

文章编号: 0559-9350(2026)05-0732-12

基于多物理信息神经网络的心墙堆石坝多源数据同化研究

孙明月¹, 马刚^{1, 2, 3}, 张毅¹, 周伟^{1, 2, 3}, 常晓林^{1, 2, 3}(1. 武汉大学 水资源工程与调度全国重点实验室, 湖北 武汉 430072; 2. 武汉大学 水工程科学研究院, 湖北 武汉 430072;
3. 武汉大学 水工岩石力学教育部重点实验室, 湖北 武汉 430072)

摘要: 水利工程的透彻感知对构建数字孪生体系、推动水利高质量发展至关重要。随着大坝安全监测技术的发展和“天空地水工”一体化监测感知网络的建设, 如何同化积累的多源数据进而实现大坝透彻感知是当前研究重点。本文提出一种基于多物理信息神经网络(MPINN)的多源数据同化方法, 其核心在于将大坝应力-渗流多场耦合理论和参数随机场嵌入神经网络并监督模型训练, 在满足物理一致性的情况下充分利用数据驱动方法的灵活性, 实现对大坝工程性态的最优估计。以两河口心墙堆石坝为例, 采用MPINN同化了砾石土心墙的孔隙水压力、土压力监测数据和压缩模量、渗透系数检测数据, 实现了从稀疏数据中重构心墙全域的孔隙水压力场和土压力场。对比实验表明, MPINN在预测准确性和鲁棒性方面均优于其他方法, 验证了数据同化的效果, 为实现水利工程全域的透彻感知提供了一条新途径, 可为数字孪生工程和智能大坝的建设提供技术支撑。

关键词: 智能大坝; 堆石坝; 透彻感知; 数据同化; 多场耦合; 多物理信息神经网络

中图分类号: TV698.2

文献标识码: A

doi: 10.3724/j.slx.20250596

1 研究背景

通过物联网、大数据、人工智能、数字孪生等技术构建智能大坝已成为坝工领域发展的新方向, 也是实现安全大坝、生态大坝的重要手段^[1-2]。对大坝性态全面实时精准感知, 是构建智能大坝的重要一环, 也是实现大坝智能化分析、精准化决策与协同化管理的基础^[3]。随着安全监测技术的快速发展, 逐渐形成了“天空地水工”一体化的大坝监测感知体系, 可以获取多来源、多模态、多类型的数据^[4-5]。但对于体型巨大的大坝而言, 这些数据在空间上仍是相对稀疏的。因此, 如何同化不同来源和类型的数据, 实现大坝全域透彻感知, 是构建智能大坝的迫切需求之一^[6]。

心墙堆石坝存在复杂的应力-渗流多场耦合^[7], 多物理场之间的相互作用关系到大坝安全^[8]。由于多物理场相互作用的强非线性、时间滞后性、空间异质性等特点, 建立多场耦合模型和率定模型参数面临巨大挑战。在堆石坝的心墙区域布置了大量仪器用以监测孔隙压力、土压力、变形等, 但由于复杂的多场耦合作用, 单独分析某一类数据难以全面反映心墙的工作性态。因此, 需要对多源数据进行同化, 以全面准确反映心墙的工作性态。

数据同化是指将不同来源、不同尺度、不同类型的观测数据与物理模型相结合, 以得到对物理系统状态更明确、更完整估计的科学方法, 本质上是一个最优估计问题^[9]。数据同化技术已广泛应用于地球系统科学并获得了巨大成功^[10], 在水利学科的多个方面也得到发展应用^[11-13]。传统的数据同化方

收稿日期: 2025-09-21; 网络首发日期: 2026-04-16

网络首发地址: <https://link.cnki.net/urlid/11.1882.TV.20260416.1137.001>

基金项目: 国家自然科学基金项目(52322907, 52579134, U23B20149)

