

侯建康, 程永舟, 王敦格, 等. 规则波作用下双桩基础周围海床超孔隙水压力智能预测[J]. 海洋学报, 2026, 48(x): 1–13. doi:  
Hou Jiankang, Cheng Yongzhou, Wang Dunge, et al. Intelligent prediction of excess pore water pressure of seabed around double pile foundation under the action of regular wave[J]. Haiyang Xuebao, 2026, 48(x): 1–13. doi:

# 规则波作用下双桩基础周围海床超孔隙水压力 智能预测

侯建康<sup>1</sup>, 程永舟<sup>1,2\*</sup>, 王敦格<sup>1</sup>, 韩小锐<sup>1</sup>, 李沅龙<sup>1</sup>, 石一<sup>1</sup>

(1. 长沙理工大学水利与海洋工程学院, 湖南 长沙 410114; 2. 水沙科学与水灾害防治湖南省重点实验室, 湖南 长沙 410114)

**摘要:** 本研究针对波浪作用下双桩基础周围海床超孔隙水压力预测问题, 开展了多目标智能预测研究。首先, 通过波浪水槽试验, 分析了不同波高条件下双桩基础周围海床超孔隙水压力时程演化和空间分布规律。其次, 采用相位滞后检测与动态对齐方法对数据进行预处理, 并分别利用 GRU 和 ELM 神经网络进行训练预测。最后, 采用动态误差择优融合方法对两项模型的输出进行融合。结果表明: 在当前试验条件下, 随着波高增加, 双桩基础周围海床超孔隙水压力幅值显著增大, 沿深度方向呈现出明显的幅值衰减和相位滞后现象, 且双桩基础周围超孔隙水压力最大幅值存在明显的空间差异。此外, 构建的融合模型相较于原始模型或单一模型评估指标表现最优, 其中  $PCC$  为 0.982 7,  $NSE$  为 0.921 8,  $RMSE$  为 0.330 5%,  $MAE$  为 0.255 9%。研究成果为波浪作用下桩基周围海床多目标孔压智能预测提供了一种有效途径。

**关键词:** 双桩基础; 超孔隙水压力; 相位滞后检测; 动态误差; 融合模型

中图分类号: 文献标志码: A 文章编号: 0253-4193(2026)x-0001-13

## 1 引言

随着全球能源结构转型与海洋经济的蓬勃发展, 海上光伏、海上平台、跨海桥梁等重大海洋工程的建设规模持续扩大。多桩基础作为支撑海上构筑物的核心基础形式<sup>[1-2]</sup>, 凭借稳定性高、可靠性强、承载面积大、适应复杂环境等显著优势, 在海洋工程领域得到广泛应用<sup>[3-5]</sup>。然而, 在复杂的海洋动力环境中, 多桩基础需长期承受波浪荷载, 这易引发桩基周围海床超孔隙水压力急剧变化, 导致海床承载力下降, 从而威胁结构的整体安全与稳定。因此, 准确预测波浪作用下多桩基础周围海床超孔隙水压力演变趋势, 对于评价非液化状态下海床稳定, 保障海洋工程结构的长

期安全运行具有重要意义。

目前, 许多学者对波浪荷载作用下桩基周围海床动态响应开展诸多研究。例如, Wang 等<sup>[6]</sup>探讨了波浪作用下单桩周围海床动态响应特征, 指出孔隙水压力随波高和波周期的增大而增加, 且其空间分布受波浪影响显著。Zhang 等<sup>[7]</sup>对波浪作用下单桩周围海床动态响应进行了研究, 发现波高和周期增大会显著提升桩周孔隙水压力, 且最大孔隙水压力随海床深度增加而衰减。郑余伟等<sup>[8]</sup>研究了波浪作用下斜坡上单桩周围海床动力响应特性, 发现桩周不同位置孔隙水压力幅值存在明显差异, 且桩前孔隙水压力最大幅值明显大于桩侧与桩后。此外, Asumadu 等<sup>[9]</sup>通过数值模拟指出, 波浪荷载会显著影响单桩基础的结构位移与

收稿日期: 2026-03-08; 修订日期: 2026-05-12。

基金项目: 国家自然科学基金 (52371258); 湖南省研究生科研创新项目 (CX20251352)。

作者简介: 侯建康 (1995—), 男, 河南周口人, 博士研究生, 主要从事港口、海岸及近海工程研究。E-mail: 24904030111@csust.edu.cn

\* 通信作者: 程永舟, 男, 教授, 主要从事港口、海岸及近海工程研究。E-mail: chengyongzhou@163.com

摇摆运动,进而引发海床响应剧烈变化。Cheng等<sup>[10]</sup>针对聚焦波作用下单桩基础周围海床响应进行了模拟,发现聚焦波峰的瞬时冲击会导致结构振动,并显著改变单桩基础周围海床响应规律。

随着人工智能技术的快速发展,机器学习与深度学习已广泛应用于复杂海洋工程问题的研究中。例如,秦知朋等<sup>[11]</sup>构建了一种贝叶斯优化长短期记忆神经网络模型,实现了对单一站点台风浪波高的快速智能预报。Wang等<sup>[12]</sup>提出了一个融合时间卷积网络、门控循环单元与注意力机制的预测框架,该框架能够对短期波高进行准确预测。Firat与Gungor<sup>[13]</sup>采用广义回归神经网络和前馈神经网络对圆形桥墩周围冲刷深度进行预测研究,发现广义回归神经网络具有更好的预测性能。Zhang等<sup>[14]</sup>建立了一种基于模拟退火算法与集成学习方法的预测模型,可有效预测圆柱桩周围局部冲刷深度。Du等<sup>[15]</sup>采用RNN、LSTM和GRU三种网络模型对波浪引起的海床孔隙水压力进行预测,结果表明三种模型均能有效预测,其中GRU模型的精度最高。Cheng等<sup>[16]</sup>基于机器学习和深度学习模型构建了端到端的波(流)导致孔隙水压力响应预测框架,发现门控循环单元能够较好预测单桩基础周围孔隙水压力响应。

综合上述研究可以看出,目前针对波浪作用下单桩基础周围海床动力响应的研究相对较多。然而,对于波浪与多桩结构耦合作用下海床动力响应机制尚缺乏深层次的解析。此外,深度学习和机器学习技术已在海洋工程中得到广泛应用,为多桩基础周围海床响应多目标预测提供了可行的技术途径。为此,本研究基于波浪水槽试验,建立了规则波与双桩耦合物理模型,重点分析了波高对双桩基础周围海床超孔隙水压力的影响规律。同时,基于试验获取的波高与超孔隙水压力时序数据,引入相位滞后检测与动态对齐方法,并结合GRU和ELM模型预测动态误差择优融合策略,构建了一种新的融合预测模型。该研究成果为波浪作用下多桩基础周围海床响应预测提供了一种创新且有效的分析方法,也为保障近海结构物的安全稳定运行提供了重要参考。

## 2 试验与方法

### 2.1 试验布置

试验主要在长沙理工大学港航中心波浪水槽内进行,水槽总长60 m,宽1.5 m,高1.8 m,侧壁为钢化透明玻璃。水槽中段底部布置有长4.5 m,宽1.5 m,高0.6 m的沙槽。波浪水槽首端设有造波系统,末端

