

基于 GNN 和 ISPH 耦合方法的波浪与结构物相互作用数值模拟研究¹⁾

张宁波 倪宝玉²⁾ 薛彦卓 武奇刚 袁广宇

(哈尔滨工程大学船舶工程学院, 哈尔滨 150001)

摘要 波浪与结构物相互作用的研究因其在海洋结构物设计、操作及安全性方面的关键性作用而受到广泛关注. 作为一种无网格数值方法, 不可压缩光滑粒子流体动力学 (incompressible smoothed particle hydrodynamics, ISPH) 方法正逐渐成为研究波浪与结构相互作用问题的潜力工具. 在传统的 ISPH 方法中, 压力是通过求解压力泊松方程 (pressure Poisson equation, PPE) 获得的, 这是整个计算过程最为耗时的部分. 采用一种图神经网络 (graph neural network, GNN) 与 ISPH 相结合的耦合方法 (ISPH_GNN) 对波浪与结构物相互作用展开数值模拟研究. 在 ISPH_GNN 中, GNN 模型用于预测流体压力, 取代了传统 ISPH 方法中的 PPE 求解过程. 文章的一项贡献是揭示了基于相对简单算例生成的数据训练的 GNN 模型可以有效地应用于相对更复杂的波浪与结构物相互作用问题. 具体而言, 本文采用基于溃坝和液舱晃荡算例数据训练而成的 GNN 模型, 并将其与 ISPH 方法相结合, 构建了 ISPH_GNN 方法, 以模拟不同的波浪与结构相互作用问题, 包括孤立波冲击阶梯结构、规则波冲击水下梯形结构物和规则波与浮式箱体的相互作用. 仿真结果显示, ISPH_GNN 在这些不同场景下均能提供令人满意的模拟结果, 展现了其在波浪与结构相互作用问题上的良好泛化能力. 文章的另一项重要贡献在于, 与传统 ISPH 方法相比, ISPH_GNN 在取得相似甚至略高计算精度的同时, 显著提升了压力预测的计算效率, 尤其是在处理大规模粒子数的波浪-结构物相互作用仿真时. 例如, 在包含 130 万粒子的模拟工况下, ISPH_GNN 的压力预测速度提升了多达 93 倍. 研究结果突显了 ISPH_GNN 方法在波浪-结构物相互作用仿真中的巨大潜力, 可为海洋工程提供一种更具可扩展性和计算高效性的仿真工具.

关键词 波浪与结构物相互作用, 不可压缩光滑粒子流体动力学, 图神经网络, 耦合方法, 压力泊松方程, 压力预测

中图分类号: O352

文献标识码: A

DOI: [10.6052/0459-1879-24-552](https://doi.org/10.6052/0459-1879-24-552)

CSTR: [32045.14.0459-1879-24-552](https://cstr.net.cn/32045.14.0459-1879-24-552)

NUMERICAL STUDY OF WAVE-STRUCTURE INTERACTIONS BY A HYBRID METHOD COMBINING GNN WITH ISPH¹⁾

Zhang Ningbo Ni Baoyu²⁾ Xue Yanzhuo Wu Qigang Yuan Guangyu

(College of Shipbuilding Engineering, Harbin Engineering University, Harbin 150001, China)

Abstract The study of wave-structure interactions has attracted significant attention due to its crucial role in the

2024-12-02 收稿, 2025-03-19 录用, 2025-03-24 网络版发表.

1) 国家自然科学基金资助项目(52371270, 52192693 和 52192690).

2) 通讯作者: 倪宝玉, 教授, 主要研究方向为计算流体力学、极地船舶与海洋工程. E-mail: nibaoyu@hrbeu.edu.cn

引用格式: 张宁波, 倪宝玉, 薛彦卓, 武奇刚, 袁广宇. 基于 GNN 和 ISPH 耦合方法的波浪与结构物相互作用数值模拟研究. 力学学报, 2025, 57(4): 816-828

Zhang Ningbo, Ni Baoyu, Xue Yanzhuo, Wu Qigang, Yuan Guangyu. Numerical study of wave-structure interactions by a hybrid method combining GNN with ISPH. *Chinese Journal of Theoretical and Applied Mechanics*, 2025, 57(4): 816-828

design, operation, and safety of marine structures. As a mesh-free numerical method, the incompressible smoothed particle hydrodynamics (ISPH) method has gradually become a promising tool for simulating wave-structure interactions. In traditional ISPH, pressure is obtained by solving the pressure Poisson equation (PPE), which is the most time-consuming part of the entire computational process. In this study, a hybrid method, ISPH_GNN, combining the graph neural network (GNN) with ISPH, is employed to numerically simulate wave-structure interactions. In ISPH_GNN, the GNN model is used to predict fluid pressure, replacing the PPE-solving process in traditional ISPH. One of the contributions of this paper is to demonstrate that a GNN model trained on data generated from relatively simple cases can be effectively applied to more complex wave-structure interaction scenarios. Specifically, this article adopts a GNN model trained with dam-break and sloshing tank example data, and combines it with the ISPH method to construct the ISPH_GNN method, which is used to simulate various wave-structure interaction problems, including solitary wave overtopping over a step, regular wave impact on a submerged trapezoidal structure, and the interaction between regular waves and a floating box. The simulation results show that ISPH_GNN provides satisfactory results in these different scenarios, demonstrating its excellent generalization ability in wave-structure interaction problems. Another significant contribution of this study is demonstrating that, compared to the conventional ISPH method, ISPH_GNN achieves similar or slightly higher computational accuracy while significantly enhancing the efficiency of pressure prediction, especially in large-scale wave-structure interaction simulations with a high number of particles. For example, in a simulation with 1.3 million particles, the pressure prediction speed of ISPH_GNN is enhanced by up to 93 times. These results highlight the great potential of the ISPH_GNN method in wave-structure interaction simulations, offering a more scalable and computationally efficient tool for marine engineering.

Key words wave-structure interactions, incompressible smoothed particle hydrodynamics, graph neural network, hybrid method, pressure Poisson equation, pressure prediction

引言

波浪与结构物相互作用的研究因其在海洋结构物设计、操作及安全性方面的关键性作用而受到广泛关注^[1-2]. 发展高精度、高效率的数值方法是模拟研究波浪与结构物相互作用的重要手段之一. 作为一种拉格朗日无网格方法, 光滑粒子流体动力学 (smoothed particle hydrodynamics, SPH) 方法^[3-4] 已被广泛证明为有效的流-固耦合问题仿真工具^[5-8]. SPH 方法通过粒子离散计算域, 这些粒子携带压力、密度和速度等变量, 并以拉格朗日方式运动. SPH 方法的无网格特性和拉格朗日粒子特性, 使其能够轻松处理大变形问题从而适用于破碎波和波浪-结构物相互作用的模拟研究. 作为 SPH 的一个重要分支, 不可压缩 SPH (incompressible SPH, ISPH) 方法^[9] 也被广泛应用于波浪-结构物相互作用模拟, 并展现出生成稳定且准确压力场的能力^[10-14], 同时具备优异的体积守恒特性^[15]. 在 ISPH 方法中, 压力是通过求解压力泊松方程 (pressure Poisson equation, PPE) 获得^[16], 尽管近年来在改进求解效率方面已有一定进展^[17], 但 PPE 的求解仍是 ISPH 方法中最为耗时的部分.

