机器学习(ML)建立代理模型是最有效的替代方法之一。近年来,代理模型如支持向量机(SVM)^[9]、随机森林(RF)^[10]、人工神经网络(ANN)^[11]等已逐步应用于流体力学研究。ANN 是近年来较为流行的模型,其基于人脑思维,可以从大量复杂、非线性和非平稳性的时间序列中学习到隐藏的规律,给予研究人员前瞻性信息^[12]。为了准确地预测流体的运动规律,选取的神经网络模型及其结构参数因场景不同而异。卷积神经网络(CNN)、循环神经网络(RNN)和长短期记忆网络(LSTM)是三种常用的神经网络模型,与其它神经网络模型相比,具有局部表征能力强和权值共享(参数数量减少降低了训练难度)等优势^[13-14]。Peng 等^[7]设计了一种降阶模型,将 CNN 作为编码器,反卷积神经网络(DCNN)作为解码器(重建由 CNN 编码器提取到的特征信息),实现了对流场的快速预测,为非定常流动问题研究提供了新思路。Murata 等^[15]将 CNN 和自编码器(AE)相结合,构造了一种新的神经网络模型用于流场重建,结果表明,该模型比传统正交分解(POD)模式提取流场特征的能力更强。Liu 等^[16]将 CNN 和 LSTM 相结合,开发了一种神经网络结构,对流场的瞬时状态进行了训练和优化,可有效地预测湍流粘度场。Meng 等^[17]使用 LSTM 模型对规则波、不规则波和真实海浪波高的长期演化趋势进行了精确的预测,并通过改变输入长度进一步提高了预测的精度。

为了预测流体晃荡的压强和波高,本文采用 CNN、RNN 和 LSTM 三种神经网络模型重现总压强和自由表面高程的时序演变过程。结果表明:CNN、RNN、LSTM 三种神经网络模型的均方根误差小于 4%,拟合优度普遍大于 0.88,说明上述模型均可以有效提取到总压强和自由表面高程的时程信息,能够精准地预测流体晃荡压强和波高的时序信息。

1 原理与方法

1.1 神经网络模型

1.1.1 神经网络模型的建立

本文将神经网络模型的建立分为样本集划分、模型结构搭建、模型编译和模型训练四个部分,如图 1 所示。

具体步骤如下:

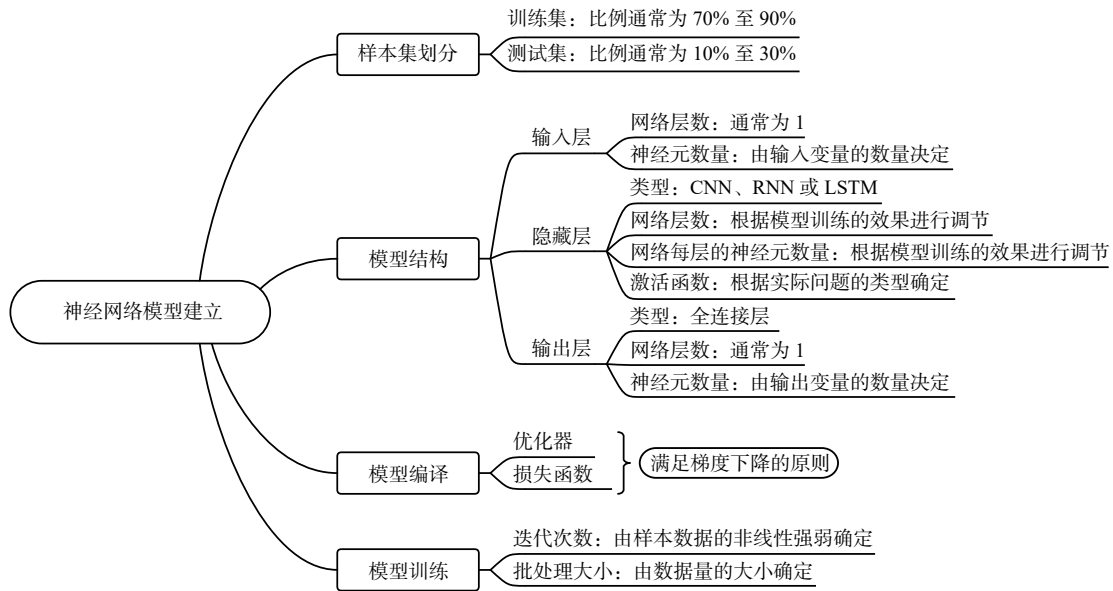


图 1 神经网络模型的流程图

Fig.1 Flow diagram of neural network

- (1) 按照一定比例将输入样本划分为训练集和测试集;
- (2) 构建由适当数量的输入层、隐藏层和输出层组成的神经网络结构,并在每层网络中设置合适的神经元个数和激活函数;
- (3) 选择适当的优化器和损失函数对模型进行编译;
- (4) 设置适当的迭代次数和批处理大小对模型进行训练。