设有消波区。沙槽中央埋置 $D = 0.09$  m的双钢管桩,壁厚3.0 mm,埋置深度0.55 m,桩间距 $G = 2D$ <sup>[17]</sup>,双桩结构之间采用固定螺杆进行连接。受试验条件的限制,采用变形挠度较小的钢管桩。考虑近海桩基实际尺度与水深,模型试验中桩直径与水深遵循1:100相似准则进行缩放尺度设计<sup>[18]</sup>。海床沙参数为浮容重 $9.07$  KN/m<sup>3</sup>、中值粒径0.334、孔隙比0.784 mm、孔隙率0.439、相对密实度0.343、渗透系数 $1.31 \times 10^{-4}$  m/s<sup>[16]</sup>。试验中,波浪水槽宽度 $B = 1.5$  m与钢管桩直径 $D = 0.09$  m之比远大于6,因此可以忽略边壁效应对双桩基础周围流场的干扰。试验开始前整平沙床,再缓慢注水至0.3 m位置处,静水浸泡72 h以上,使沙床达到准饱和状态<sup>[19-20]</sup>。双桩基础前侧0.09 m、中间和后侧0.09 m,距海床表面0.04 m、0.08 m、0.14 m和0.20 m位置处分别布置YPS300-L数字压力传感器,量程0~50 KPa,测量精度达到0.1%,采集频率为50 Hz。此外,在双桩基础周围分别布置DYD300数字浪高仪,测量点分别位于双桩前侧3.0 m(1#)、0.5 m(2#)、双桩侧面0.3 m(3#)和双桩后侧0.5 m(4#),采样频率为50 Hz,精度可达0.2%。试验入射波高和周期分别设置为0.02 m、0.04 m、0.06 m、0.08 m和1.2 s<sup>[21]</sup>。试验布置如图1所示。

### 2.2 预测方法

#### 2.2.1 相位滞后检测与动态对齐

针对双桩基础周围海床中测得的超孔隙水压力数据与波高数据之间存在显著的相位滞后,且该滞后程度随测点位置与深度的不同呈现明显差异。若直接采用未处理的波高和超孔压时序数据进行神经网络训练,容易导致模型难以捕捉准确的动态对应关系,从而造成预测精度下降与泛化能力受限等。为此,本研究创新性地提出了一种相位滞后检测与动态对齐方法。该方法以波高时序数据作为参考依据,不同深度及位置的超孔隙水压力时序数据作为检测与对齐目标,通过计算不同滞后步数下的相关系数来衡量波高与超孔压之间的线性相关性,并以最大相关系数绝对值作为判断准则确定最优滞后步数,根据最优滞后步数对超孔隙水压力时序数据进行平移,为保证所有对齐后的数据具有相同的有效长度,以所有时序数据中最短的作为截断范围,进而实现波高与超孔隙水压力之间的动态对齐。计算流程如图2所示。

其中,最优滞后步数 $\tau_i$ 通过最大相关系数的绝对值确定,其计算公式如(1)所示:

$$\tau_i = \arg \max_{\tau \in [-L, L]} |\rho_i(\tau)| \quad (1)$$

式中, $L$ 为最大滞后步数; $\rho_i(\tau)$ 为最大相关系数,主要

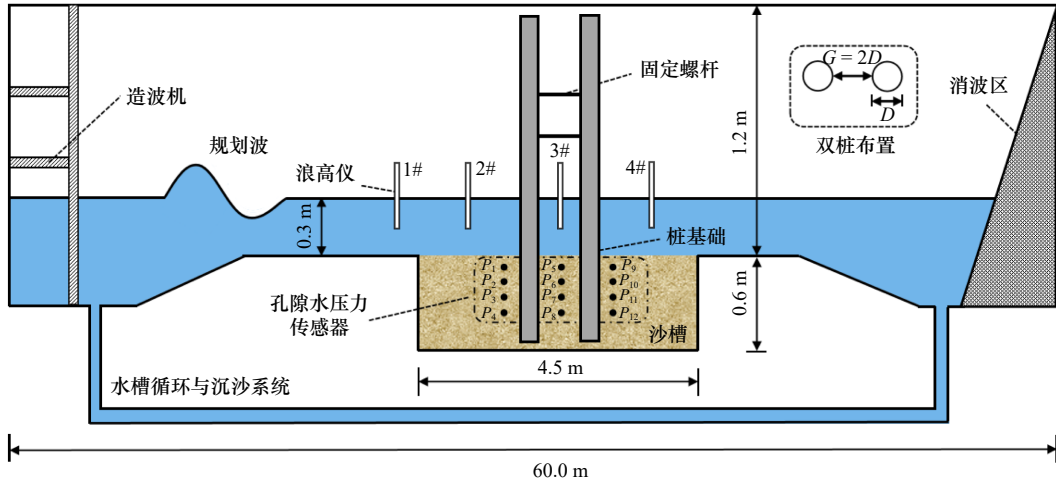


图 1 试验布置示意图

Fig. 1 Schematic diagram of test arrangement




图 2 相位滞后检测与动态对齐流程图

Fig. 2 Phase lag detection and dynamic alignment flow chart

采用皮尔逊相关系数计算波高与超孔压时序数据之间的相关程度,其计算公式参考(9)。根据最优滞后步数  $\tau_i$ ,对每个超孔压时序数据进行位移,其公式如(2)所示:

$$z_i(t) = y_i(t + \tau_i) \quad (2)$$

式中,  $z_i$  为第  $i$  个测点位移后超孔压时序数据;  $y_i$  为第  $i$  个测点超孔压时序数据; 当  $\tau_i > 0$  时往前位移, 当  $\tau_i < 0$  时往后位移, 当  $\tau_i = 0$  时无位移。而位移后每个时序数据有效长度如(3)所示:

$$Length_i = N - |\tau_i| \quad (3)$$

式中,  $N$  为超孔压时序数据长度; 从所有位移后的数据中选择有效长度最短的序列作为基准, 其公式如(4)所示:

$$k = \arg \min_{i \in [1, 12]} Length_i \quad (4)$$

式中,  $k$  为最短超孔压序列测点; 根据最短序列有效长度, 将所有位移后的超孔压时序数据和波高时序数据与最短序列重叠部分进行截取处理, 最终得到对齐后的波高与超孔压时序数据。

### 2.2.2 GRU 网络模型

门控循环单元 (GRU)<sup>[22-23]</sup> 是一种常用于处理序列信息的神经网络模型, 其核心思想是通过引入更新门与重置门来调控信息在单元内的传递过程, 如图 3 所示。更新门决定是否更新当前时间步的隐藏状态, 重置门决定是否忽略历史输入并重新初始化隐藏状态<sup>[24]</sup>, 该机制能够有效降低计算复杂度, 提升计算效率。

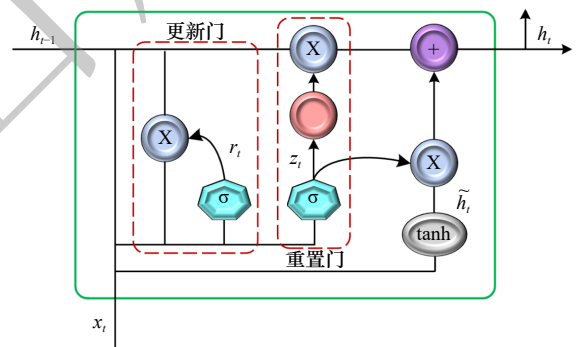


图 3 GRU 网络结构

Fig. 3 GRU network structure

### 2.2.3 ELM 网络模型

极限学习机<sup>[25-27]</sup> 是一种具有单隐藏层的前馈神经网络模型, 训练时无须调整输入层与隐含层的连接权值和隐含层神经元的偏置, 因此具有高效且简洁的学习过程。其核心结构主要包含输入层、隐含层和输出层, 如图 4 所示。




图 4 ELM 网络结构

Fig. 4 ELM network structure

### 2.2.4 动态误差择优融合

尽管 GRU 模型与 EMD 模型已在海洋工程领域得到广泛应用,但在预测波浪作用下双桩基础周围 seabed 超孔隙水压力时,单一模型往往难以全面捕捉波浪与超孔隙水压力之间的内在波动关联。为弥补单一模型存在的局限性,进一步提升预测精度与可靠性,本研究提出一种动态误差择优融合方法,其具体计算流程如下。

首先,计算两种模型的绝对预测误差,计算公式如(5)和(6)所示:

$$e_i^{GRU}(t) = |y_i^{GRU}(t) - x_i(t)| \quad (5)$$

$$e_i^{ELM}(t) = |y_i^{ELM}(t) - x_i(t)| \quad (6)$$

式中,  $y_i^{GRU}(t)$  为 GRU 模型预测值;  $y_i^{ELM}(t)$  为 ELM 模型预测值;  $x_i(t)$  为实际值。

其次,构建绝对误差定义择优函数  $f_i(t)$ ,根据最小误差原则动态选择最优预测值:

$$f_i(t) = \begin{cases} 1, & e_i^{GRU}(t) \leq e_i^{ELM}(t) \\ 2, & e_i^{GRU}(t) > e_i^{ELM}(t) \end{cases} \quad (7)$$