作者简介: 孙明月(2001—), 博士生, 主要从事堆石坝渗流固结问题研究。E-mail: sunmingyue1027@whu.edu.cn

通信作者: 马刚(1985—), 教授, 主要从事水工结构智能计算和智能设计研究。E-mail: magang630@whu.edu.cn

法,如集合卡尔曼滤波算法^[14],使用一组预测样本来代表系统的状态和不确定性,从而实现模型预测和观测数据的融合。但随着数据量的快速增长,传统数据同化方法难以满足实时或近实时需求^[15]。近年来,机器学习和深度学习算法逐渐被引入数据同化领域^[16-17],其强大的非线性处理能力可以很好地适应急剧增长数据量的需求^[18]。Zhang等^[19]提出了迭代式深度学习算法,实现了高度非线性的水文数据同化;Kheiry等^[20]将概率有限元模型与深度学习算法结合,解决了非饱和堆石坝渗流的数据同化问题。然而,单一数据驱动方法需要大量训练数据,在小样本数据条件下模型效果、预测结果的物理一致性和可解释性难以保证^[21]。

基于此,Raissi等^[22]提出了一种物理信息神经网络(Physics-Informed Neural Network, PINN),令控制方程的残差作为网络损失函数的一部分,将物理知识引入到神经网络中。PINN可以利用不同来源和类型的数据,如流场的速度、压力、温度等,并在物理定律约束下训练网络^[23]。方卫华等^[24]采用PINN进行了对圣维南方程组的数据同化;Wang等^[25]将PINN与蒙特卡洛方法结合,进行地下水渗流数据的同化。由于无需显式求解器、强大的泛化能力、对噪声的鲁棒性以及在处理非线性问题上的优势,PINN已成为解决复杂物理系统数据同化问题的一个极具前景的新范式^[26]。

本文提出了一种基于多物理信息神经网络(Multiphysics-Informed Neural Network, MPINN)的多源数据同化方法。该方法将心墙土体参数随机场引入应力-渗流多场耦合模型,并通过降维与向量化嵌入的方式将随机场参数纳入网络结构,从而在保证物理一致性的前提下提升模型的预测能力,建立起随机场与多物理场耦合问题统一的多源数据同化框架。以两河口心墙堆石坝为例,采用MPINN研究非均质心墙的应力-渗流多场耦合问题,实现对心墙孔隙水压力、土压力的正向预测和渗透系数、压缩模量的逆向反演。该多源数据同化方法能够充分利用工程中的稀疏多源数据,实现对大坝全生命期的透彻感知,为工程安全预警及智能大坝模型提供了新思路。

2 心墙堆石坝多源监测和检测数据

2.1 工程概况 雅砻江两河口水电站的心墙堆石坝高303 m,是已建世界最高心墙堆石坝。大坝典型断面如图1(a)所示,包括堆石区、心墙区、防渗帷幕等。大坝从2016年6月开始填筑,于2020年10月开始蓄水,2021年12月全面填筑到顶,2024年10月首次蓄水至正常蓄水位。大坝共有6个监测断面,如图1(b)所示。心墙区域布置了大量监测仪器,如渗压计、土压力计及电磁式沉降环等,用于持续获取随时间变化的监测信息。同时在大坝填筑过程中,每填筑一定高度需进行一次现场检测,并在重要部位加密检测。通过原状样渗透变形试验、固结试验等,获取心墙不同位置的检测数据,从而评价和控制心墙的填筑质量。监测、检测数据的具体情况见表1。




图1 两河口心墙堆石坝

Fig. 1 LHK core wall rockfill dam

2.2 心墙检测数据 采用原状样渗透变形试验和固结试验,对2590~2774 m高程心墙土体进行了30余组的渗透系数和压缩模量检测。

心墙原状砾石土渗透系数和压缩模量检测数据随高程的分布如图2(a)(b)所示,渗透系数范围

表1 两河口堆石坝心墙区的检测和监测数据来源

Table 1 Sources of monitoring and testing data in the core wall of the LHK dam

监测数据类型	监测仪器名称	监测点数量	监测点代号	检测数据类型	检测试验名称	检测点数量
孔隙水压	渗压计	60	P _{DB}	渗透系数	渗流试验	37
土压力	土压力计	55	E _{DB}			
沉降变形	电磁式沉降环	75	VE	压缩模量	压缩变形试验	38
	柔性测斜仪	4	IN-R			