1.1.2 CNN、RNN、LSTM 模型原理

CNN、RNN、LSTM 是 ANN 中具有代表性的三种模型,其特点分别是:CNN 可以高效地提取数据的局部特征,最大限度地规避过拟合问题;RNN 源于 CNN,引入了时间联结功能,即神经元输入的顺序将影响训练的结果;LSTM 是 RNN 的一种衍生模型,避免了神经网络层数多、结构繁琐引起的梯度消失或爆炸现象。虽然上述模型在多个领域已有应用^[18-20],但在流体晃荡方面的研究效果仍未可知。基于此,本文采用上述三种模型预测流体的晃荡压强和波高,并对它们的预测效果进行了讨论。鉴于三种模型的原理基本一致,下面以 LSTM 为例,其流程如图 2 所示。

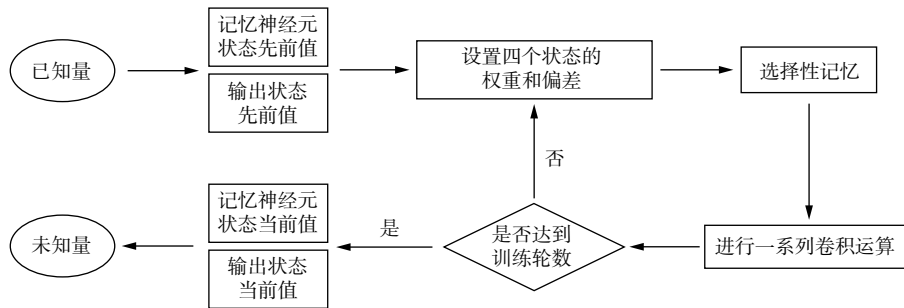


图 2 LSTM 的流程图

Fig.2 Flow diagram of LSTM

LSTM 的运算分为忘记、选择记忆和输出三个阶段。忘记阶段对上一节点传递的输入信息进行选择性忘记,以 f_t 作为忘记门控,控制 C_{t-1} 将获得的信息进行保留或忘记;选择记忆阶段将输入信息进行选择性记忆,其门控信号由 i_t 控制,通过归一化并整合新输入信息 C_t^* 得到新的状态 C_t ;输出阶段决定当前

状态的输出对象,具体方法是将门控信号 o_t 与缩放过的 C_t 进行卷积,得到一个步长的输出。以上计算如式(1)~(6)所示^[21]:

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i) \quad (2)$$

$$C_t^* = \tanh(W_c[h_{t-1}, X_t] + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * C_t^* \quad (4)$$

$$o_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

式中, $[h_{t-1}, X_t]$ 表示两个向量的连接, W_f 、 W_i 、 W_c 、 W_o 和 b_f 、 b_i 、 b_c 、 b_o 分别表示四个状态的权重和偏差。

1.2 数据预处理与评估标准

在搭建神经网络之前,将已知数据按照一定比例划分为训练集和测试集两部分。训练集用于更新模型的参数,测试集用于评价模型的泛化能力。由于不同数据在数值上差异可能很大,量纲也不一致,直接取值对模型参数的优化非常不利。因此,为了提高模型训练的速度和精度,将训练数据进行归一化处理,如式(7)所示:

$$X_n = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

式中, X_{\max} 和 X_{\min} 分别表示训练集中数据的最大值和最小值, X_i 为当前数值, X_n 是 X_i 的归一化值^[22]。经过归一化后,所有数据都在0和1之间。采用均方根误差(R_{MSE})和拟合优度(R^2)来衡量预测的精确度,分别如式(8)和式(9)所示^[23]:

$$R_{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (r_i - p_i)^2} \quad (8)$$

$$R^2 = \frac{\frac{1}{n} \sum_{i=1}^n (r_i - \bar{r})(p_i - \bar{p})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (r_i - \bar{r})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - \bar{p})^2}} \quad (9)$$

式中, n 为样本数量, r_i 是第 i 个样本的真实值, p_i 是第 i 个样本的预测值, \bar{r} 是所有真实样本的平均值, \bar{p} 是所有样本预测结果的平均值。

1.3 神经网络模型的参量

建立和编译神经网络模型时,选择合适的反向传播算法、激活函数和损失函数至关重要。其中,激活函数在建立CNN模型时设置,反向传播算法和损失函数在编译三种模型时设置。尽管这些参量的设置在前人的研究中有所体现,但未有关于不同应用场景的通用设置。此外,文中未提及的一些参量,如训练轮数、批处理大小等,也需要根据不同的物理现象灵活调试,找到最佳值。

1.3.1 反向传播算法

反向传播算法(BP)的原理是通过逐层求偏导优化先前神经元的权重^[24]。利用现代编程软件,可以在优化器(Optimizer)中设置反向传播算法的类型。常用的BP类型有随机梯度下降法(SGD)、动量法(Adam)等。与传统的随机梯度下降法相比,Adam可以为参数设计独立的自适应性学习率,适合应用于非稳态目标,解决大规模数据和参数的优化问题。因此,本文采用Adam优化算法。