式中,  $f_i(t) = 1$  为选择 GRU 预测值;  $f_i(t) = 2$  为选择 ELM 预测值。

最后,基于择优函数,确定最优融合预测值  $\tilde{z}_i(t)$ :

$$\tilde{z}_i(t) = \begin{cases} y_i^{GRU}(t), & f_i(t) = 1 \\ y_i^{ELM}(t), & f_i(t) = 2 \end{cases} \quad (8)$$

### 2.2.5 预测精度评估指标

为了量化融合模型对规则波作用下双桩基础周围 seabed 超孔隙水压力整体预测精度,采用皮尔逊相关系数  $PCC$  (Pearson Correlation Coefficient)、纳什效率系数  $NSE$  (Nash-Sutcliffe Efficiency)、均方根误差  $RMSE$  (Root Mean Square Error) 和平均绝对误差  $MAE$  (Mean Absolute Error) 作为预测精度评价指标<sup>[28-29]</sup>,衡量融合模型超孔隙水压力预测值与实际值之间的拟合优度。评估指标见公式(9)~(12)。

$$PCC = \frac{\sum_{i=1}^n (z_i - \bar{z}_i)(\tilde{z}_i - \hat{z}_i)}{\sqrt{\sum_{i=1}^n (z_i - \bar{z}_i)^2 \sum_{i=1}^n (\tilde{z}_i - \hat{z}_i)^2}} \quad (9)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (z_i - \hat{z}_i)^2}{\sum_{i=1}^n (z_i - \bar{z}_i)^2} \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (z_i - \tilde{z}_i)^2} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |z_i - \tilde{z}_i| \quad (12)$$

式中,  $z_i$  为超孔隙水压力实际值;  $\tilde{z}_i$  为超孔隙水压力预测值;  $\bar{z}_i$  实际超孔隙水压力平均值;  $\hat{z}_i$  为预测超孔隙水压力平均值。

### 2.2.6 融合预测模型框架

本研究提出了一种用于预测波浪作用下双桩基础周围 seabed 多目标超孔隙水压力的融合模型框架。具体预测流程如下:

(1) 选取波高 0.06m 工况下 #1 浪高仪与 12 个孔压测点的历时测量数据,通过相位滞后与动态对齐方法对波高与超孔压数据进行预处理。

(2) 将预处理后的波高和超孔压共计 26 000 个数据样本按照 7:3 的比例划分训练集和测试集,并通过归一化将数据映射至 [0, 1] 区间,其中波高为输入变量,12 个超孔压为目标变量。

(3) 将归一化后的波高与孔压数据分别输入到 GRU 和 ELM 模型中进行训练,同时输出 12 个超孔压预测结果,其中时间窗长度设置为 1,输入步长设置 1,隐藏单元数设置为 64,激活函数设置为 tanh,优化器设置为 rmsprop,最小批量设置为 128,迭代次数设置为 100,初始学习率设置为 0.005,丢弃概率设置为 0.3。

(4) 将预测后的数据进行反归一化处理,并采用皮尔逊相关系数  $PCC$ 、纳什效率系数  $NSE$ 、均方根误差  $RMSE$ 、平均绝对误差  $MAE$  和绝对误差等多个指标,对融合模型的预测性能进行量化评估。

## 3 结果与分析

### 3.1 双桩基础周围波面形态特征

图 5 为不同波高条件下桩前、桩侧和桩后波面历时曲线。从图中可以看出,随着波高由低向高增加,其波面呈现出不同的波动形态。当波高较小时,波浪




图 5 不同波高面历时曲线 (a: #1=3.0 m; b: #2=0.5 m; c: #3=0.3 m; d: #4=0.5 m)

Fig. 5 Different wave height surface duration curves (a: #1=3.0 m; b: #2=0.5 m; c: #3=0.3 m; d: #4=0.5 m)

荷载输出的能量效应相对较弱,波峰与波谷起伏形态相对平缓。随着波高的增大,波浪荷载输出的能量逐渐增强,波峰与波谷起伏形态发生显著变化,波峰逐渐变陡。同时,从图 5 中还可以看出,在桩前 2#处和桩侧 3#处,波谷和波峰出现小幅度的次生波动,这是因为波浪在传播过程中遇到双桩

这一直立障碍物时,部分波浪能量会形成反射波,与后续传来的入射波之间产生复杂的非线性叠加

与干涉作用。这种波与波之间的相互作用,会导致波谷或波峰形态产生变形,从而形成可见的次生波动。

相比之下,在桩前 1#和桩后 4#处,波浪的绕射与遮蔽效应占主导,其波面形态受反射干涉的影响相对较弱,波峰和波谷形态相对规则。这些结果表明,波高对双桩周围波浪场形态的扰动具有显著的差异性。

### 3.2 双桩基础周围海床超孔压历时特征

图 6 为规则波作用下双桩基础前侧海床超孔压历时曲线。从图中可以看出,超孔隙水压力响应沿海




图 6 前侧超孔隙水压力历时曲线 (a: 0.02 m; b: 0.04 m; c: 0.06 m; d: 0.08 m)

Fig. 6 Front side excess pore water pressure duration curve (a: 0.02 m; b: 0.04 m; c: 0.06 m; d: 0.08 m)

床深度方向均呈现出明显的幅值衰减和相位滞后现象,且随着波高的增加超孔压响应均呈现出明显增大趋势,浅层超孔压幅度波动最为剧烈,深层超孔压幅度波动相对平缓。这主要是因为沙质海床在循环荷载作用下的能量耗散与传递机制所致。沙质海床内部存在的摩擦阻尼与粘滞效应会吸收并耗散部分波动能量,导致超孔压幅值沿深度方向增加而衰减。同时,沙质海床的渗透性与压缩性致使孔隙水的排出和压力传递需要时间,从而导致海床深层超孔压响应滞后于浅层。此外,波动能量的传递并非均匀,海床浅层能够更直接地受到波压力的周期性作用,而海床深层由于受到能量耗散的影响,超孔压幅值沿深度方向逐渐减弱,从而形成“浅层超孔压强、深层超孔压弱”的分布特征。

### 3.3 双桩基础周围海床超孔压最大幅值对比

图 7 为规则波作用下双桩基础周围超孔隙水压力最大幅值分布情况。从图中可以看出,最大幅值随着波高的增强呈整体增大趋势。这主要是因




图 7 超孔压最大幅值对比  
Fig. 7 Comparison of the maximum amplitude of excess pore pressure

为随着波高的提升,输出的波浪能量显著增强,传递给海床上的波动压力显著增大。尤其是在海床浅层,受到的约束程度较低、渗透性较好,且紧邻波致压力的直接作用,致使最大幅值变化最为显著。同时,在当前试验条件下,当波高分别为 0.02 m、0.04 m、0.06 m 和 0.08 m 时,  $P_1$  最大幅值分别为 0.0266 KPa、0.0516 KPa、0.0874 KPa 和 0.1128 KPa;  $P_5$  最大幅值分别为 0.0262 KPa、0.0499 KPa、0.0786 KPa 和 0.0985 KPa;  $P_9$  最大幅值分别为 0.0349 KPa、0.0635 KPa、0.0999 KPa 和 0.1321 KPa。通过分析  $P_1$ 、 $P_5$  和  $P_9$  超孔压最大幅值,可以发现随着波高的增加,距双桩壁 0.09 m 不同位置超孔压最大幅值存在明显空间差异性。这主要是因为桩前直接承受入射波作用,并受到桩体反射波的影响;桩间受两侧桩体约束,并受绕射波与反射波相互干扰;桩后受双重遮蔽效应影响,并受双桩绕射产生的波动作用,从而导致双桩基础周围最大幅值变化呈现出显著不同。