近年来, 研究人员逐渐将机器学习 (machine

learning, ML) 方法应用到流体动力学数值模拟, 旨在提升计算效率或改善计算精度. 例如, Tompson 等^[18] 利用卷积神经网络 (convolutional neural network, CNN) 在基于欧拉法的求解器中执行压力投影任务, 从而提高了欧拉流体模拟的效率. Dong 等^[19] 开发了 Smart FluidNet 框架, 使用 CNN 来自动选择多个神经网络模型, 从而加速欧拉流体模拟. Zhang 等^[20] 将 CNN 与 ISPH 结合, 使用 CNN 模型来预测流体压力, 替代了直接求解 PPE 的步骤, 从而用于模拟自由液面流动. 张珍等^[21] 基于组合神经网络模型预测新的雷诺平均模型模拟的流场, 实现对雷诺应力线性部分的隐式处理和雷诺应力非线性部分的修正, 展现出在数据驱动的湍流建模及工程应用中的巨大潜力. 罗仁宇等^[22] 首次基于格子 Boltzmann 方法 (lattice Boltzmann method, LBM), 结合卷积神经网络, 建立了超分辨率流场重构模型 (SRLBM), 可通过还原宏观速度场与涡量场, 快速重构高精度复杂流场.

此外, 图神经网络 (graph neural network, GNN) 作为一种基于图结构的机器学习方法, 能够处理不规则分布节点上的数据, 因此, GNN 能够为基于粒子数据的数值模拟提供关键优势, 例如拉格朗日 ISPH 数值模拟, 其中数据通常以不规则分布的粒子

形式表示. 近年来, GNN 也被应用于在流体动力学仿真中. 例如, Kumar 等^[23]开发了一个基于图神经网络的模拟器 (graph network simulator, GNS), 用于预测颗粒流系统中的流体动力学行为; Li 等^[24]提出了一种基于数据驱动的 GNN 模型, 用于拉格朗日粒子基础的流体模拟. Zhang 等^[25]将 GNN 与 ISPH 结合, 用于模拟自由表面流动. 虽然现有的基于 GNN 的研究已经展示了 GNN 在数值仿真中的潜力, 但这些研究主要集中在流体力学仿真模拟.

在本文中, 应用 GNN 和 ISPH 的耦合方法 (ISPH_GNN) 来模拟波浪与结构的相互作用. 在这种耦合方法中, Li 等^[24]开发的 GNN 模型被结合到我们自主开发的 ISPH 求解器^[26]中, 用于预测流场压力, 从而替代传统 ISPH 方法中 PPE 的求解过程. ISPH_GNN 结合基于溃坝和液舱晃荡算例生成的数据训练的 GNN 模型被扩展应用于模拟不同的波浪-结构物相互作用问题, 包括孤立波爬越阶梯结构, 规则波冲击水下梯形结构物和规则波与箱式浮体的相互作用. 并通过与实验结果和传统 ISPH 结果的对比, 验证了 ISPH_GNN 方法在模拟波浪-结构物相互作用中的准确性和有效性. 本文的一项重要贡献是揭示了基于相对简单数值算例生成的数据训练得到的 GNN 模型与 ISPH 方法相结合, 能够有效地应用于更复杂的波浪-结构相互作用问题的模拟, 这也体现了 ISPH_GNN 的良好泛化性能. 此外, 本文还探讨了 ISPH_GNN 在压力预测方面的计算效率, 展示了 ISPH_GNN 方法在提高压力预测计算效率方面的显著优势, 凸显了其在大规模粒子数的波浪-结构物相互作用数值模拟中的优势和潜力.

1 数学和数值公式

1.1 ISPH

ISPH 框架中不可压缩流体的控制方程包括连续性和 Navier-Stokes 方程, 如下所示

$$\nabla \cdot \mathbf{u} = 0 \quad (1)$$

$$\frac{D\mathbf{u}}{Dt} = -\frac{1}{\rho}\nabla p + \mathbf{g} + \nu\nabla^2\mathbf{u} \quad (2)$$

其中, $\mathbf{u}$, p 和 ρ 分别是流体的速度、压力和密度; $\mathbf{g}$ 是重力加速度; ν 是流体的运动黏度. 在固体边界上, 分别施加了以下速度和压力的 Neumann 边界条件

$$\mathbf{u} \cdot \mathbf{n} = \mathbf{U} \cdot \mathbf{n} \quad (3)$$

$$\mathbf{n} \cdot \nabla p = \rho(\mathbf{n} \cdot \mathbf{g} - \mathbf{n} \cdot \dot{\mathbf{U}}) \quad (4)$$

其中, $\mathbf{n}$ 是固体边界的单位法向量; $\mathbf{U}$ 和 $\dot{\mathbf{U}}$ 分别是固体边界的速度和加速度. 在自由表面上施加以下压力条件

$$p = 0 \quad (5)$$

在 ISPH 中, 投影法被用于求解控制方程和边界条件, 它主要由 3 个阶段组成.

(1) 预测阶段: 预测粒子的中间步的速度和位置

$$\mathbf{u}^* = \mathbf{u}_t + \Delta\mathbf{u}^* \quad (6)$$

$$\Delta\mathbf{u}^* = (\mathbf{g} + \nu\nabla^2\mathbf{u})\Delta t \quad (7)$$

$$\mathbf{r}^* = \mathbf{r}_t + \mathbf{u}^*\Delta t \quad (8)$$

其中, $\mathbf{u}_t$ 和 $\mathbf{r}_t$ 分别是时间步 t 时粒子的速度和位置; Δt 是时间步长; $\mathbf{u}^*$ 和 $\mathbf{r}^*$ 是粒子中间步的速度和位置.

(2) 压力投影阶段: 在该阶段, 通过将式 (6) 和公 (7) 代入式 (1) 和式 (2), 可以得到 PPE. 根据 Ma 等^[27]以及 Zheng 等^[10]的研究, 以下 PPE 的替代形式可应用于所有内部流体粒子

$$\nabla^2 p_{t+\Delta t} = \psi / \Delta t \quad (9)$$

其中, $\psi = \alpha \frac{\rho - \rho^*}{\Delta t} + (1 - \alpha)\rho \nabla \cdot \mathbf{u}^*$, α 是混合系数且在本文中取值 0.01, ρ^* 是粒子运动过程中中间时间步预估的粒子密度.