1.3.2 激活函数

激活函数(Activation)借助误差梯度调节神经元的权重和偏差,用于拟合神经网络模型的非线性(不规则性)特征^[25]。ReLU作为卷积层中常用的激活函数,将输出结果进行非线性映射,其数学表达式^[26]为

$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (10)$$

该函数的值域为正实数,且斜率始终为 1,使得神经网络有了稀疏特性,可以解决梯度消失的问题。

1.3.3 损失函数

损失函数(Loss)用来衡量预测值和真实值之间的差异。对于回归问题,常用的损失函数是均方误差函数^[27],其数学表达式为

$$M_{SE}(p, q) = \frac{\sum_{i=1}^n (p(x_i) - q(x_i))^2}{n} \quad (11)$$

式中, p 表示真实值的分布, q 表示预测值的分布。

2 神经网络模型的构建

2.1 数据样本

本文采用 Xue 等^[28](2019)的实验数据和 Jin 等^[29](2021)的数值模拟结果作为输入样本。实验数据的采样间隔为 0.06 s,数值模拟结果的采样间隔为 0.01 s。数值和实验得到的流体晃荡总压强和自由表面高程的时程比较关系如图 3 所示。

可以看出,除了图 3(a)的初始段(前 1.5 s,归结于实验仪器突然启动带来的干扰)和极值点处(实验采样频率相对较低,遗漏部分极值),数值结果和实验数据较为吻合。

2.2 模型建立与参数设置

本文使用 Python 中的 Keras 库完成 CNN、RNN、LSTM 模型的构建。三种模型均由 1 个输入层、3 个隐藏层和 1 个输出层组成,每个隐藏层的神经元个数为 128。在 CNN 中,采用一维卷积,卷积层的内核大小设为 3,池化层的池大小和跨度均设置为 3,激活函数选择 ReLU。

在 RNN 和 LSTM 中,将数值结果和实验数据样本的输入步长分别设为 50 和 10。最后设置与神经网络模型编译和训练有关的超参数,原理如下:

(1)损失函数:根据研究问题的类型进行确定。本文对流体晃荡压强和波高的时序重构属于回归问题,因此选用均方误差函数。

(2)优化器:根据数据的特点进行确定。针对流体晃荡波高和压强数据规模庞大和不规则的特点,本文选用 Adam 优化器以更好地优化参数。

(3)训练轮数:根据损失函数的变化进行确定。三种模型在训练轮数超过 50 后,损失函数均不再有明显变化的趋势,此时停止迭代不再训练,最终将训练轮数设定为 50。

(4)批处理大小:根据数据量进行确定。通常情况下,数据量越大,批处理大小的值越大。基于以上原理,本文将数值和实验数据的批处理大小分别设为 32 和 16。

(5)梯度下降:为防止出现过拟合现象而设定。其原理是每经过一层神经网络,模型丢弃部分数




图 3 数值结果^[29]和实验结果^[28]的时程比较

Fig.3 Comparisons of time histories between numerical and experimental results

据。一般而言,每层丢弃数据的比例为 0.2。基于以上原则,本文将该参数设置为 0.2。
综上所述,神经网络超参数的设置如表 1 所示。

表 1 神经网络超参数
Tab.1 Hyper-parameters of neural network

参数名	值或类型
损失函数	均方误差函数
优化器	Adam
训练轮数	50
批处理大小	16 (实验数据) 或 32 (数值结果)
梯度下降	0.2

3 结果与讨论

3.1 误差分析

基于样本集划分理论^[30],选取了三种不同比例的训练样本,分别为 70%、80% 和 90%。对比发现,当样本比例为 90% 时,模型的预测效果最佳。因此,选取前 90% 的数据作为训练样本,剩余的 10% 数据作为测试样本。图 4 和图 5 分别展示了训练集(部分)和测试集中 CNN、RNN、LSTM 三种模型预测结果与实际值的时程比较关系。