### 3.4 相位滞后检测与动态对齐结果与分析

图 8 为入射波高 0.06 m 工况下, #1 浪高仪测得的波高与不同测点超孔压历时演变曲线。从图 8 可以看出,双桩基础周围超孔压幅值显著滞后于 #1 波高,这主要是因为孔压传感器布置在 #1 浪高仪之后,导致采集信号存在明显滞后。为此,本研究提出了一种相位滞后检测与动态对齐方法,处理结果如表 1 所示。表 1 给出了波浪与超孔压之间的最大相关系数及最优滞后步数,其中双桩基础前侧  $P_2$  最大相关系数为 0.986 5,最优滞后步数为 9;  $P_4$  最大相关系数为 0.786 9,最优滞后步数为 20。双桩基础中间  $P_5$  最大相关系数为 0.988 6,最优滞后步数为 12;  $P_8$  最大相关系数为 0.874 9,最优滞后步数为 35。双桩基础后侧  $P_9$  最大相

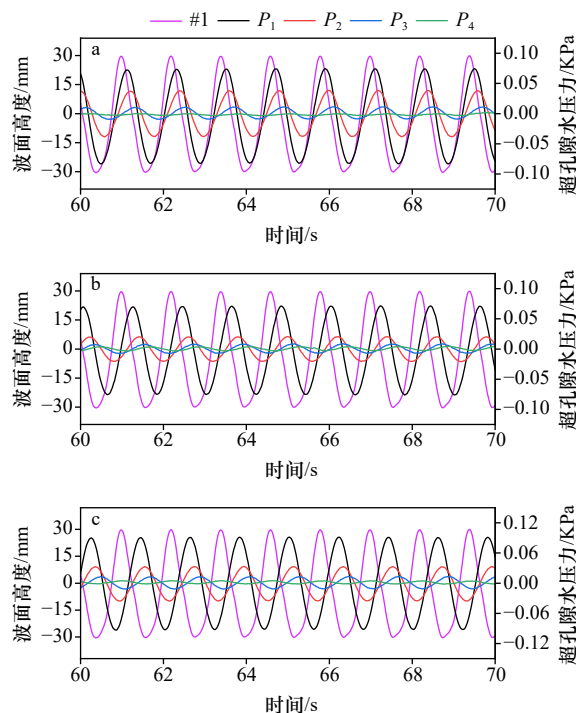


图 8 实际波高与超孔压 (a: 前侧; b: 中间; c: 后侧)  
Fig. 8 Actual wave height and excess pore pressure (a: front side; b: intermediate; c: rear side)

表 1 最大相关系数与最优滞后步数

Table 1 Maximum correlation coefficient and optimal lag step

孔压测点	最大相关系数	最优滞后步数
$P_1$	0.985 9	5
$P_2$	0.986 5	9
$P_3$	0.976 3	15
$P_4$	0.786 9	20
$P_5$	0.988 6	12
$P_6$	0.987 2	20
$P_7$	0.975 1	26
$P_8$	0.874 9	35
$P_9$	0.986 3	21
$P_{10}$	0.985 6	26
$P_{11}$	0.975 2	33
$P_{12}$	0.959 7	39

关系数为 0.986 3,最优滞后步数为 21;  $P_{12}$  最大相关系数为 0.959 7,最优滞后步数为 39。图 9 为相位滞后检测与动态对齐后的波高与超孔压历时曲线,结果表明,对齐后超孔压与波高的变化形态具有高度一致性。

### 3.5 动态误差择优融合结果与分析

图 10 为融合模型绝对误差累计曲线。从图中




图 9 动态对齐后波高与超孔压(a: 前侧; b: 中间; c: 后侧)

Fig. 9 Wave height and excess pore pressure after dynamic alignment (a: front side; b: intermediate; c: rear side)

可以看出, 融合模型累计绝对误差显著低于单一 ZDGRU 模型与 ZDELML 模型。同时, 对比  $P_1$ 、 $P_5$  和  $P_9$  三个位置的累计绝对误差可以发现, 误差呈现明显的分布规律, 即桩后最小、桩中间次之、桩前最大。此外, 图 10 中同时给出了基于动态模型选择的累计绝对误差贡献分布直方图(每隔 20 个数据点选取 1 个绝对误差进行展示)。从图中可以看出, 双桩基础前侧超孔压预测中, 融合模型中的 ZDGRU 模型累计绝对误差贡献显著高于 ZDELML 模型; 进一步对比  $P_1$ 、 $P_5$  和  $P_9$  三个位置的累计绝对误差贡献可知, ZDGRU 模型与 ZDELML 模型累计绝对误差贡献存在显著差异, 其中桩后 ZDELML 模型累计绝对误差贡献最大, 而桩中间 ZDGRU 和 ZDELML 模型累计绝对误差贡献相对均衡。

### 3.6 融合模型预测结果与分析

#### 3.6.1 融合模型预测误差对比

为了分析融合模型对波浪作用下双桩基础周围超孔隙水压力预测能力, 绘制了融合模型预测绝

对误差随时间变化的历时曲线, 如图 11 所示。从图中可以看出, 融合模型的预测绝对误差整体更靠近零点, 尤其是在超孔压幅值变化最为剧烈的波峰与波谷位置, 其绝对误差相对较小。同时, 融合模型预测绝对误差整体波动幅度显著小于原始模型以及单

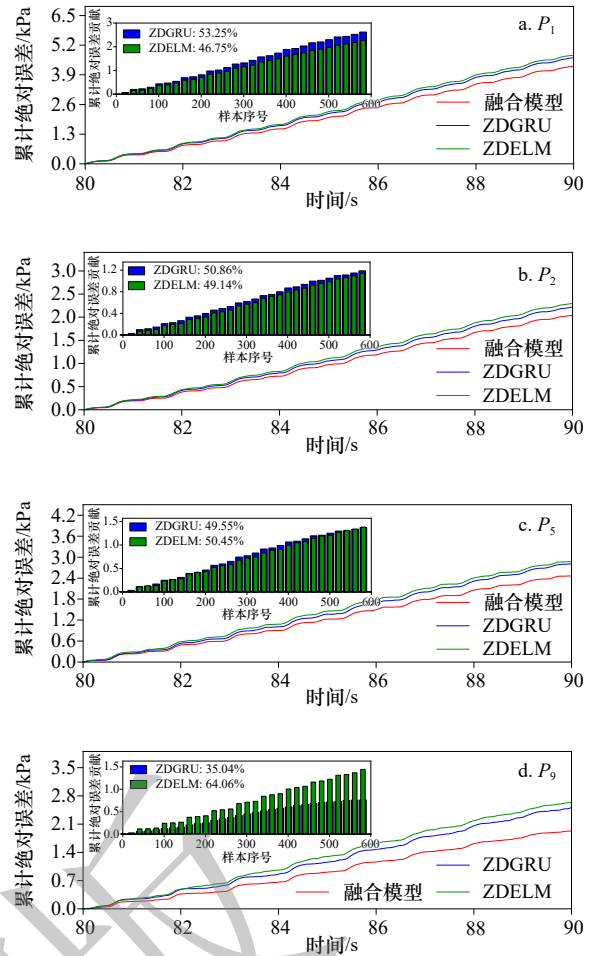


图 10 融合模型累计绝对误差对比(a:  $P_1$ ; b:  $P_2$ ; c:  $P_5$ ; d:  $P_9$ )

Fig. 10 Comparison of cumulative absolute error of fusion model (a:  $P_1$ ; b:  $P_2$ ; c:  $P_5$ ; d:  $P_9$ )