为 $1.40 \times 10^{-7} \sim 9.20 \times 10^{-6} \text{ cm/s}$ ，水平方向和垂直方差差异很小。压缩模量范围为 $41.2 \sim 81.4 \text{ MPa}$ ，压缩系数范围为 $0.0147 \sim 0.0305 \text{ MPa}^{-1}$ 。检测数据的统计指标见表2，其中相关距离是土体相关性的一种度量标准，在该范围内土性指标基本上是相关的，反之，在该范围之外土性指标基本上不相关^[27]。垂直和水平相关距离由递推空间法计算^[28]。为量化心墙渗透系数和压缩模量检测数据的空间自相关性，图2(c)(d)采用全局莫兰指数^[29]为指标，计算不同空间距离阈值下参数的全局莫兰指数。可以看出，随着空间距离阈值的增大，莫兰指数呈现下降的趋势。而莫兰指数越大，数据空间自相关性越强，说明在一定空间距离范围内，渗透系数和压缩模量具有显著的空间自相关性，可以通过自相关函数^[30]来表示。

表2 心墙检测数据的统计指标

Table 2 Statistical indices of core wall testing data

检测参数	数据范围	均值	标准差	水平相关距离	垂直相关距离
渗透系数 $\times 10^{-6}/(\text{cm/s})$	0.1 ~ 9.2	2.37	2.07	35.0 m	2.5 m
压缩模量/MPa	41.2 ~ 81.4	57.26	9.05	40.0 m	3.0 m
饱和度/%	86.1 ~ 100.0	95.1	4.8		




图2 心墙检测数据统计特性和空间相关性

Fig. 2 Statistical characteristics and spatial correlation of core wall testing data

2.3 心墙孔隙水压力和土压力监测数据 由于心墙掺砾土料的渗透系数低,在填筑蓄水过程中,心墙中的孔隙水压力难以迅速排出,导致心墙土体产生复杂渗流固结变形^[31]。由表2可得,两河口心墙的饱和度均值为95.1%,可视为饱和状态。根据有效应力原理,持续的高孔隙水压力会降低心墙的有效应力。同时由于心墙和坝壳之间的变形模量差异,在施工及运行过程会出现沉降差,使得心墙内部的土压力降低^[32]。这种高孔隙水压力和低土压力的共同作用可能会导致心墙出现裂缝甚至水力劈裂的现象^[33]。

心墙内部布设了渗压计和土压力计(见图3),分别监测心墙的孔隙水压力和土压力。心墙的渗流固结过程是一个典型的多场耦合过程,其渗流场和应力场相互影响。因此,心墙的孔隙水压和土压监测数据必然存在时空相关性。令孔隙水压力和土压力监测点两两组合,采用动态时间规整法^[34](Dynamic Time Warping, DTW)计算每个测点对的时序特征相似度。DTW距离越小,相似度越高。图4展示了测点对空间距离与DTW距离之间的关系,可以看出孔隙水压力测点与土压力测点之间的距离越近,DTW距离也越小,二者时间序列的相关性也越强。说明孔隙水压力和土压力在一定距离内互相影响,体现了二者之间的时空相关性,在计算时需要考虑其耦合作用,共同分析物理量的变化。




图3 心墙应力监测点分布

Fig. 3 Distribution of stress monitoring points in the core wall

3 基于MPINN的多源数据同化方法

上述分析说明孔隙水压力、土压力以及渗透系数、压缩模量是反映心墙工作性态的关键指标,在实际工程中相互关联,共同反映了心墙的整体工作状态。对上述关键指标进行耦合分析,不仅能实现跨物理场监测、检测数据的协同验证,还能揭示不同物理过程之间的内在联系,从而提升工程性态评价的全面性与准确性^[35]。在此背景下,对测量数据的独立分析难以充分刻画上述复杂关联性,因此亟需一种考虑多物理场耦合的数据同化方法。

3.1 非均质土体的固结理论 比奥固结理论描述了当外荷载作用在饱和土层时,孔隙水压力和土压力是如何变化的^[36]。比奥固结理论既满足应力应变关系和平衡条件,又满足变形协调条件和水流连续方程,是均质土渗流固结过程的基础理论。