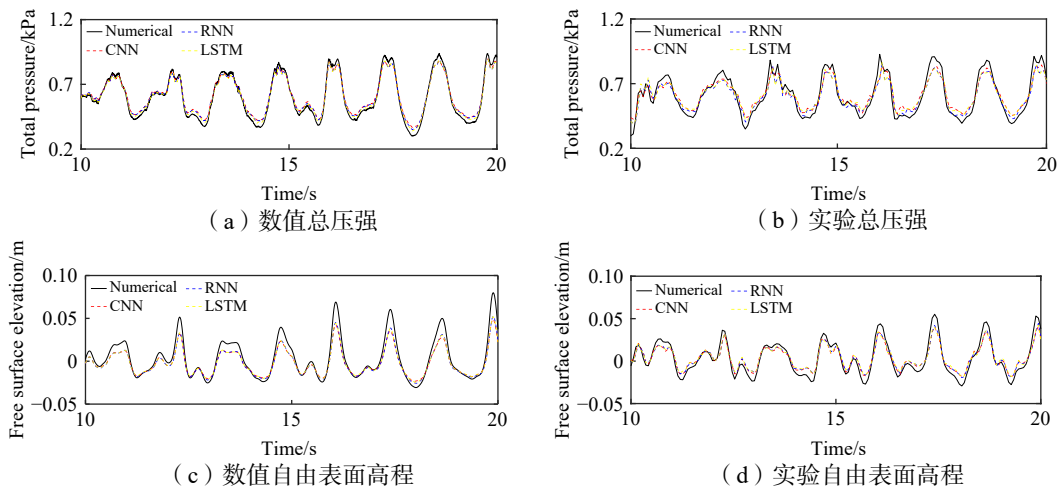


图 4 训练集中三种神经网络模型预测结果与实际值的时程比较

Fig.4 Comparisons of time histories between actual and predicted values from three neural network models in the training set

从图 4 和图 5 可以看出,三种模型得到的时程数据与真实结果较为接近,预测效果整体较好,但在局部存在一定的差异(如图 4(b)的 10.2 s 至 10.6 s 和图 5(d)的 28.8 s 至 29 s,数据在该时段的波动较强,预测效果相对较差),这与波浪的非线性特性紧密相关。一般来说,波浪的非线性越强,神经网络模型的预测精度相应降低^[17]。例如,三种模型对极值点的预测效果较其它位置差,这是因为波浪在此刻变化最剧烈,非线性最强。此外,RNN 和 LSTM 模型对极值点的预测效果较 CNN 更佳(如图 5(a)和(c)所示),说明在重构非线性数据方面,RNN 和 LSTM 模型的性能优于 CNN 模型。鉴于图 4 和图 5 不能直观地量化预测效果,下面将通过误差分析进行细致描述。

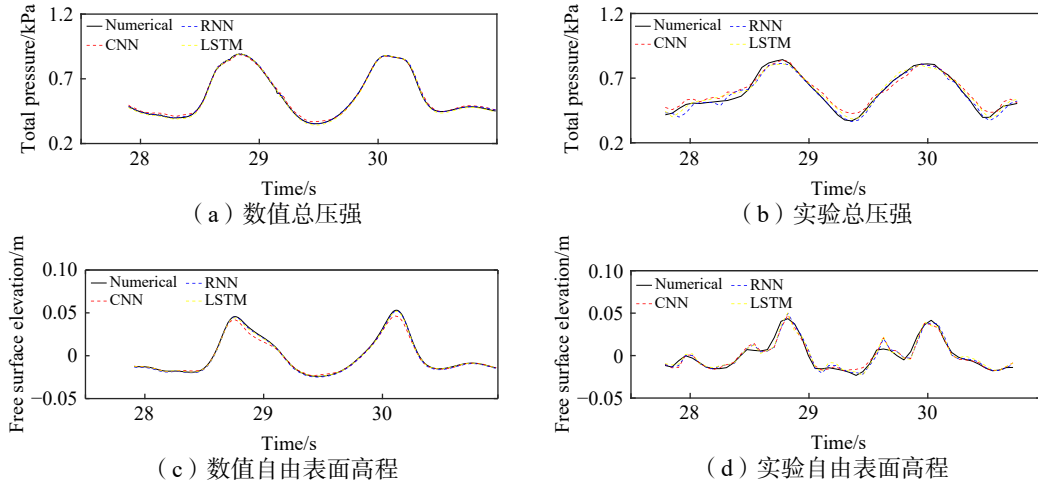


图 5 测试集中三种神经网络模型预测结果与实际值的时程比较

Fig.5 Comparisons of time histories between actual and predicted values from three neural network models in the test set

表 2 列举了训练集和测试集中不同样本预测结果与实际值的均方根误差。可以得出: 对于所有样本, 三种模型的均方根误差均不显著, 说明三者的解算结果均能较好地接近真实数据。在训练集和测试集中, 三种模型的均方根误差相近, 说明通过对样本的训练, 神经网络已经提取到充足的信息, 可以根据学习到的规律比较精确地拟合训练集之外的样本。对于同一样本中的训练集或测试集, 三种模型的均方根误差没有明显的差异。因此在满足精度的前提下, 为了提高计算效率, 可以优先采用 CNN 模型。

表 2 训练集/测试集的预测结果与实际值的均方根误差

Tab.2 Root mean square error between the predicted and actual values in training/test set

样本集类型	CNN模型	RNN模型	LSTM模型
数值总压强	0.0130/0.0131	0.0122/0.0101	0.0102/0.0071
实验总压强	0.0334/0.0231	0.0371/0.0247	0.0373/0.0256
数值自由表面高程	0.0011/0.0019	0.0009/0.0009	0.0007/0.0009
实验自由表面高程	0.0028/0.0040	0.0028/0.0043	0.0028/0.0043