(3) 修正阶段: 这一阶段, 在求解结合边界条件的 PPE 后, 通过以下公式获得修正阶段中粒子的速度变化

$$\mathbf{u}^{**} = -\frac{\Delta t}{\rho} \nabla^2 p_{t+\Delta t} \quad (10)$$

随后, 使用以下公式校正时间步 $t + \Delta t$ 时粒子的速度

$$\mathbf{u}_{t+\Delta t} = \mathbf{u}^* + \mathbf{u}^{**} \quad (11)$$

相应地, 时间步 $t + \Delta t$ 时粒子的位置可通过以下方式更新获得

$$\mathbf{r}_{t+\Delta t} = \mathbf{r}_t + \frac{\mathbf{u}_t + \mathbf{u}_{t+\Delta t}}{2} \Delta t \quad (12)$$

1.2 GNN 模型

本文采用的 GNN 模型包括 3 个步骤: 编码、信息传递和解码^[28-29], 如图 1 所示.




图 1 GNN 模型网络结构示意图

Fig. 1 Diagram of the GNN network architecture

编码步骤旨在将输入数据转换为可用于图卷积的节点嵌入特征. 编码步骤的具体过程可描述为: 对于图 1 中的目标节点 i , 可通过基于具有 n 层的多层感知器 (MLP) 的可学习编码器 $en()$, 将输入数据 f_i^0 编码为高维度特征 h_i^0

$$en(f_i^l) = \sigma(w_l f_i^{l-1} + b_l), \quad l = 1, 2, \dots, n \quad (13)$$

$$h_i^0 = en(f_i^n) \quad (14)$$

其中, $\sigma()$ 是激活函数, w_l 和 b_l 分别是 MLP 中第 l 层的可学习权重向量和偏差项, f_i^l 是 MLP 中第 l 层的节点特征. 节点嵌入特征 h_i^0 是式 (14) 中给出的 MLP 的输出, 该输出将用作下述的信息传递模块 (即图卷积) 的输入.

在信息传递模块中, 首先需评估相邻节点 j 对所考虑的节点 i 的邻域影响, 即 $m_{j \rightarrow i}$. 第 l 层图卷积中的邻域影响由下式给出

$$m_{j \rightarrow i}^l = h_j^{l-1} W(r_{ij}, r_0) \quad (15)$$

其中 h_j^{l-1} 表示 i 节点的相邻节点 j 在第 l 层卷积中的节点嵌入, 权重由 $W(r_{ij}, r_0) = \begin{cases} r_0/r_{ij} - 1, & 0 < r_{ij} \leq r_0 \\ 0, & r_{ij} > r_0 \end{cases}$ 给出. 来自所有相邻节点对目标节点的影响可聚合为

$$M_i^l = \frac{\sum_{j=1}^N m_{j \rightarrow i}^l}{\sum_{j=1}^N W(r_{ij}, r_0)} \quad (16)$$

在信息传递的第 l 层, 节点 i 的节点嵌入特征可通过以下公式计算得到

$$h_i^l = \sigma(w'_l M_i^l + b'_l h_i^{l-1}), \quad l = 1, 2, \dots, L \quad (17)$$

其中, $\sigma()$ 是激活函数, w'_l 和 b'_l 分别是第 l 层的可学习权重向量和偏差项.

在 L 层信息传递后, 可获得最终层的节点嵌入

特征 h_i^L . 在解码步骤, 可通过解码器 $den()$ 对 h_i^L 进行解码, 得出预测项 q_i (本文中为压力项)

$$q_i = den(h_i^L) \quad (18)$$

在本文中, 所有编码器/解码器的多层感知机 (MLP) 均采用 3 层结构, 而信息传递层的数量根据第 3 节中的数值测试结果, 选择为 2 层. 所有神经网络层中的非线性激活函数均采用高斯误差线性单元 (GeLUs)^[30].

2 耦合方法: ISPH_GNN

在 ISPH_GNN 中, 采用了 GNN 模型预测压力, 以替代传统 ISPH 中 PPE 的求解. 具体而言, ISPH 中执行完预测阶段后, 根据预测的粒子速度和位置获得 GNN 所需的输入参数, 并将输入参数传递到 GNN 模型, 通过 GNN 模型预测得到粒子的压力, 将 GNN 预测的粒子动压力返回传递到 ISPH, 随后在 ISPH 框架中继续执行修正阶段, 即根据更新后的压力校正时间步 $t + \Delta t$ 时粒子的速度, 并更新获得相应的粒子位置. ISPH_GNN 的流程图如图 2 所示.

本文中, ISPH 程序是基于 Fortran 语言编写而成, GNN 模型则是基于 Python 语言构建, 并在 PyTorch 平台上运行. 为了实现 ISPH 与 GNN 之间物理信息的相互高效传递, 本研究采用 C++ 接口, 结




图 2 GNN 与 ISPH 的耦合流程图 (传统 ISPH 的流程以实线箭头表示, ISPH_GNN 的流程以虚线箭头表示)

Fig. 2 Flowchart of ISPH incorporating the GNN (flowcharts of the conventional ISPH (solid arrows) and the ISPH_GNN (dashed arrows))

合 Pybind11 库, 实现从 ISPH 向 GNN 传递输入参数, 并同步将 GNN 预测的粒子动压力反向传递回 ISPH. 具体信息相互传递过程如下: 在 ISPH 程序中, 根据 GNN 模型的输入要求, 获得输入参数后, 将这些参数按照接口函数定义的格式进行整理, 并调用 C++ 接口函数, 将输入参数传递给 GNN 模型. 在 C++ 接口函数内部, 通过 Pybind11 库将 C++ 数据类型转换为 Python 可识别的数据类型, 然后调用的 GNN 模型, 将参数传递给 GNN 模型进行处理. 已训练好的 GNN 模型在接收到输入参数后, 在 PyTorch 平台上通过前向传播计算, 输出预测的动压力结果. GNN 模型预测完成后, 将动压力结果返回给 C++ 接口. C++ 接口函数再将压力预测结果转换为 ISPH 程序能够接收的格式, 并传递回 ISPH.

本节简要讨论了 GNN 的训练和执行等与 GNN 模型相关的一些内容. 更多详细信息可参考文献 [25].

2.1 输入参数

GNN 模型的输入参数应包括能充分反映水动力特性的物理变量. 基于 Zhang 等 [25] 的研究, 本文选取粒子中间步速度 $\mathbf{u}^*$, PPE 中的 ψ 项 (式 (9)) 和前一时间步的动压力 $p_{d,t}$ 作为输入参数去训练 GNN 模型以预测下一时间步的动压力 $\hat{p}_{d,t+\Delta t}$. 本文中, GNN 模型可用表示从输入到输出的映射函数 f_{GNN} 表征, 映射函数 f_{GNN} 可以表达为

$$\hat{p}_{d,t+\Delta t} = f_{\text{GNN}}(\mathbf{u}^*, \psi, p_{d,t}, c_p) \quad (19)$$

其中, c_p 是神经网络模型参数, 即式 (13) 和式 (17) 中涉及的权重和偏差, 这些参数在训练过程中得到优化.