在实际情况中,岩土体受到形成过程、组成、结构及周边环境等复杂因素的影响,具有显著的空间变异性^[37]。基于比奥固结理论,考虑土体参数的空间异质性,得到非均质土的固结微分方程,描述




图4 测点对空间距离与DTW距离关系

Fig. 4 Relationship between spatial distance and DTW distance of monitoring point pairs

了非均质土的应力-渗流多场耦合过程：

$$\frac{1}{\gamma_w} \operatorname{div}(K(\mathbf{x}) \cdot \nabla u(t, \mathbf{x})) + \frac{1-\nu}{(1+\nu)E_s(\mathbf{x})} \cdot \left(\frac{\partial E(t, \mathbf{x})}{\partial t} - \frac{3\partial u(t, \mathbf{x})}{\partial t} \right) = 0 \quad (1)$$

式中： ν 为泊松比； γ_w 为水的容重； t 为时间； $\mathbf{x}$ 为空间的一个点 (x, y, z) ； $K(\mathbf{x})$ 、 $E_s(\mathbf{x})$ 分别为渗透系数和压缩模量，是随空间位置变化的函数； $u(t, \mathbf{x})$ 为孔隙水压力； $E(t, \mathbf{x})$ 为总土压力。

3.2 随机场理论 从渗透系数和压缩模量的检测数据可以看出，心墙土体具有显著的空间异质性，可以用自相关函数来表示。为了描述非均质土体的参数分布，引入了随机场的概念^[38]，即将土体参数模拟为空间位置坐标的随机函数 $F(\mathbf{x})$ 。土体的空间相关性一般采用高斯型自相关函数 $\rho(\mathbf{x}_m, \mathbf{x}_n)$ 表示^[30]。

本文采用Karhunen-Loeve(KL)级数展开法，对随机场进行级数展开。土体参数一般服从对数正态随机场^[39]，即对数化后的参数可以用随机场 $R(\mathbf{x}, \tau)$ 表示，其中 $\mathbf{x} \in D$ (物理域)， $\tau \in \Theta$ (概率空间)，可以用一组 n 维独立随机变量 $\xi = [\xi_1(\tau), \xi_2(\tau), \dots, \xi_n(\tau)]$ 参数化，随机场表示为：

$$R(\mathbf{x}, \tau) = \bar{R}(\mathbf{x}) + R'(\mathbf{x}, \tau) = \bar{R}(\mathbf{x}) + \sum_{i=1}^n \sqrt{\lambda_i} f_i(\mathbf{x}) \xi_i(\tau) \quad (2)$$

式中： $R(\mathbf{x}, \tau)$ 为随机场最终离散值； $\bar{R}(\mathbf{x})$ 为随机场的平均值； $R'(\mathbf{x}, \tau)$ 为偏移量； λ_i 和 $f_i(\mathbf{x})$ 为 $\rho(\mathbf{x}_m, \mathbf{x}_n)$ 第 i 个特征值和特征函数； $\xi_i(\tau)$ 为考虑随机场之间互相关性的均值为零的正交高斯随机变量。

本文考虑渗透系数 K 和压缩模量 E_s 的空间变异性。KL展开后的参数可以表示为 $K(\mathbf{x}, \tau) = \exp(R_K(\mathbf{x}, \tau))$ 和 $E_s(\mathbf{x}, \tau) = \exp(R_{E_s}(\mathbf{x}, \tau))$ ，其中 $R_K(\mathbf{x}, \tau)$ 和 $R_{E_s}(\mathbf{x}, \tau)$ 分别为渗透系数和压缩模量的对数随机场。

3.3 多物理信息神经网络 PINN是基于神经网络扩展的一组算法^[40]，将复杂物理定律与数据驱动相结合，减少了对标记数据的依赖，增强了模型的可解释性^[22]。考虑土体性质的空间变异性，本文提出MPINN，将参数随机场与渗流-应力场耦合，从而实现非均质心墙多场耦合问题的数据同化。图5展示了基于MPINN的多源数据同化框架。