下面具体分析不同样本的均方根误差。对于实验结果, 三种模型的均方根误差十分接近。对于数值结果(其样本容量大于实验结果), RNN 和 LSTM 模型的均方根误差普遍小于 CNN 模型, 主要归结于 RNN 和 LSTM 模型适合处理有长期依赖关系的数据, 而 CNN 模型没有“记忆”效应。因此, 当处理数据量较大的序列时, 如果对预测精度要求高, 可以优先使用 RNN 或 LSTM 模型。此外, 在同一模型中, 数值和实验的自由表面高程的均方根误差总是小于数值和实验的总压强, 这也与流体晃荡的非线性特性密切相关。在自由表面高程和总压强的时程曲线中, 总压强关于平衡位置的不对称性较自由表面高程更为明显, 属于典型的非线性特性。因此, 自由表面高程(非线性较弱)的预测效果好于总压强(非线性较强)是合理的。

综合上述结果可以推断, 三种代理模型的预测效果优异, 均可应用于流体晃荡研究; 对于线性特性较强或容量较小的样本集, 三种模型的预测结果基本无差异; 对于非线性较强或大容量样本集, RNN 和 LSTM 模型比 CNN 模型的预测精度更高。在实际应用中, 可根据不同情况选择对应的代理模型。

3.2 相关性分析

图 6 和图 7 分别展现了训练集和测试集中, CNN、RNN 和 LSTM 预测结果与实际值的交会结果。可以看出: 大部分数据点都集中在理想线附近, 说明预测结果与实际值的相关性良好。此外, 图 6(c)和

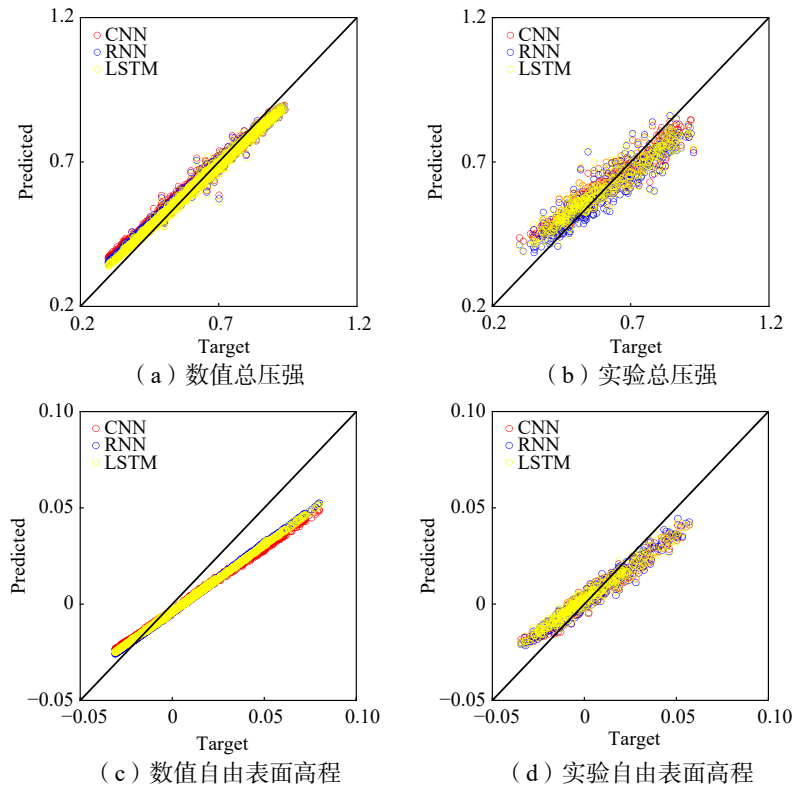


图 6 训练集中三种神经网络模型预测结果与实际值的交会结果

Fig.6 Rendezvous results between actual and predicted values from three neural network models in the training set