作为输入参数之一的前一时间步的动压 $p_{d,t}$, 可以通过从总压力中减去静压力 p_{static} 来获得, 即 $p_{d,t} = p_t - p_{\text{static}}$. 在使用 GNN 模型 f_{GNN} 预测得到下一步的动压力 $\hat{p}_{d,t+\Delta t}$ 后, 流体粒子的总压力可以通过将静压和预测的动压相加来获得, 即 $p_{t+\Delta t} = \hat{p}_{d,t+\Delta t} + p_{\text{static}}$. 静压力 p_{static} 可以直接通过 $\rho g z$ 计算获得, 其中 z 是流体粒子在水面以下的对应深度.

2.2 训练数据

为使 ISPH_GNN 能够模拟不同的波浪与结构物相互作用问题, 训练出具有良好泛化性能的 GNN 模型至关重要. 该模型需通过训练准确捕捉流固耦合过程中压力场与输入参数间的复杂非线性映射关系, 这要求训练数据应尽量覆盖各种流-固耦合问题

中的典型流体动力学行为特征. 溃坝和液舱晃荡作为基础算例, 涵盖了流固耦合问题中多种典型的流体动力学行为, 包括流体的低速与快速流动、流体对固体边界的冲击, 以及冲击波破碎等涵盖流体低速流动、高速冲击、自由面破碎、周期振荡和边界碰撞等典型现象. 不仅如此, 相较于波浪传播以及波浪与结构物相互作用算例, 溃坝和液舱晃荡场景的计算域要小很多. 采用这类简单的流固耦合算例生成训练数据, 能显著缩短数据生成和模型训练的时间.

基于上述流体动力学典型特性以及训练成本因素的综合考量, 本文选用溃坝和液舱晃荡算例生成训练数据, 以此来训练 GNN 模型. 此外, 丰富多样的训练数据也有助于提升 GNN 模型的泛化性能. 因此, 本文在溃坝和液舱晃荡算例中, 通过随机设定不同的初始参数, 生成多样化的训练数据集. 根据本文的研究测试, 采用 60 个溃坝算例和 60 个液舱晃荡算例生成的训练和测试集, 并以此为基础训练得到的 GNN 模型, 在本文所模拟研究的波浪与结构物相互作用问题中展现出令人满意的预测精度和泛化性能. 后续研究将重点优化算例组合策略与数据规模选择, 以进一步提升 ISPH_GNN 在模拟研究流固耦合问题中的性能表现.

本文采用一种连续二阶 ISPH 方法 (ISPH_CQ) [31] 对这些算例进行数值模拟以生成训练数据. ISPH_CQ 中的控制方程和边界条件与传统 ISPH 相同. 然而, ISPH_CQ 采用了二阶 SFDI 方法 [32] 对 ISPH 中的拉普拉斯算子、速度散度、相关的 Neumann 边界条件以及压力梯度进行数值近似, 可提高相关计算精度. 有关 ISPH_CQ 的更多详细信息, 请参阅文献 [31-32].

为了生成训练数据, 采用 ISPH_CQ 共模拟了 60 个溃坝算例和 60 个液舱晃荡算例. 训练数据集由 30 个溃坝算例和 30 个液舱晃荡算例组成, 这些算例是从所有模拟算例中随机选择的. 未包含在训练数据集中的其他案例则作为测试集使用. 溃坝算例的模拟计算域为一个水平长度为 L 的水槽, 水槽中包含一个宽度为 l 和高度为 h 的矩形水柱, 如图 3(a) 所示. 对于液舱晃荡算例, 其计算域设置如图 3(b) 所示, 其中 L 表示水槽的长度, D 为水槽高度, d 表示初始水深. 水槽经历周期性摇摆运动, 运动方程可描述为 $X_s = a \sin(\omega t)$, 其中 a 和 ω 分别是运动的幅度和频率.




图 3 数值水槽示意图

Fig. 3 Sketch of the numerical water tank

用于生成训练数据的上述算例中的参数是随机选择的. 例如, 在溃坝算例中, 水柱的高度 h 和宽度 l 在范围 $h/L = 0.2 \sim 0.5$ 和 $l/L = 0.2 \sim 0.5$ 之间选择, 其中 L 固定为 2.0 m. ISPH_CQ 模拟使用初始粒子大小为 0.01 m 和时间步长为 0.001 s. 每个算例包含 100 帧且每帧间隔为 0.006 s 的数据, 覆盖了从初始时刻到溃坝水流冲击水槽右墙壁的整个过程. 对于液舱晃荡算例, 其中参数设置为 $d = 0.2L$, $D = 0.5L$, $L = 0.6$ m. 运动幅度 a 在 $0.05L$ 和 $0.1L$ 之间随机选择, 运动周期 T 赋值为 1.4, 1.5 和 1.6 s. ISPH_CQ 模拟中初始粒子大小为 0.01 m, 时间步长为 0.001 s. 每个案例也同样包含 100 帧数据, 每帧间隔为 0.1 s.

2.3 训练和执行 GNN

当上述训练数据生成后, 可应用这些训练数据对 GNN 进行训练以最小化损失函数. 该损失函数定义为动压力的预测值和真实值之间误差的平方 L_2 范数之和, 可表示为

$$f_{\text{obj}} = \sum_i^N s_i (\hat{p}_{d,i} - p_{d,i})^2 \quad (20)$$

其中, $\hat{p}_{d,i}$ 和 $p_{d,i}$ 分别是粒子 i 对应的预测和真实动压力.

在式 (20) 中, s_i 是考虑边界影响的权重. 本文所研究的问题通常涉及两类边界条件, 即自由表面边界条件和固体边界条件. 在 GNN 训练过程中, 未考

虑自由表面上预测压力与实际压力之间的差异. 当运用 GNN 模型进行压力预测时, 自由表面粒子的压力被设定为 0, 以确保满足自由表面边界条件式 (5). 当考虑涉及压力法向导数的固体边界条件时, 即式 (4), 我们发现, 在训练和测试阶段直接施加固体边界条件会引入较大误差. 为避免这一问题, 采用以下策略: 在 GNN 的训练和测试阶段, 仅考虑内部流体粒子, 忽略代表固体边界的粒子. 以这种方式训练的 GNN 模型仅用于预测流体粒子 (不包括边界粒子) 的压力. 固壁和结构物边界上的边界粒子压力 p_b 则参照文献 [33] 中的边界处理方法, 直接从相邻流体粒子处插值获得

$$p_b = \frac{\sum_{f \in \text{fluid}}^M p_f W_{bf} + (\mathbf{g} - \dot{\mathbf{U}}) \cdot \sum_{f \in \text{fluid}}^M \rho_f (\mathbf{r}_f - \mathbf{r}_b) W_{bf}}{\sum_{f \in \text{fluid}}^M W_{bf}} \quad (21)$$

其中, p_f 是流体粒子的压力, ρ_f 是流体的密度, W_{bf} 是核权重函数, M 是边界粒子的相邻流体粒子的总数, $\mathbf{r}_f$ 和 $\mathbf{r}_b$ 分别是流体和边界粒子的位置矢量.