一 ZDGRU 模型和 ZDELML 模型。其中, 原始 GRU 模型与 ELM 模型的预测绝对误差波动幅度最为剧烈, 主要在于原始模型未考虑超孔压与波高

之间的相位滞后问题, 无法精准捕捉超孔压的时序演变特征; 而相位滞后检测与动态对齐后的单一 ZDGRU 模型和 ZDELML 模型预测绝对误差波动幅得到大幅降低, 但仍明显大于融合模型, 主要在于单一模型的预测能力存在局限性, 无法全面适用于双桩基础周围不同位置超孔压的复杂变化规律。此外, 从图 12 绝对误差箱型分布中可以进一步看出, 融合模型的绝对误差箱型指标更加靠近零点, 预测误差更集中且离散性更小。与原始 GRU、原始 ELM、ZDGRU 和 ZDELML 模型相比, 融合模型的绝对误差均值、中位数及箱体位置均处于较低水平。以上研究表明, 采用相位滞后检测与动态对齐方法, 可有效改善超孔压与波高之间的相位滞后效应, 同时对 ZDGRU 和 ZDELML 模型进行动态误差择优融合, 能够充分发挥

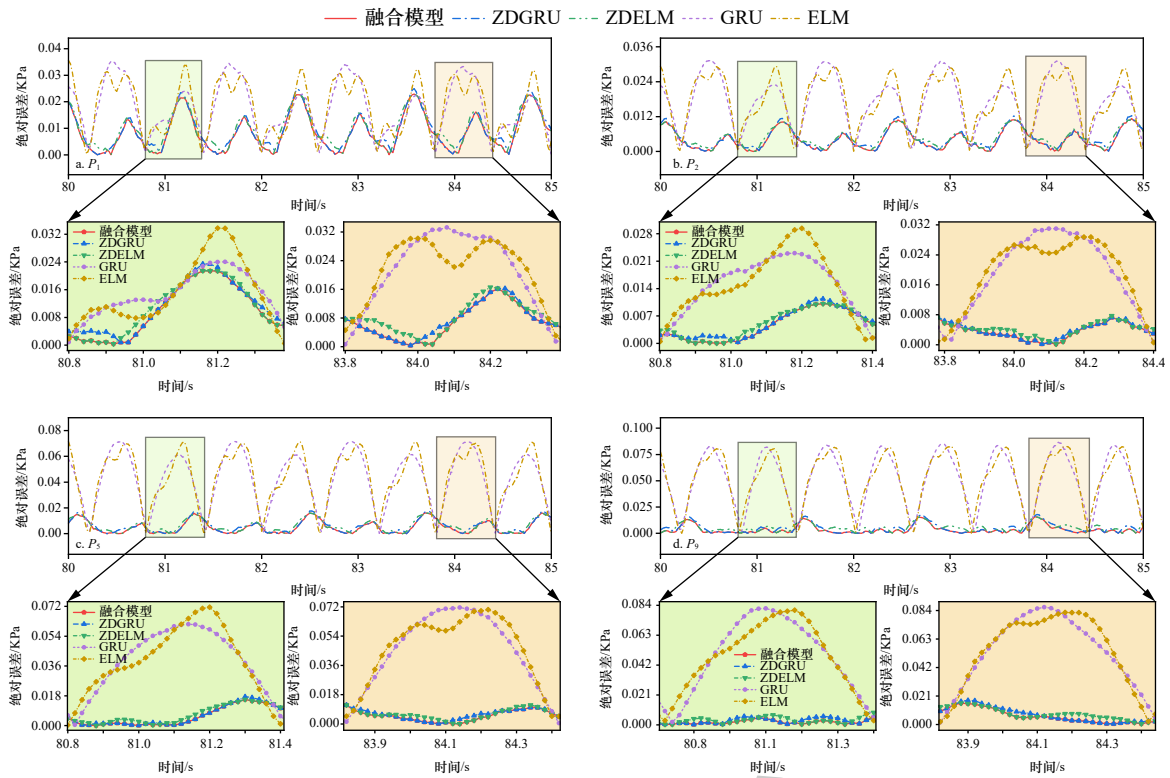


图 11 绝对误差演变曲线 (a:  $P_1$ ; b:  $P_2$ ; c:  $P_5$ ; d:  $P_9$ )  
 Fig. 11 Absolute error evolution curve (a:  $P_1$ ; b:  $P_2$ ; c:  $P_5$ ; d:  $P_9$ )

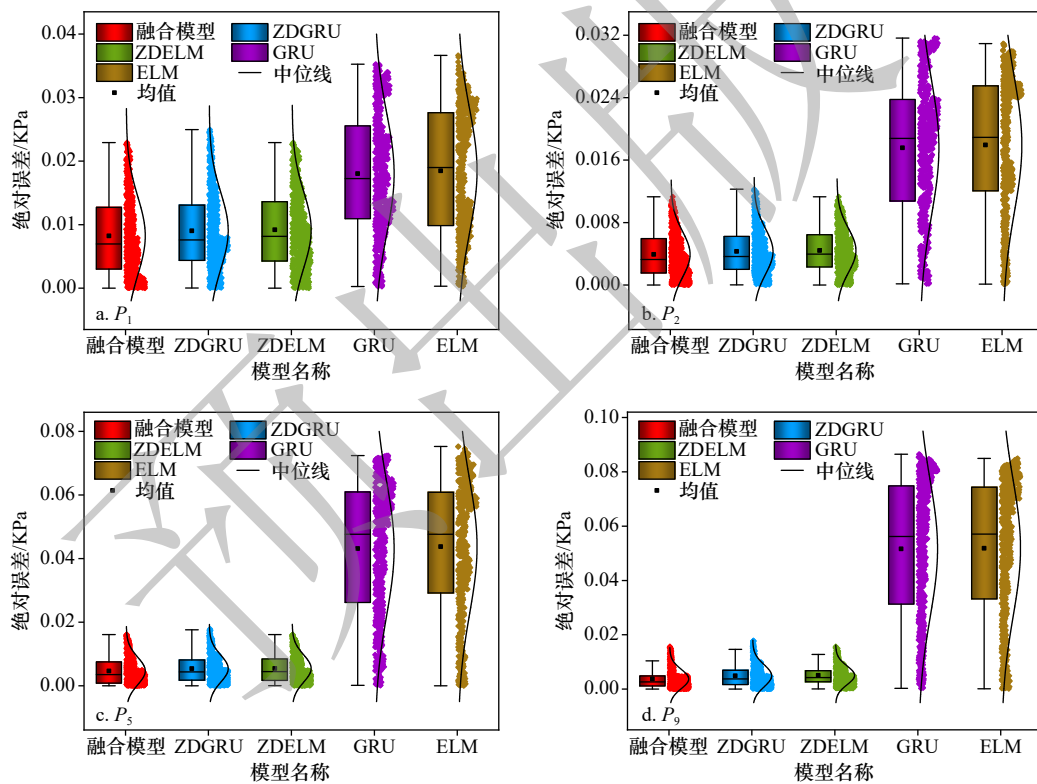


图 12 绝对误差箱型分布 (a:  $P_1$ ; b:  $P_2$ ; c:  $P_5$ ; d:  $P_9$ )  
 Fig. 12 Absolute error box distribution (a:  $P_1$ ; b:  $P_2$ ; c:  $P_5$ ; d:  $P_9$ )

两种单一模型的预测优势、弥补各自不足,从而显著提升融合模型的综合性能,使其在双桩基础多目标超

孔隙水压力预测中表现出更高的预测精度和更强的运行稳定性。

### 3.6.2 融合模型评估指标对比

为了验证融合模型对双桩基础周围海床超孔压整体预测性能, 将融合模型测试集预测评估指标与 ZDGRU、ZDELm、原始 GRU 和原始 ELM 模型评估指标进行对比, 结果如表 2 所示。从表 2 中可以看出, 相位滞后检测与动态对齐后的 ZDGRU 和 ZDELm 模型评估指标显著优于原始 GRU 和原始 ELM 模型, 而融合模型评估指标相较于原始模型以及单一 ZDGRU 和 ZDELm 模型均表现最优, 其中  $PCC$  为 0.982 7,  $NSE$  为 0.921 8,  $RMSE$  为 0.330 5%,  $MAE$  为 0.255 9%。同时, 从图 13 评估指标箱型分布中可以看出, 融合模型  $PCC$  和  $NSE$  评估指标均值、中位数和箱体位置均处于较高