图5 基于MPINN的多源数据同化框架

Fig. 5 Multi-source data assimilation framework based on MPINN

为了求解函数 $f(t, \mathbf{x}) = 0$ ，构建一个神经网络模型 $NN(t, \mathbf{x}; \theta)$ 用于近似该函数。其中， $\theta = [(\mathbf{W}_i, \mathbf{b}_i)]_{i=1}^L$ ， $\mathbf{W}$ 和 $\mathbf{b}$ 表示整个网络的权重和偏置， L 为网络层数。

损失函数通常是预测值和真实值之间的均方误差，监测数据损失函数可以表示为：

$$\mathcal{L}_{\text{Monitoring_Data}} = \frac{1}{N_l} \sum_{i=1}^{N_l} |NN(t_i, \mathbf{x}_i; \boldsymbol{\theta}) - f_i|^2 \quad (3)$$

式中： N_l 为标记数据的数量； f_i 为实际值，即孔隙水压力和土压力监测数据。

对于非均质心墙的多场耦合问题，将固结理论微分方程作为控制方程加入到 MPINN 的物理损失中。渗透系数和弹性模量的空间分布由随机变量 ξ 决定的随机场来描述。 ξ 设置为可训练参数，通过自定义梯度进行参数更新。将 $K(\mathbf{x}, \tau) = \exp(R_K(\mathbf{x}, \tau))$ 和 $E_s(\mathbf{x}, \tau) = \exp(R_{E_s}(\mathbf{x}, \tau))$ 代入式(1)，微分方程的残差表示为：

$$f(t, \mathbf{x}) = \frac{1}{\gamma_w} \text{div}(\exp(R_K(\mathbf{x}, \tau)) \nabla NN_u(t, \mathbf{x}; \boldsymbol{\theta})) + \frac{1 - \nu}{1 + \nu} \left(\frac{\partial NN_{E_s}(t, \mathbf{x}; \boldsymbol{\theta}) - 3 \partial NN_u(t, \mathbf{x}; \boldsymbol{\theta})}{\exp(R_{E_s}(\mathbf{x}, \tau)) \partial t} \right) \quad (4)$$

残差构成的微分方程损失项表示为：

$$\mathcal{L}_{\text{PDE}} = \frac{1}{N_c} \sum_{i=1}^{N_c} |f(t_i, \mathbf{x}_i)|^2 \quad (5)$$

式中： $\{t_i, \mathbf{x}_i\}_{i=1}^{N_c}$ 为配点，保证在该处满足微分方程； N_c 为配点的数量。

同时为了使网络训练下的材料参数与实际检测结果保持一致，设置参数的损失函数：

$$\mathcal{L}_{\text{Testing_Data}} = \frac{1}{N_K} \sum_{i=1}^{N_K} |\ln K(\mathbf{x}_i) - \ln \hat{K}(\mathbf{x}_i, \tau)|^2 + \frac{1}{N_{E_s}} \sum_{i=1}^{N_{E_s}} |\ln E_s(\mathbf{x}_i) - \ln \hat{E}_s(\mathbf{x}_i, \tau)|^2 \quad (6)$$

式中： N_K 和 N_{E_s} 分别为渗透系数和压缩模量的检测数据数量； $K(\mathbf{x}_i)$ 和 $E_s(\mathbf{x}_i)$ 分别为渗透系数和压缩模量的检测值； $\hat{K}(\mathbf{x}_i, \tau)$ 和 $\hat{E}_s(\mathbf{x}_i, \tau)$ 为参数计算值，由训练得到的随机变量根据式(2)计算得到。因此，式(3)(6)共同构成损失函数的数据损失项。

边界条件损失和初始条件损失表示为：

$$\mathcal{L}_{\text{BC}} = \frac{1}{N_{\text{BC}}} \sum_{i=1}^{N_{\text{BC}}} |NN(t_i^{\text{BC}}, \mathbf{x}_i^{\text{BC}}; \boldsymbol{\theta}) - f_{\text{BC}}(\mathbf{x}_i^{\text{BC}})|^2 \quad (7)$$

$$\mathcal{L}_{\text{IC}} = \frac{1}{N_{\text{IC}}} \sum_{i=1}^{N_{\text{IC}}} |NN(t_i^{\text{IC}}, \mathbf{x}_i^{\text{IC}}; \boldsymbol{\theta}) - f_{\text{IC}}(\mathbf{x}_i^{\text{IC}})|^2 \quad (8)$$