然而, 由于采用不同方法来估算固体边界上以及边界附近流体粒子的压力, 边界附近的压力可能会不一致. 为解决这一问题, 在式 (20) 中, 对固体边界附近的流体粒子赋予了更大权重, 且越靠近固体边界的流体粒子权重越大. 综合考虑这一点以及自由表面条件, 提出了如下权重项

$$s_i = \begin{cases} 3, & d_b \leq 3.0dx \\ 2, & 3.0dx < d_b \leq 6.0dx \\ 1, & d_b > 6.0dx \\ 0, & \text{free-surface} \end{cases} \quad (22)$$

其中, d_b 是粒子到边界的距离, dx 是初始粒子间距.

当训练完成后, 得到的 GNN 模型可被执行应用于 ISPH_GNN 的数值模拟中, 应用过程如图 2 所示. 通过本文研究测试发现, 采用结合了式 (22) 中选定的 s_i 权重值的损失函数来训练 GNN, 能够获得令人满意的数值模拟结果. 尽管当前边界条件的处理方式并非完善, 但从下文第 3 节的数值结果来看, 这种处理方式是合理有效的. 在后续研究工作中, 将继续探索 GNN 训练过程中其他处理边界条件的可行方法.

3 数值模拟

在本节中, ISPH_GNN 结合基于溃坝和液舱晃

荡算例生成的数据训练得到的 GNN 模型被应用于孤立波爬越阶梯、规则波与水下梯形结构的相互作用, 浮体在孤立波下的运动等不同波浪-结构物相互作用问题的模拟. 这些波浪-结构物相互作用问题相比用于训练 GNN 模型的溃坝和液舱晃荡算例更加复杂.

3.1 孤立波冲击阶梯结构

首先, 使用 ISPH_GNN 模拟孤立波爬越阶梯结构, 并将使用 Seabra-Santos 等^[34]的实验数据作为对比验证数值模型的准确性. 当前计算域的示意图如图 4 所示, 其中水深为 $D = 0.2$ m, 数值计算从入射波峰通过 $x = 0$ m 处开始. 浅水区的水深为 $d = 0.5D$, 台阶边缘位于 $x = 15D$ 处. 两个波高仪 G_1 和 G_2 分别布置在 $x = 15D$ 和 $x = 30D$ 处, 用于记录波面变化. 本算例中初始粒子间距取为 0.01 m, 即 $D/dx = 20$.

图 5 展示了使用 ISPH_GNN 模拟的孤立波爬越台阶过程中不同时刻的压力场. 从图 5(a) 可以看到, 孤立波波前到达台阶边缘, 随后在图 5(b) 中越过




图 4 孤立波爬越阶梯的数值模拟波浪水槽示意图

Fig. 4 Schematic setup of wave tank for solitary wave overtopping




图 5 孤立波冲击阶梯结构算例的 ISPH_GNN 模拟结果中不同时刻的粒子分布及压力场

Fig. 5 Snapshots illustrating distribution of particles along with pressure field from the ISPH_GNN in the case of solitary wave propagation over a step at different time instants


台阶. 同时, ISPH_GNN 能够在不同时刻模拟出均匀平滑的压力场分布, 特别是在台阶附近, 表现出良好的稳定性.

图 6 比较了分别来自实验数据, 以及 ISPH 和 ISPH_GNN 数值结果的 G_1 和 G_2 位置处波形时间历程. 总体来看, ISPH 和 ISPH_GNN 的数值波形结果与实验数据均表现出良好的一致性. 以图 6 中的实验结果作为参考, ISPH_GNN 和 ISPH 在 G_1 测点处波形结果中的误差分别为 5.2% 和 5.9%; 在 G_2 测点处结果中的误差分别为 7.9% 和 7.3%. 误差是通过下述公式获得


$$Err_a = \frac{\sqrt{\sum_{i=1}^N (\eta_{i,n} - \eta_{i,e})^2}}{\sqrt{\sum_{i=1}^N \eta_{i,e}^2}} \quad (23)$$

其中, $\eta_{i,e}$ 是图 6 不同时刻的实验数据, $\eta_{i,n}$ 则是对应的 ISPH_GNN 结果, N 是从 $t = 1.0 \sim 3.0$ s 期间的总数据点个数. 上述结果表明了 ISPH_GNN 在波浪与结构相互作用模拟中的适用性与可靠性.

为了探究 ISPH_GNN 在模拟预测中采用与 GNN 训练阶段不同粒子分辨率 ($dx = 0.01$ m) 时的



(a) G_1 处波高时间历程
(a) Wave elevation time history at G_1




(b) G_2 处波高时间历程
(b) Wave elevation time history at G_2

图 6 不同测点处实验数据^[33]与数值模拟的波高时间历程的对比


Fig. 6 Comparison of experimental data^[33] and simulated wave elevation time history at different measuring points

表现, 图 7(a) 给出不同粒子分辨率下 ISPH_GNN 预测的 G_1 位置处波形时间历程. 数值结果的误差分析如图 7(b) 所示, 可以看出, 随着粒子尺寸的减小, ISPH_GNN 结果的误差线性降低, 表现出与传统 ISPH 相似的线性收敛性. 这表明在模拟预测阶段, ISPH_GNN 采用与训练阶段不同的粒子分辨率时仍可以取得合理的模拟预测结果. 这也充分展现了 ISPH_GNN 在不同粒子分辨率条件下的适应性和稳定性.



(a) 不同粒子分辨率下 ISPH_GNN

数值结果的对比
(a) Comparison of numerical results from ISPH_GNN at different particle resolutions



(b) 不同粒子分辨率下数值结果的误差
(b) Error in numerical results at different particle resolutions

图 7 不同粒子分辨率下 ISPH_GNN 模拟的 G_1 位置处波高时间历程结果及相应误差

Fig. 7 The wave elevation time history at position G_1 and corresponding errors under different particle resolutions for ISPH_GNN simulation

3.2 规则波冲击水下梯形结构物

其次, 采用 ISPH_GNN 方法模拟研究了规则波浪对水下梯形结构的冲击. 相关实验由 Ohya 等^[35]开展, 数值模拟计算域的设置如图 8 所示. 在本算例中, 深水区的水深设定为 $D = 0.5$ m, 而结构物平台上方区域的水深为 $d = 0.3D$. 数值模拟中, 波浪周期为 $T = 1.34$ s, 波高分别取 $H = 0.05D, 0.1D$. 初始粒子间距 dx 设定为 0.01 m, 即 $D/dx = 50$.

图 9 展示了波高 $H = 0.1D$ 工况下波浪冲击梯形结构物过程中不同时刻的流场压力分布. 如图所示, ISPH_GNN 模拟结果中整体流场的压力分布均匀, 尤其是在靠近结构物的区域, 压力分布依然保持平稳和光滑.