水平。而  $RMSE$  和  $MAE$  评估指标均值、中位数和箱体位置均处于较低水平。此外, 从图中可以进一步看出, 相较于 ZDGRU、ZDELm、原始 GRU 和原始 ELM 模型,  $PCC$  评估指标分别提升 0.001 6、0.001 8、0.353 5 和 0.362 9;  $NSE$  评估指标分别提升 0.007 5、0.007 7、0.499 1 和 0.509 9;  $RMSE$  评估指标分别降低 0.030 2%、0.030 4%、1.240 4% 和 1.254 2%;  $MAE$  评估指标分别降低 0.034 8%、0.041 9%、1.147 8% 和 1.161 3%。通过以上定量评估结果进一步证明, 采用相位滞后检测与动态对齐方法结合 ZDGRU 和 ZDELm 动态误差择优融合方法构建的融合模型框架在多维度评价指标中均展现出明显优势, 这主要是因为融合模型框架既有效处理了超孔压与波高存在的相位差问题, 又通过模型融合弥补了单一模型存在的局限性, 有效降低了预测误差、提升了预测精度, 致使其能够更加准确地预测规则波作用下双桩基础周围海床多目标超孔隙水压力演变趋势。

### 3.6.3 融合模型预测对比

为了更加直观地展示融合模型对规则波作用下双桩基础周围海床多目标超孔隙水压力的整体预测效果, 绘制了测试集预测值与实际值的对比图, 如图 14 所示。从图中可以看出, 融合模型的预测效果均要优

表 2 不同模型评估指标均值  
Table 2 The mean value of evaluation metrics of different models

模型名称	$PCC$	$NSE$	$RMSE/KPa$	$MAE/KPa$
融合模型	0.982 7	0.921 8	0.330 5%	0.255 9%
ZDGRU	0.981 1	0.914 3	0.360 7%	0.290 7%
ZDELm	0.980 9	0.914 1	0.360 9%	0.297 8%
GRU	0.629 2	0.422 7	1.570 9%	1.403 7%
ELM	0.619 8	0.411 9	1.584 7%	1.417 2%

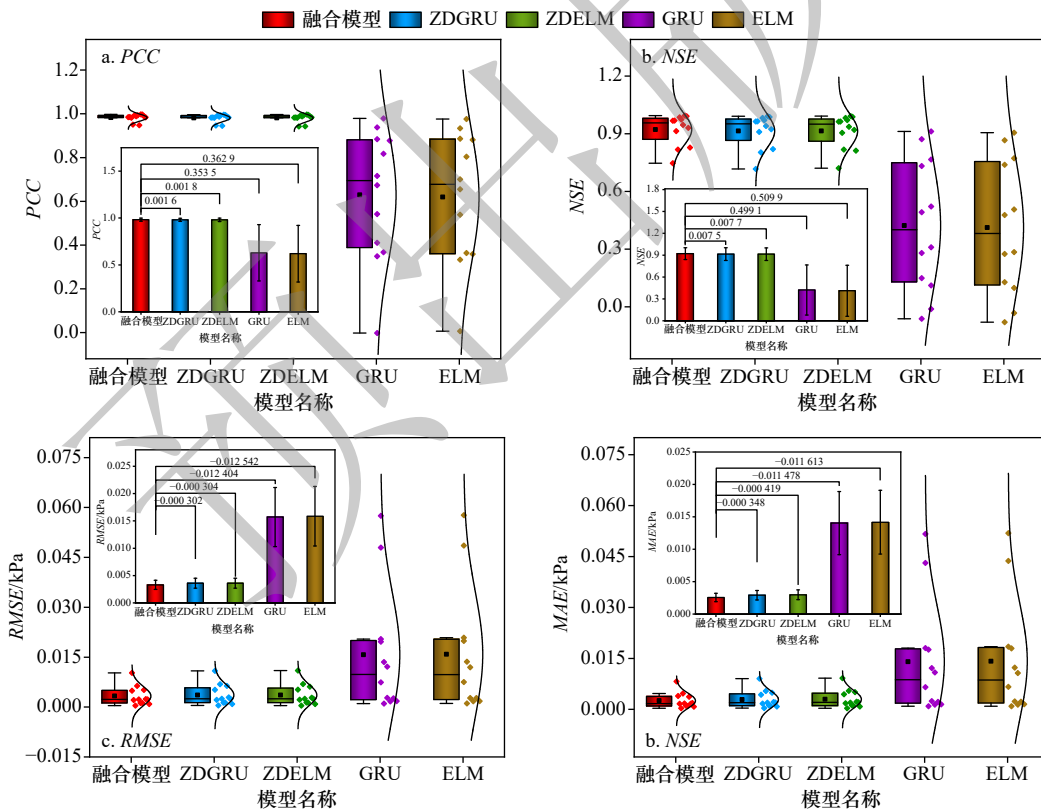


图 13 评估指标箱型分布 (a: $PCC$ ; b: $NSE$ ; c: $RMSE$ ; d: $MAE$ )

Fig. 13 Evaluation metrics box distribution(a: $PCC$ ; b: $NSE$ ; c: $RMSE$ ; d: $MAE$ )

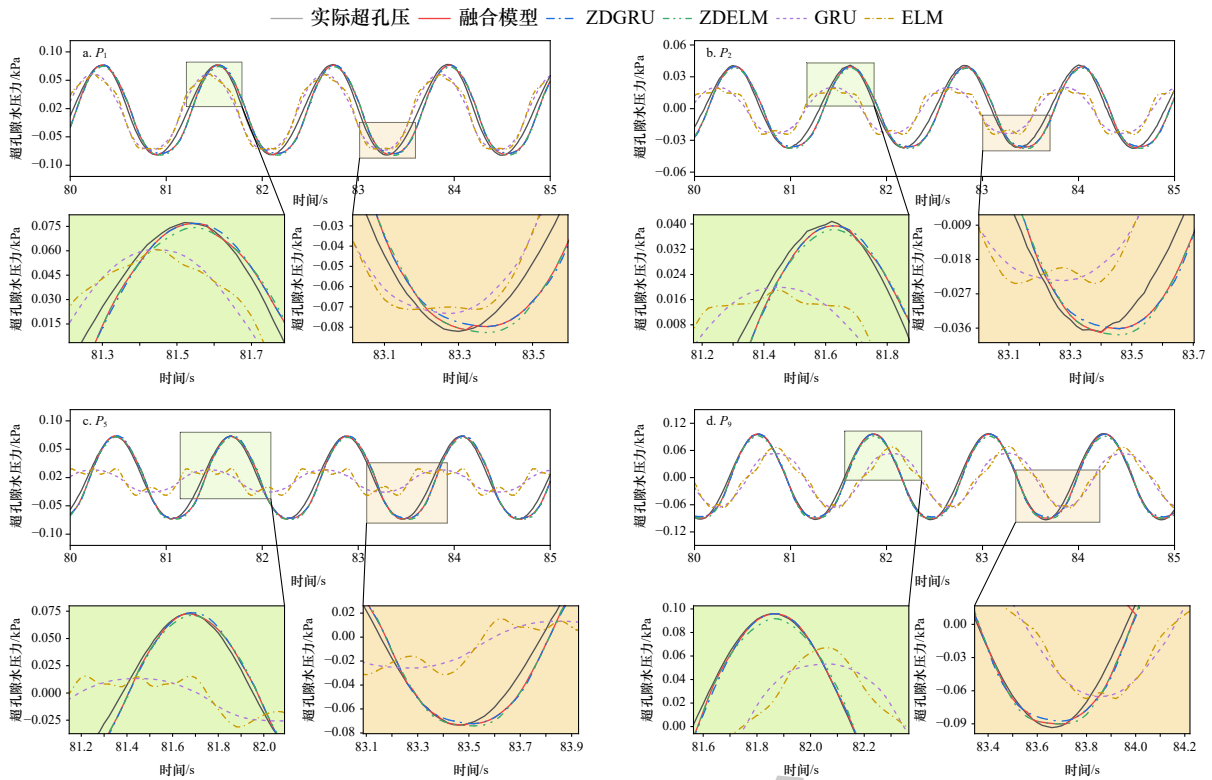


图 14 超孔压幅值预测结果(a:  $P_1$ ; b:  $P_2$ ; c:  $P_3$ ; d:  $P_9$ )