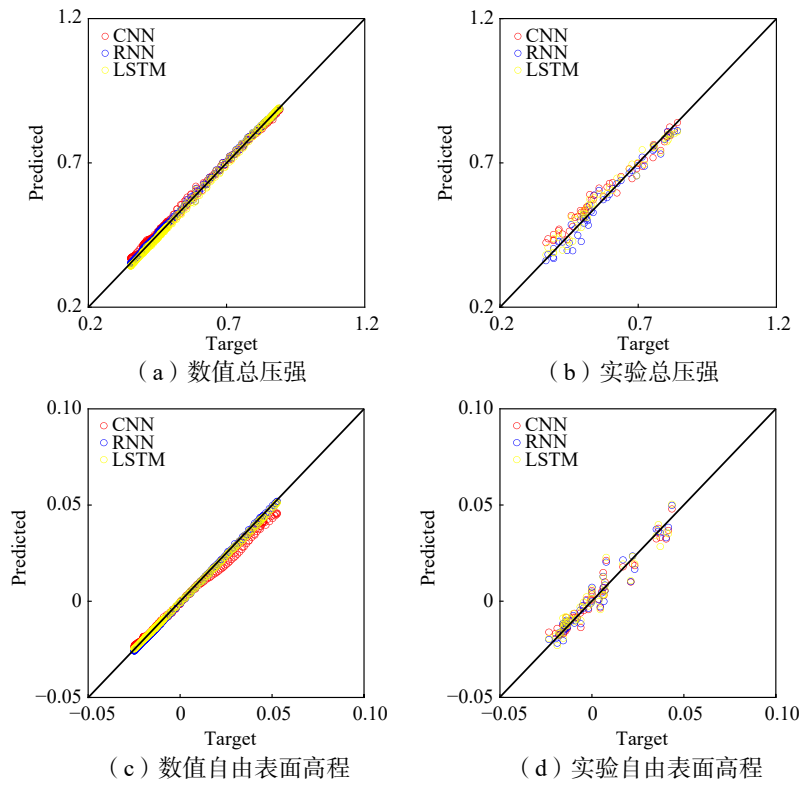


图 7 测试集中三种神经网络模型预测结果与实际值的交会结果

Fig.7 Rendezvous results between actual and predicted values from three neural network models in the test set

图 7(c) 中的数据点与理想线最为接近, 且 CNN 模型数据点偏离理想线的程度略大于 RNN 和 LSTM 模型, 表明对于数值的自由表面高程, 预测结果与实际值的相关性是所有样本中最佳的, 且 RNN 和 LSTM 模型的拟合效果优于 CNN 模型, 主要是因为该样本满足非线性特性显著和容量大的双重特点, 根据 3.1 节的分析, 其预测效果优异是合理的。

对比图 6 和图 7 不难发现: 图 6 中数值和实验总压强的相关性均低于数值和实验的自由表面高程, 而图 7 中数值和实验总压强的相关性高于数值和实验的自由表面高程。从 3.1 节得知, 总压强在平衡位置的不对称性比自由表面高程更强, 非线性特征更为突出, 理论上预测的精度更高, 而图 6 呈现的规律恰好印证了这一结论。尽管图 7 不能印证上述结论, 但不能说明理论推演的失效。潜在原因是测试集的样本量远小于训练集, 不足以体现普遍存在的规律。

为了证明这一规律的普遍性, 下面补充一个样本案例进行说明。我们通过 Fluent 仿真了塔巴斯地震激励(图 8(a))下长度为 20 m、水深为 12 m 的一个液舱内的流体晃动问题, 激发的自由表面高程如图 8(b) 所示。可以发现, 该样本的非线性, 即波峰和波谷的非对称性, 明显强于上述的自由表面高程样本。CNN、RNN、LSTM 三种神经网络模型中的参数设置与前文保持一致。三种模型对训练集和测试集的预测结果与实际值的交会结果分别如图 9 所示。




图 8 时间历程
Fig.8 Time histories

从图 9 可以看出, RNN 和 LSTM 的预测效果明显优于 CNN, 再一次证明了对于非线性较强的数据序列, RNN 和 LSTM 模型的重构能力强于 CNN。将此样本与上述的数值自由表面高程样本的预测结果进行比较, 可以发现此样本数据点偏离理想线的程度更大。以上结果表明, 数据的非线性会显著地影响模型的预测效果。一般而言, 非线性越强, 模型的预测性能越差。

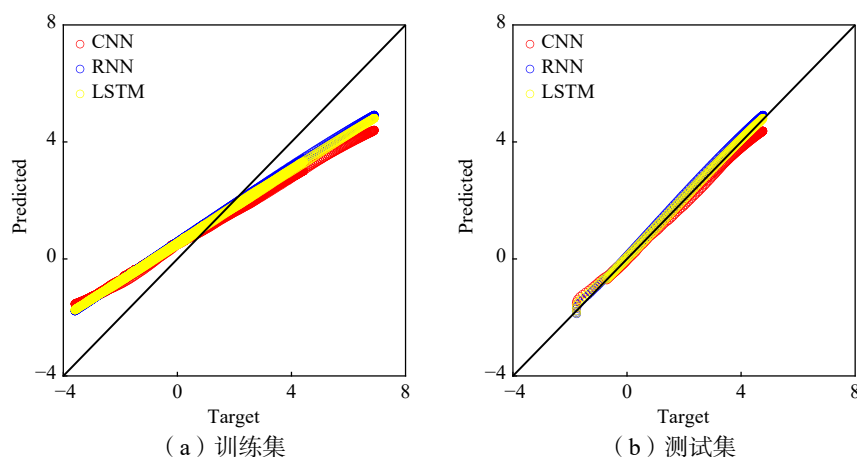


图 9 三种神经网络模型预测结果与实际值的交会结果

Fig.9 Rendezvous results between actual and predicted values from three neural network models

本文还通过拟合优度对预测结果与实际值的相关性进行了量化, 三种模型的拟合优度如表 3 所示。从表中可知, 所有样本的拟合优度均在 0.88 以上, 表明预测结果与实际值的拟合特性较强。尤其

是数值结果的拟合优度均超过了 0.99, 这主要归结于: 随着训练样本量的逐步增大, 神经网络提取到的信息越全面, 模型预测的精准性进一步提高, 可以从数值结果的相关结论印证(其拟合优度近似于 1 且高于实验结果)。此外, 对于数值结果, RNN 和 LSTM 模型的拟合优度大于 CNN 模型, 即相关性强于 CNN 模型, 而对于实验结果则不一定出现此规律。上述讨论结果再次印证了 RNN 和 LSTM 模型在预测长序列数据的准确度方面较 CNN 模型更佳。