图 10 则比较了数值结果和实验数据在波高测点 G_1 处 (位于 $x/D = 16.4$ 处) 的波形时间历程. 可见, 尽管存在一些差异, 但 ISPH_GNN 预测的结果与 SPH 结果和实验数据均吻合良好. 根据图 10 中的实验结果, ISPH_GNN 和 ISPH 在 $T = 1.34$ s, $H = 0.05D$ 工况下 G_1 测点处波形结果中的误差分别为 8.3% 和 10.4% (图 10(a)); $T = 1.34$ s, $H = 0.1D$ 工况下模拟结果的误差分别为 15.6% 和 18.7% (图 10(b)). 由此可见, ISPH_GNN 的结果与实验数据的吻合度略高于 ISPH 方法. 上述误差可能源自以下方面: 传统 ISPH 方法中采用线性离散方法离散拉普拉斯算




图 8 规则波与浸没梯形结构物相互作用示意图

Fig. 8 Sketch of regular wave interaction with a submerged trapezoidal structure




图 9 不同时刻 ISPH_GNN 结果的粒子分布及压力场

Fig. 9 Snapshots illustrating distribution of particles along with pressure field from the ISPH_GNN at different time instants




图 10 不同波浪工况下波浪与浸没梯形结构物相互作用过程中测点处的波高时间历程对比

Fig. 10 The comparison of simulated wave elevation time histories for the case of wave interaction with a submerged trapezoidal structure under different wave conditions

子以及结构物边界的边界条件,这极大地限制了PPE求解精度,而ISPH_GNN中采用的固体边界条件的处理也会在一定程度上影响边界粒子压力求解精度,尤其是在处理复杂形状的边界问题时,这种影响可能更为显著。

3.3 规则波中浮式箱体的运动响应

本节中,ISPH_GNN被应用于模拟规则波与自由漂浮箱体的相互作用,Ren等^[36]进行了该算例的相关实验研究.数值模拟所采用的计算域的示意图如图11所示.其中水深为 $d = 0.4\text{ m}$,箱体的宽度为 $b = 0.75d$,高度为 $h = 0.5d$.箱体的密度为 500 kg/m^3 ,从而其在静水中初始状态为半浸没,即初始吃水深度为 $0.25d$.初始时,箱体的质心位置为 $(20.0d, 1.0d)$.在此算例中,波高为 $H = 0.1d$,波周期为 $T = 1.2\text{ s}$.初始粒子尺寸为 $dx = 0.01\text{ m}$,即 $d/dx = 40$.

图12展示了ISPH_GNN模拟结果与实验照片^[35]




图 11 自由浮体与波浪相互作用的计算域示意图

Fig. 11 Sketch of wave interaction with a freely floating box




图 12 不同时刻浮体运动状态的对比: 实验图片 (上) 与 ISPH_GNN 结果 (下)

Fig. 12 Comparison of the floating box motions between experimental images (up) and ISPH_GNN results (down) at various time points

在不同时刻下浮体运动状态的对比。从图 11(a) 可以看出, 浮体在波浪作用下逐渐上升。随后, 如图 11(b) 所示, 浮体发生顺时针旋转, 并在时刻 $T_0 + 2T$ 返回到水平位置 (见图 11(c))。接着, 浮体开始逆时针旋转, 如图 11(d) 所示。ISPH_GNN 模拟的浮体运动状态与实验观测的浮体运动状态基本一致。在整个模拟过程中, ISPH_GNN 方法持续生成平滑且连续的压力场分布。

图 13 对比了 ISPH_GNN 模拟结果与实验数据中浮体横荡、垂荡和横摇运动的时间历程。总体来看, 数值结果与实验数据吻合较好, 尽管在某些时刻仍存在一定差异。根据图 13 中的实验结果, ISPH_GNN 和 ISPH 在横荡运动结果中的误差分别为 3.8% 和 4.1% (见图 13(a)); 在垂荡运动结果中的误差分别为 7.5% 和 8.9% (见图 13(b)); 在横摇运动结果中的误差分别约为 13.3% 和 15.2% (见图 13(c))。ISPH_GNN 和 ISPH 的横摇运动模拟结果的误差较

大, 可能原因分析如下: 浮体在波浪中的横摇运动受到波浪力矩、浮体惯性矩和阻尼等多种因素的影响, 这些因素相互作用, 使得横摇运动的模拟相对复杂。此外, 如前所述, 传统 ISPH 方法采用线性离散方法离散结构物边界的边界条件极, 而 ISPH_GNN 中采用的固体边界条件的处理, 这都在一定程度上限制了边界粒子压力求解精度。特别是在浮体横摇运动过程中, 边界条件的快速变化可能导致压力求解的误差增大, 从而导致横摇运动模拟结果误差也随之增大。

总体而言, 上述模拟结果表明, 融合基于简单算例数据训练的 GNN 模型的 ISPH_GNN 方法能够有效地应用于模拟更复杂的波浪与结构物相互作用案例, 并产生令人满意的模拟结果, 这充分体现了 ISPH_GNN 在波浪与结构物相互作用问题中的良好的泛化性潜力。

4 计算效率

计算效率是评估 ISPH_GNN 方法在模拟波浪与结构物相互作用中的性能的关键因素之一。为深入探究 ISPH_GNN 的计算效率, 图 14 展示了 ISPH_GNN 与传统 ISPH 模型在单个时间步所需压力预测时间的比较。为此, 采用 3.2 节中 $T = 1.34$ s, $H = 0.05D$ 工况下的规则波冲击水下梯形结构物的算例, 并结合表 1 中列出的不同计算参数进行了比较分析。所有模拟均在配备具有 256 GB 内存和 2.9 GHz 运行频率的 Intel Xeon Platinum 8268 CPU 以及具有 24 GB 内存的 NVIDIA GeForce RTX 3090 GPU 的工作站上执行。

从图 14 可以明显看出, 相比于传统 ISPH 方法, 使用 GNN 模型代替求解 PPE 后, ISPH_GNN 方法中的压力预测时间显著缩短, 即压力预测速度得到




图 13 浮体运动时间历程对比

Fig. 13 Comparison of the time histories of the floating box motions

表 1 规则波与水下梯形结构相互作用的算例配置

Table 1 Case configurations for the regular wave interactions with a submerged trapezoidal structure

Case	D/m	L/m	dx/m	N
1	0.5	20	0.01	92285
2	0.5	40	0.01	192285
3	0.5	80	0.01	392285
4	1.0	80	0.01	792285
5	1.0	130	0.01	1292285

了显著提升. 随着粒子数量的增加, 压力预测效率的加速比也显著提高. 例如, 在约 130 万个粒子的工况下, ISPH_GNN 在压力预测上比传统 ISPH 方法加速约 93 倍. 这表明 ISPH_GNN 方法在大规模粒子数的数值模拟中具有显著优势.

此外, 为了探究 ISPH_GNN 在不同计算域尺寸下的模拟精度, 图 15 展示规则波冲击水下梯形结构物的算例中 $D = 0.5$ m, L 分别为 20, 40 和 60 m 的 3 组不同计算域尺寸下 ISPH_GNN 模拟结果的对比. 与实验结果相比, 对应的误差分别为 8.3%, 8.6% 和 8.5%, 由此可见, 在不同计算域尺寸下, ISPH_GNN 均能取得相似准确度的模拟结果. 这表明 ISPH_GNN 在大计算域尺寸大规模粒子数的数值模拟中, 在压力预测效率显著提升的同时也能确保计算准确性.