Fig. 14 Prediction results of excess pore pressure amplitude (a:  $P_1$ ; b:  $P_2$ ; c:  $P_3$ ; d:  $P_9$ )

于 ZDGRU、ZDELm、原始 GRU 和原始 ELM 模型,且融合模型的整体预测曲线与实际值拟度最高,进一步验证了融合模型预测性能的优越性。此外,从图 15

中可以进一步看出,融合模型对于不同深度位置超孔压最大幅值具有较高的预测效果,其预测值与实际值最为接近,且不同位置的绝对误差均值最小,

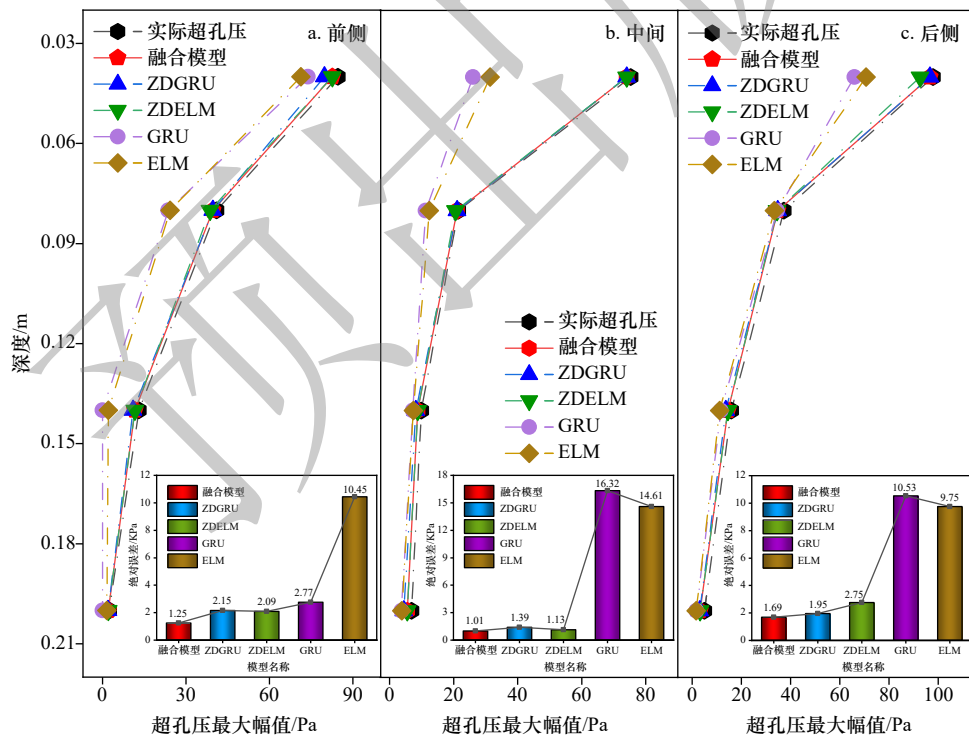


图 15 超孔压最大幅值预测结果

Fig. 15 Prediction results of the maximum amplitude of excess pore pressure

进一步证明融合模型在多目标超孔压预测中的精准性。这主要是因为通过相位滞后检测与对齐处理,能够有效解决超孔压与波高之间的相位滞后问题,提升了 GRU 和 ELM 模型对超孔压时序演变特征的捕捉能力,避免了因相位滞后导致的预测偏差,从而增强了模型的预测稳定性。同时,采用动态误差择优融合策略,能够对 ZDGRU 与 ZDELm 两种模型的输出进行自适应融合,通过评估预测误差并动态分配权重,充分发挥两种模型在不同时序模式与数据分布下的互补优势。以上结果表明,将相位滞后检测与动态对齐方法,同 ZDGRU 和 ZDELm 模型的动态误差择优融合策略相结合,可显著提升融合模型在规则波作用下双桩基础周围海床多目标超孔隙水压力的预测精度与稳定性,从而为保障海洋工程的安全运行提供了更为可靠的预测方法。

## 4 结论

本研究基于波浪水槽试验,研究了不同波高作用下双桩基础周围超孔隙水压力的演变特征。此外,通过相位滞后检测与动态对齐方法将原始数据进行预处理,并分别采用 GRU 与 ELM 模型进行预测。最后,引入动态误差择优融合策略对两种模型的预测结果进行自适应融合。具体研究结论如下:

(1)在本次试验条件下,双桩基础周围超孔压幅

值波动随着波高增大而显著升高,不同深度的幅值衰减与相位滞后现象愈发明显。沿深度方向,超孔压响应呈现出“浅层强、深层弱”的分布特征,浅层波动剧烈,深层波动相对较小。超孔压最大幅值随波高增大明显增强,且浅层增幅最为显著,深层增幅相对较小;同时,超孔压最大幅值沿深度方向逐渐衰减,波高越大衰减越平缓。此外,双桩基础周围超孔压最大幅值呈现出显著空间差异。

(2)构建的融合模型能够有效实现波浪作用下双桩基础周围超孔压智能预测。通过相位滞后检测与动态对齐方法,能够有效解决波高与超孔压之间的相位偏差,显著增强模型对超孔压时序演变特征的捕捉能力,提高模型的预测效果。同时,采用动态误差择优融合策略,可以有效弥补单一模型存在的不足,进一步降低预测误差,提升模型整体预测精度。与原始及单一模型相比,融合模型评估指标和预测准确性均表现最优。

(3)受试验环境、试验设备等因素限制,难以通过大量试验系统探究桩基埋深、土体参数、桩间距、桩型等变量对超孔隙水压力的影响。针对上述不足,后续将采用数值模拟方法,深入分析波浪荷载、桩基埋深、土体性质以及土层厚度等参数变化对超孔隙水压力的作用规律。同时,后续将收集实际工程中的测量数据开展应用研究,进一步完善并优化预测模型。

## 参考文献:

- [1] Lang Ruiqing, Liu Run, Lian Jijian, et al. Study on load-bearing characteristics of different types of pile group foundations for an offshore wind turbine[J]. *Journal of Coastal Research*, 2015, 73: 533-541.
- [2] Zhang Haochen, Liu Shuxue, Li Jinxuan, et al. Interactions between multi-directional irregular waves and a pile group in a side-by-side arrangement: probabilistic analysis[J]. *Coastal Engineering*, 2021, 165: 103851.
- [3] 宋木清, 及春宁, 许栋. 单向流作用下多桩承台式基础局部冲刷数值模拟研究[J]. *水动力学研究与进展 (A 辑)*, 2023, 38(1): 1-9.  
Song Muqing, Ji Chunqing, Xu Dong. Numerical investigation on local scour of offshore multi-pile foundation under unidirectional flow[J]. *Chinese Journal of Hydrodynamics*, 2023, 38(1): 1-9.
- [4] 张继生, 来嘉豪, 林祥峰, 等. 潮流能水轮机三脚桩基础局部冲刷深度演变特性[J]. *河海大学学报 (自然科学版)*, 2025, 53(4): 116-123.  
Zhang Jisheng, Lai Jiahao, Lin Xiangfeng, et al. Local scour depth evolution characteristics of tripod pile foundation for a tidal current energy turbine[J]. *Journal of Hohai University (Natural Sciences)*, 2025, 53(4): 116-123.
- [5] Yu Heng, Zhang Yuhang, Jia Jiayu, et al. Experimental and numerical study on local scour of pile group foundations for offshore wind turbines under wave-current interactions[J]. *China Ocean Engineering*, 2025, 39(3): 493-503.
- [6] Wang Shaohua, Wang Pandi, Zhai Hualing, et al. Experimental study for wave-induced pore-water pressures in a porous seabed around a mono-pile[J]. *Journal of Marine Science and Engineering*, 2019, 7(7): 237.
- [7] Zhang Qibo, Zhai Hualing, Wang Pandi, et al. Experimental study on irregular wave-induced pore-water pressures in a porous seabed around a mono-pile[J]. *Applied Ocean Research*, 2020, 95: 102041.
- [8] 郑余伟, 程永舟, 李典麒, 等. 波浪作用下斜坡上单桩周围海床孔隙水压力响应特性试验研究[J]. *海洋通报*, 2023, 42(3): 343-351.  
Zheng Yuwei, Cheng Yongzhou, Li Dianqi, et al. Experimental study for wave-induced pore water pressure response characteristics on slope seabed around monopile foundation[J]. *Marine Science Bulletin*, 2023, 42(3): 343-351.
- [9] Asumadu R, Zhang Jisheng, Zhao H Y, et al. A 3D numerical analysis of wave-induced seabed response around a monopile structure[J]. *Geomechanics and Geoengineering*, 2022, 17(1): 1-21.