表 3 训练集/测试集的预测结果与实际值的拟合优度

Tab.3 Goodness-of-fit between predicted and actual values in training/test set

样本集类型	CNN模型	RNN模型	LSTM模型
数值总压强	0.990 09/0.994 55	0.991 32/0.996 80	0.993 88/0.998 39
实验总压强	0.909 10/0.974 35	0.887 52/0.970 66	0.886 64/0.968 53
数值自由表面高程	0.994 85/0.992 78	0.996 48/0.998 51	0.997 65/0.998 48
实验自由表面高程	0.961 79/0.949 04	0.960 63/0.942 93	0.961 18/0.941 08

4 结 论

本文实现了基于 CNN、RNN 和 LSTM 三种神经网络模型对流体晃荡的总压强和自由表面高程的准确预测。研究表明:

(1)神经网络模型具有预测非线性复杂数据序列的潜力。本文采用的神经网络模型均能精准地捕捉流体晃荡时波高和压强的主要特征, 尽管预测值和真实值存在一定的偏差, 但误差整体较小, 证明了神经网络模型在流体晃荡预测方面的实用性。

(2)样本量对模型预测的准确度有一定影响。对于大容量的数值样本集, RNN 和 LSTM 模型的误差小于 CNN 模型, 相关性强于 CNN 模型, 优于样本量较小的实验样本集, 凸显了 RNN 和 LSTM 模型具有一定记忆功能的优越性。

(3)样本的非线性特性是影响预测精度的重要因素之一。对于数值和实验的总压强, 三种模型的均方根误差均大于 0.005, 反观数值和实验的自由表面高程, 其均方根误差均小于 0.005。本文中总压强时程曲线的非线性特性比自由表面高程更强, 因此预测结果与实际值的偏离程度相对较大。

(4)基于神经网络模型对流体晃荡的波高和压强的时序重构技术, 其花费和预测时间远小于传统的数值模型和模型实验, 有望用于快速准确地研究真实的流体晃荡现象。下一步工作将着重探究神经网络结构参数对预测结果的影响以及如何提高预测的精确度。

参 考 文 献:

- [1] Tao K D, Zhou X Q, Ren H L. The application of an advanced coupled SPH-BEM algorithm to 2D fluid sloshing simulation[J]. *Engineering Analysis with Boundary Elements*, 2022, 138: 280–300.
- [2] Saltari F, Pizzoli M, Gambioli F, et al. Sloshing reduced-order model based on neural networks for aeroelastic analyses[J]. *Aerospace Science and Technology*, 2022, 127: 107708.
- [3] 朱奎松, 赵英涛, 曹丽, 等. 计算流体力学数值计算在化工原理实践课程教学中的应用[J]. *当代化工研究*, 2021(22): 139–141.
Zhu Q S, Zhao Y T, Cao L, et al. Application of computational fluid dynamics numerical calculation in the teaching of chemical engineering principle practice course[J]. *Modern Chemical Research*, 2021(22): 139–141.
- [4] 李裕龙, 朱仁传, 缪国平, 等. 基于 OpenFOAM 的船舶与液舱流体晃荡在波浪中时域耦合运动的数值模拟[J]. *船舶力学*, 2012, 16(7): 750–758.
Li Y L, Zhu R C, Miu G P, et al. Simulation of ship motions coupled with tank sloshing in time domain based on