在 ISPH 方法中, PPE 求解是采用迭代求解方法实现的, 该方法通过反复迭代更新压力值, 直到满足收敛条件. 在传统 ISPH 方法中, PPE 的求解时间会随着粒子数的增大而显著增加, 如本文中的规则波

与水下梯形结构相互作用的算例中可见, PPE 的求解时间会随着粒子数的增加而 2 倍增加. 此外 PPE 的求解效率会受到粒子分布状态的显著影响. 尤其是在涉及破碎波的复杂流固耦合问题中, 剧烈的界面变形会导致粒子分布高度不均匀, 使得离散化 PPE 对应的系数矩阵条件数急剧恶化. 此时, 迭代求解器往往需要更多次迭代方能收敛, 显著增加了 PPE 求解计算成本. 相比之下, ISPH_GNN 方法展现出独特的计算优势. GNN 模型的压力预测耗时仅随粒子数量呈近似线性微幅增长, 此外, 其压力预测时间也不会受到粒子分布状态的影响. 针对不同复杂程度的流固耦合问题, 在大规模粒子数的情况下, ISPH_GNN 在压力预测方面相较于传统 ISPH 方法始终具备加速效果. 尤其是在处理涉及破碎波的剧烈流固耦合问题时, 理论 ISPH_GNN 在压力预测上比传统 ISPH 方法的加速效果会更加明显. 当然, ISPH_GNN 在剧烈流固耦合问题上的模拟精度和计算效率表现需要在未来工作得到进一步探究评估.

目前, 基于并行技术加速求解 PPE 的方法主要有基于图形处理单元 (GPU) 和消息传递接口 (MPI) 的并行加速算法. 基于 GPU 并行加速求解 PPE 主要是将 PPE 的每次迭代求解过程分解为多个独立的计算任务, 分配给 GPU 的多个核心同时执行, 利用 GPU 的并行计算能力实现 PPE 的并行加速求解^[37]. 而基于 MPI 并行加速求解 PPE, 则是在每次迭代过程中将计算区域划分为多个子区域, 每个子区域分配给一个进程进行计算, 结合高效的通信策略, 通过多个进程并行协同完成大规模计算任务^[38]. 然而, 基于 GPU/MPI 等并行求解 PPE 的方法, 在每个时间步求解 PPE 时仍需执行完整的迭代流程. 因此, 并行计算速度在很大程度上依旧依赖于迭代收敛速度. 由此可以预见, 基于 GPU/MPI 等的并行求解 PPE 方法的计算效率仍会受到粒子分布状态的显著影响. 当粒子分布不均匀引发矩阵病态时, 即便采用 GPU/MPI 等并行加速计算技术, 单时间步 PPE 求解的计算耗时也会显著增加.

相比之下, ISPH_GNN 采用学习输入参数到压力场的端到端隐式映射关系的 GNN 模型替代 PPE 的求解, 将压力求解转化为前向推理过程, 无需迭代求解而直接预测获得压力, 因此求解预测效率不受粒子分布状态影响. 所以, 相较于基于 GPU/MPI 的并行加速算法, ISPH_GNN 方法在压力求解方面具




图 14 规则波与浸没梯形结构相互作用算例中每步压力预测的平均计算时间

Fig. 14 The averaged computational time used for pressure prediction per step for the case of regular wave interactions with a submerged trapezoidal structure




图 15 规则波冲击水下梯形结构物的算例中不同计算域尺寸下 ISPH_GNN 模拟的波高时间历程对比

Fig. 15 The comparison of simulated wave elevation time histories for the case of wave interaction with a submerged trapezoidal structure under different computational domain sizes

有计算效率上的优势. 尽管 ISPH_GNN 在计算效率层面展现优势, ISPH_GNN 在数值模拟中的准确性和泛化性能依然需要在未来工作得到进一步验证.

5 结论

本文应用一种 GNN 和 ISPH 的耦合方法 (ISPH_GNN) 对波浪与结构物相互作用进行了数值模拟研究. 在这种方法中, 仅基于简单算例数据训练得到的 GNN 模型取代了传统 ISPH 中的 PPE 求解. 随后, 融合该 GNN 模型的 ISPH_GNN 被应用于模拟多种更复杂的波浪与结构物的相互作用问题, 包括孤立波爬越阶梯、规则波与水下梯形结构的相互作用以及浮体在规则波作用下的运动. 这些问题远远超出了用于生成训练数据的溃坝和液舱晃荡等算例的范畴. 数值结果表明, ISPH_GNN 在波浪与结构物相互作用模拟研究中表现出色. 体现了 ISPH_GNN 良好的泛化能力.

此外, 在相同粒子间距条件下, ISPH_GNN 能够生成与传统 ISPH 相似的结果, 并且在大多数情况下误差略小于传统 ISPH. 然而, 与传统 ISPH 方法相比, ISPH_GNN 方法在压力预测方面的计算效率显著提高, 尤其在大规模粒子数的工况下, 表现出极其显著的加速效果. 这些结果充分表明 ISPH_GNN 在波浪与结构物相互作用的数值模拟研究中具有巨大的应用潜力和优势.

然而, ISPH_GNN 方法在不同复杂程度的波浪与结构物相互作用问题数值模拟中的准确性和泛化性能仍需要通过更广泛的数值模拟进行进一步验证. 未来的工作也将探索 ISPH_GNN 在三维波浪与结构物相互作用问题中的应用表现.