- [10] Cheng Haiyang, Liang Bingchen, Zhang Hong, et al. Coupled numerical simulation of seabed response to focused wave loads around monopile foundation[J]. *Ocean Engineering*, 2025, 341: 122453.
- [11] 秦知朋, 陈永平, 潘毅, 等. 基于 BO-LSTM 神经网络模型的台风浪波高预报方法研究[J]. *海洋学报*, 2024, 46(10): 107–116.  
Qin Zhipeng, Chen Yongping, Pan Yi, et al. Research on typhoon wave height prediction method based on BO-LSTM neural network model[J]. *Haiyang Xuebao*, 2024, 46(10): 107–116.
- [12] Wang Mie, Ying Feixiang, Zhu Yunlou. A novel multistep point and interval prediction framework for accurate short-term wave height estimation incorporating the TCN-GRU-attention model and error distribution analysis[J]. *Renewable Energy*, 2026, 256: 124222.
- [13] Firat M, Gungor M. Generalized regression neural networks and feed forward neural networks for prediction of scour depth around bridge piers[J]. *Advances in Engineering Software*, 2009, 40(8): 731–737.
- [14] Zhang Zhishuai, Lin Mingbao, Han Bo, et al. Prediction of local scour depth around cylindrical piles: using simulated annealing algorithm and ensemble learning[J]. *Ocean Engineering*, 2025, 330: 121221.
- [15] Du Xing, Sun Yongfu, Song Yupeng, et al. Neural network models for seabed stability: a deep learning approach to wave-induced pore pressure prediction[J]. *Frontiers in Marine Science*, 2023, 10: 1322534.
- [16] Cheng Haiyang, Cheng Yongzhou, Zheng Yuwei, et al. Prediction of irregular wave (current)-induced pore water pressure around monopile using machine learning methods[J]. *Coastal Engineering*, 2023, 182: 104291.
- [17] Zhang Qi, Zhou Xianglian, Wang Jianhua, et al. Wave-induced seabed response around an offshore pile foundation platform[J]. *Ocean Engineering*, 2017, 130: 567–582.
- [18] Wang Wei, Zhang Zitao, Yu Guangming, et al. Behavioral investigation of the large diameter monopiles under cyclic lateral loading in clay[J]. *Ocean Engineering*, 2025, 321: 120406.
- [19] 陈林雅. 波流荷载作用下桩基周围海床响应的实验研究及数值模拟[D]. 成都: 西南交通大学, 2020.  
Chen Linya. Experimental and numerical studies of seabed response around pile foundation under wave and current loading[D]. Chengdu: Southwest Jiaotong University, 2020.
- [20] Yu Ziqin, Cheng Yongzhou, Cheng Haiyong. Experimental investigation on seabed response characteristics considering vibration effect of offshore monopile foundation[J]. *Ocean Engineering*, 2023, 288: 116000.
- [21] 张启博. 波浪作用下单桩周围砂质海床瞬态响应研究[D]. 成都: 西南交通大学, 2019.  
Zhang Qibo. Wave-induced transient sandy seabed response around a single pile foundation[D]. Chengdu: Southwest Jiaotong University, 2019.
- [22] Cho K, Van Merriënboer B, Gulçehre Ç, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha: Association for Computational Linguistics, 2014: 1724-1734.
- [23] 王敏, 曹小萌, 洪梅, 等. 基于 GMC-GRU 的洪泽湖水质指标溶解氧预测研究[J]. *环境科学与技术*, 2025, 48(12): 102–112.  
Wang Min, Cao Xiaomeng, Hong Mei, et al. Study on DO prediction for Hongze Lake water based on GMC-GRU[J]. *Environmental Science & Technology*, 2025, 48(12): 102–112.
- [24] 陈莹, 史明哲, 张子凯, 等. 融合 CNN-GRU-Attention 的含水砂岩蠕变预测方法研究[J]. *安全与环境学报*, 2025, 25(12): 4566–4576.  
Chen Ying, Shi Mingzhe, Zhang Zikai, et al. Creep prediction method for water-bearing sandstone using a CNN-GRU-Attention model[J]. *Journal of Safety and Environment*, 2025, 25(12): 4566–4576.
- [25] Huang Guangbin, Zhu Qinyu, Siew C K. Extreme learning machine: theory and applications[J]. *Neurocomputing*, 2006, 70(1/3): 489–501.
- [26] 王嘉翀, 吴自银, 王明伟, 等. 海底声学底质分类的 ELM-AdaBoost 方法[J]. *海洋学报*, 2021, 43(12): 144–151.  
Wang Jiachong, Wu Ziyin, Wang Mingwei, et al. ELM-AdaBoost method of acoustic seabed sediment classification[J]. *Haiyang Xuebao*, 2021, 43(12): 144–151.
- [27] Dokur E, Erdogan N, Yuzgec U. Swarm intelligence-based multi-layer kernel meta extreme learning machine for tidal current to power prediction[J]. *Renewable Energy*, 2025, 243: 122516.
- [28] Zhao Lingxiao, Li Zhiyang, Pei Yuguo, et al. Disentangled seasonal-trend representation of improved CEEMD-GRU joint model with entropy-driven reconstruction to forecast significant wave height[J]. *Renewable Energy*, 2024, 226: 120345.
- [29] Chen Jiaxin, Li Shibao, Zhu Jinze, et al. Significant wave height prediction based on variational mode decomposition and dual network model[J]. *Ocean Engineering*, 2025, 323: 120533.

## Intelligent prediction of excess pore water pressure of seabed around double pile foundation under the action of regular wave

Hou Jiankang<sup>1</sup>, Cheng Yongzhou<sup>1,2</sup>, Wang Dunge<sup>1</sup>, Han Xiaorui<sup>1</sup>, Li Yuanlong<sup>1</sup>, Shi Yi<sup>1</sup>

(1. School of Hydraulic and Ocean Engineering, Changsha University of Science & Technology, Changsha 410114, China; 2. Key Laboratory of Water-Sediment Sciences and Water Disaster Prevention of Hunan Province, Changsha 410114, China)

**Abstract:** This study conducted multi-objective intelligent prediction research on the super-pore water pressure around double-pile foundations in the seabed under wave action. Firstly, the time-history evolution and spatial distribution of excess pore water pressure around the double-pile foundation under different wave heights are analyzed by wave flume test. Secondly, the phase lag detection and dynamic alignment method are used to preprocess the data, and GRU and ELM neural networks are used for training prediction respectively. Finally, the dynamic error preferred fusion method is used to fuse the outputs of the two models. The results show that under the current test conditions, with the increase of wave height, the amplitude of excess pore water pressure in the seabed around the double-pile foundation increases significantly, showing obvious amplitude attenuation and phase lag along the depth direction, and there are obvious spatial differences in the maximum amplitude of excess pore water pressure around the double-pile foundation. In addition, the constructed fusion model performs best compared with the original model or single model evaluation metrics, where  $PCC$  is 0.982 7,  $NSE$  is 0.921 8,  $RMSE$  is 0.330 5%, and  $MAE$  is 0.255 9%. The research results provide an effective way for the intelligent prediction of multi-objective pore pressure of seabed around pile foundation under wave action.

**Key words:** double pile foundation; excess pore water pressure; phase lag detection; dynamic error; fusion model