- OpenFOAM[J]. *Journal of Ship Mechanics*, 2012, 16(7): 750–758.
- [5] Xue M A, Chen Y C, Zheng J H, et al. Fluid dynamics analysis of sloshing pressure distribution in storage vessels of different shapes[J]. *Ocean Engineering*, 2019, 192: 106582.
- [6] Takami T, Ma C. Surrogate model approach for stochastic prediction of sloshing-induced pressure based on SPH with FORM[J]. *Ships and Offshore Structures*, 2023, 18(2): 143–156.
- [7] Peng J Z, Chen S H, Aubry N, et al. Time-variant prediction of flow over an airfoil using deep neural network[J]. *Physics of Fluids*, 2020, 32(12): 123602.
- [8] Huang Y, Zhang Z Y, Zhang X, et al. A direct-forcing immersed boundary method for incompressible flows based on physics-informed neural network[J]. *Fluids*, 2022, 7(2): 56.
- [9] Liu Q, Feng X Y, Tang T N. A machine learning model for wave prediction based on support vector machine[J]. *International Journal of Offshore and Polar Engineering*, 2022, 32(4): 394–401.
- [10] Ye Z T, Shi F Y, Zhao X Z, et al. A data-driven approach to modeling subgrid-scale shallow marsh hydrodynamics[J]. *Coastal Engineering*, 2021, 166: 103856.
- [11] Guo C, Cui S A, Zeng G, et al. Vehicle stochastic response prediction of sea-crossing railway bridges under correlated wind and wave via machine learning[J]. *Ocean Engineering*, 2023, 270: 113714.
- [12] Zhang C P, Li S, Ye M, et al. Learning various length dependence by dual recurrent neural networks[J]. *Neurocomputing*, 2021, 466: 1–15.
- [13] 韩仁坤, 刘子扬, 钱炜祺, 等. 基于深度神经网络的流场时空重构方法[J]. *实验流体力学*, 2022, 36(3): 118–126.
Han R K, Liu Z Y, Qian W Q, et al. Spatio-temporal reconstruction method of flow field based on deep neural network[J]. *Journal of Experiments in Fluid Mechanics*, 2022, 36(3): 118–126. (in Chinese)
- [14] 惠心雨, 袁泽龙, 白俊强, 等. 基于深度学习的非定常周期性流动预测方法[J]. *空气动力学学报*, 2019, 37(3): 462–469.
Hui X Y, Yuan Z L, Bai J Q, et al. A method of unsteady periodic flow field prediction based on the deep learning[J]. *Acta Aerodynamica Sinica*, 2019, 37(3): 462–469. (in Chinese)
- [15] Murata T, Fukami K, Fukagata K. Nonlinear mode decomposition with convolutional neural networks for fluid dynamics[J]. *Journal of Fluid Mechanics*, 2020, 882: A13.
- [16] Liu Y, Hu R, Kraus A, et al. Data-driven modeling of coarse mesh turbulence for reactor transient analysis using convolutional recurrent neural networks[J]. *Nuclear Engineering and Design*, 2022, 390: 111716.
- [17] Meng Z F, Chen Z, Khoo B C, et al. Long-time prediction of sea wave trains by LSTM machine learning method[J]. *Ocean Engineering*, 2022, 262: 112213.
- [18] Puffay C, Vanthornhout J, Gillis M, et al. Robust neural tracking of linguistic speech representations using a convolutional neural network[J]. *Journal of Neural Engineering*, 2023, 20(4): 046040.
- [19] Luan X L, Huang Z L. Stationary random response evaluation of nonlinear oscillators with Preisach hysteresis discretized by RNN model[J]. *International Journal of Non-Linear Mechanics*, 2023, 154: 104449.
- [20] Kumar B, Yadav N. A novel hybrid model combining β SARMA and LSTM for time series forecasting[J]. *Applied Soft Computing*, 2023, 134: 110019.
- [21] Hasegawa K, Fukami K, Murata T, et al. Machine-learning-based reduced-order modeling for unsteady flows around bluff bodies of various shapes[J]. *Theoretical and Computational Fluid Dynamics*, 2020, 34(4): 367–383.
- [22] Chegini H G, Zarepour G. Numerical study of rectangular tank with sloshing fluid and simulation of the model using a machine learning method[J]. *Geofluids*, 2022, 2022: 4121956.
- [23] Xie C, Liu X D, Man T H, et al. PWPNet: A deep learning framework for real-time prediction of significant wave height distribution in a port[J]. *Journal of Marine Science and Engineering*, 2022, 10(10): 1375.
- [24] Aurelio Y S, Almeida G M, Castro C L, et al. Learning from imbalanced data sets with weighted cross-entropy function[J]. *Neural Processing Letters*, 2019, 50(2): 1937–1949.
- [25] Moslemi M, Farzin A, Kianoush M R. Nonlinear sloshing response of liquid-filled rectangular concrete tanks under seismic excitation[J]. *Engineering Structures*, 2019, 188: 564–577.
- [26] 吴婷婷, 许晓东, 吴云龙. 卷积神经网络中 SPReLU 激活函数的优化研究[J]. *计算机与数字工程*, 2021, 49(8):

1637–1641.

Wu T T, Xu X D, Wu Y L. Research on optimization of SPReLU activation function in convolutional neural network[J]. *Computer & Digital Engineering*, 2021, 49(8): 1637–1641. (in Chinese)

[27] Niroomand M P, Morgan J W R, Cafolla C T, et al. On the capacity and superposition of minima in neural network loss function landscapes[J]. *Machine Learning: Science and Technology*, 2022, 3(2): 025004.

[28] Xue M A, Chen Y, Zheng J, et al. Fluid dynamics analysis of sloshing pressure distribution in storage vessels of different shapes[J]. *Ocean Engineering*, 2019, 192: 106582.

[29] Jin X, Xue M A, Lin P Z. Numerical modeling and formulation of the runup of seismically-induced surge waves in idealized reservoirs[J]. *Soil Dynamics and Earthquake Engineering*, 2021, 143: 106625.

[30] 陈先来, 杨路明. 基于均矢量相似性的机器学习样本集划分[J]. *中南大学学报(自然科学版)*, 2009, 40(6): 1636–1641.

Chen X L, Yang L M. Partitioning machine learning sample set using similarity to mean vector[J]. *Journal of Central South University (Science and Technology)*, 2009, 40(6): 1636–1641. (in Chinese)