参 考 文 献

- 1 滕斌. 波浪对结构物作用的分析理论和应用. 北京: 海洋出版社, 2016 (Teng Bin. Theoretical Analysis and Application of Wave Action on Structures. Beijing: Ocean Publishing House, 2016 (in Chinese))
- 2 于小伟, 周骏, 罗瑞锋等. 新型浮式平台波浪载荷分析与结构强度评估. 造船技术, 2022, 50(5): 30-34 (Yu Xiaowei, Zhou Jun, Luo Ruifeng, et al. Analysis of wave loads and structural strength assessment for a new type of floating platform. *Shipbuilding Technology*, 2022, 50(5): 30-34 (in Chinese))
- 3 Lucy LB. A numerical approach to the testing of the fission hypothesis. *Astronomical Journal*, 1977, 8(12): 1013-1024
- 4 Gingold RA, Monaghan JJ. Smoothed particle hydrodynamics — Theory and application to non-spherical stars. *Monthly Notices of the Royal Astronomical Society*, 1977, 181(3): 375-389
- 5 Sun PN, Ming FR, Zhang AM. Numerical simulation of interactions between free surface and rigid body using a robust SPH method. *Ocean Engineering*, 2015, 98: 32-49
- 6 何方. 基于光滑粒子动力学的波浪-结构物相互作用过程三维模拟研究. 中国科学: 物理学 力学 天文学, 2022, 52(10): 184-200 (He Fang. Three-dimensional simulation study of wave-structure interaction process based on smoothed particle hydrodynamics. *Science China: Physics, Mechanics & Astronomy*, 2022, 52(10): 184-200 (in Chinese))
- 7 Zhang NB, Ma QW, Zheng X, et al. A two-way coupling method for simulating wave-induced breakup of ice floes based on SPH. *Journal of Computational Physics*, 2023, 488: 112185
- 8 Luo M, Khayyer A, Lin PZ. Particle methods in ocean and coastal engineering. *Applied Ocean Research*, 2021, 114: 102734
- 9 Shao SD, Lo EYM. Incompressible SPH method for simulating newtonian and non-newtonian flows with a free surface. *Advances in Water Resources*, 2003, 26(7): 787-800
- 10 Zheng X, Ma QW, Duan WY. Incompressible SPH method based on Rankine source solution for violent water wave simulation. *Journal of Computational Physics*, 2014, 276: 291-314
- 11 吕锡鹏. ISPH 方法的改进及其在波浪与结构物相互作用问题中的应用. [硕士学位论文]. 哈尔滨: 哈尔滨工程大学, 2017 (Lyu Xipeng. Improvement of the ISPH method and its application in wave-structure interaction problems. [Master Thesis]. Harbin: Harbin Engineering University. 2017 (in Chinese))
- 12 Zhang NB, Yan SQ, Ma QW, et al. A QSFBI based Laplacian discretisation for modelling wave-structure interaction using ISPH. *Applied Ocean Research*, 2021, 117: 102954
- 13 Khayyer A, Gotoh H, Falahaty H, et al. An enhanced ISPH-SPH coupled method for simulation of incompressible fluid-elastic structure interactions. *Computer Physics Communications*, 2018, 232: 139-164
- 14 Shao SD. Incompressible SPH flow model for wave interactions with porous media. *Coastal Engineering*, 2010, 57(3): 304-316
- 15 Gotoh H, Shao SD, Memita T. SPH-LES model for numerical investigation of wave interaction with partially immersed breakwater. *Coastal Engineering Journal*, 2004, 46(1): 39-63
- 16 Ma QW, Zhou Y, Yan SQ. A review on approaches to solving Poisson's equation in projection-based meshless methods for modelling strongly nonlinear water waves. *Journal of Ocean Engineering and Marine Energy*, 2016, 2: 279-299
- 17 Fournakos G, Rogers BD, Nasar AM. Towards pseudo-spectral incompressible smoothed particle hydrodynamics (ISPH). *Computer Physics Communications*, 2021, 266: 108028
- 18 Tompson J, Schlachter K, Sprechmann P, et al. Accelerating eulerian fluid simulation with convolutional networks//International Conference on Machine Learning, PMLR, 2017: 3424-3433
- 19 Dong W, Liu J, Xie Z, et al. Adaptive neural network-based approximation to accelerate eulerian fluid simulation//Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis, 2019: 1-22
- 20 Zhang NB, Yan SQ, Ma QW, et al. A CNN-supported Lagrangian ISPH model for free surface flow. *Applied Ocean Research*, 2023, 136: 103587
- 21 张珍, 叶舒然, 岳杰顺等. 基于组合神经网络的雷诺平均湍流模型多次修正方法. 力学学报, 2021, 53(6): 1532-1542 (Zhang Zhen, Ye

- Shuran, Yue Jieshun, et al. A combined neural network and multiple modification strategy for Reynolds-averaged Navier-Stokes turbulence modeling. *Chinese Journal of Theoretical and Applied Mechanics*, 2021, 53(6): 1532-1542 (in Chinese))
- 22 罗仁宇, 李奇志, 祖公博等. 基于卷积神经网络的超分辨率格子 Boltzmann 方法研究. *力学学报*, 2024, 56(11): 3358-3370 (Luo Renyu, Li Qizhi, Zu Gongbo, et al. A super-resolution lattice Boltzmann method based on convolutional neural network. *Chinese Journal of Theoretical and Applied Mechanics*, 2024, 56(11): 3358-3370 (in Chinese))
 - 23 Kumar K, Vantassel J. GNS: A generalizable graph neural network-based simulator for particulate and fluid modeling. *arXiv preprint arXiv*: 2022, 2211.10228
 - 24 Li Z, Farimani AB. Graph neural network-accelerated Lagrangian fluid simulation. *Computers & Graphics*, 2022, 103: 201-211
 - 25 Zhang NB, Yan SQ, Ma QW, et al. A hybrid method combining ISPH with graph neural network for simulating free-surface flows. *Computer Physics Communications*, 2024, 301: 109220
 - 26 Zhang NB, Zheng X, Ma QW, et al. A hybrid stabilization technique for simulating water wave-structure interaction by incompressible smoothed particle hydrodynamics (ISPH) method. *Journal of Hydro-Environment Research*, 2018, 18: 77-94
 - 27 Ma QW, Zhou J. MLPG_R method for numerical simulation of 2D breaking waves. *Computer Modeling in Engineering & Sciences*, 2009, 43(3): 277-304
 - 28 Sanchez-Gonzalez A, Godwin J, Pfaff T, et al. Learning to simulate complex physics with graph networks//International Conference on Machine Learning, PMLR, 2020: 8459-8468
 - 29 Lino M, Fotiadis S, Bharath AA, et al. Multi-scale rotation-equivariant graph neural networks for unsteady Eulerian fluid dynamics. *Physics of Fluids*, 2022, 34(8): 087110
 - 30 Hendrycks D, Gimpel K. Gaussian error linear units (gelus). *arXiv preprint arXiv*: 2016, 1606.08415
 - 31 Zhang NB, Yan SQ, Ma QW, et al. A consistent second order ISPH for free surface flow. *Computers & Fluids*, 2024, 274: 106224
 - 32 Yan SQ, Ma QW, Wang JH. Quadric SFDI for laplacian discretisation in lagrangian meshless methods. *Journal of Marine Science and Application*, 2020, 19: 362-380
 - 33 Adami S, Hu XY, Adams NA. A generalised wall boundary condition for smoothed particle hydrodynamics. *Journal of Computational Physics* 2012, 231: 7057-7075
 - 34 Seabra-Santos FJ, Renouard DP, Temperville AM. Numerical and experimental study of the transformation of a solitary wave over a shelf or isolated obstacle. *Journal of Fluid Mechanics*, 1987, 176: 117-134
 - 35 Ohyama T, Kioka W, Tada A. Applicability of numerical models to nonlinear dispersive waves. *Coastal Engineering*, 1995, 24(3-4): 297-313
 - 36 Ren B, He M, Dong P, et al. Nonlinear simulations of wave-induced motions of a freely floating body using WCSPH method. *Applied Ocean Research*, 2015, 50: 1-12
 - 37 Chow AD, Rogers BD, Lind SJ, et al. Incompressible SPH (ISPH) with fast Poisson solver on a GPU. *Computer Physics Communications*, 2018, 226: 81-103
 - 38 Monteleone A, Burriesci G, Napoli E. A distributed-memory MPI parallelization scheme for multi-domain incompressible SPH. *Journal of Parallel and Distributed Computing*, 2022, 170: 53-67