式中： $\{t_i^{\text{BC}}, \mathbf{x}_i^{\text{BC}}\}_{i=1}^{N_{\text{BC}}}$ 和 $\{t_i^{\text{IC}}, \mathbf{x}_i^{\text{IC}}\}_{i=1}^{N_{\text{IC}}}$ 分别为边界条件和初始条件点； N_{BC} 和 N_{IC} 分别为边界条件和初始条件点数量。

总损失函数可以表示为：

$$\mathcal{L}_{\text{Total}} = \lambda_{\text{Data}} (\mathcal{L}_{\text{Monitoring_Data}} + \mathcal{L}_{\text{Testing_Data}}) + \lambda_{\text{PDE}} \mathcal{L}_{\text{PDE}} + \lambda_{\text{BC}} \mathcal{L}_{\text{BC}} + \lambda_{\text{IC}} \mathcal{L}_{\text{IC}} \quad (9)$$

式中 λ_{Data} 、 λ_{PDE} 、 λ_{BC} 和 λ_{IC} 为控制对应损失的权重值，均取为 1^[21]。训练过程通过优化算法调整网络参数 $\boldsymbol{\theta}$ 并最小化损失函数 $\mathcal{L}_{\text{total}}$ ，最终实现非均质心墙应力-渗流多场耦合问题的求解。监测数据和检测数据分别构成了对应的数据损失项，在数据同化的过程中不断约束网络的优化方向。

4 心墙数据同化结果与分析

4.1 MPINN 结构和网络训练 收集两河口心墙堆石坝心墙区域的检测和监测数据，构建了考虑多场耦合的 MPINN 模型。由于上下游堆石区和心墙的渗透系数相差较大，假设堆石区域为没有时间迟滞的自由排水区。渗流边界条件可以分为溢出边界条件、不透水边界条件和水头边界条件^[41]。

心墙下游水位以上边界设置为溢出边界，不设置额外约束；上游水位以上边界设置为不透水边界，孔隙水压设置为 0，代表孔压在边界处完全消散：

$$u(\mathbf{x} \in \Pi_{\text{up}}, t) = 0 \quad (10)$$

式中 Π_{up} 为心墙的上游边界。

心墙上、下游水位以下边界设置为水头边界，即孔隙水压设置为对应水位的静水压力：

$$\begin{cases} u(\mathbf{x} \in \Pi_{up}, t) = \rho g (y_{up} - y_0) \\ u(\mathbf{x} \in \Pi_{down}, t) = \rho g (y_{down} - y_0) \end{cases} \quad (11)$$

式中： Π_{down} 为心墙的下游边界； ρ 为水的密度； g 为重力加速度； y_0 为心墙底部高程； y_{up} 、 y_{down} 分别为心墙上、下游边界对应点的高程。

初始条件设置为：

$$\begin{cases} u(t=0) = u_0 \\ E(t=0) = E_0 \end{cases} \quad (12)$$

式中 u_0 和 E_0 分别为初始时刻孔隙水压力和土压力的实际值。

设置KL展开保留99%的能量，即展开项 $n(\xi)=30$ 。构建一个5个隐藏层的神经网络，每层有50个神经元，激活函数为 $\tanh$ 。神经网络的标记数据均来自表1的数据。网络输入为每个测点的时空坐标，神经网络的输出为心墙孔隙水压力和土压力，共5000组时空数据。归一化后的数据被划分为训练集(60%)、验证集(20%)和测试集(20%)，训练过程中采用十折交叉验证。设置训练轮次为1000，优化器为Adam，学习率为0.001。评价指标采用决定系数(R-Square, R^2)和平均绝对误差(Mean Absolute Error, MAE)。

4.2 训练结果分析 在物理定律与多源数据的双重约束下，训练后的MPINN能够同时实现正向压力预测和逆向参数反演。

图6(a)展示了训练集损失中各组成成分的变化，其中物理驱动损失和数据驱动损失占总损失的比重较大，体现了物理与数据双驱动在神经网络训练中起到的重要作用。图6(b)展示了训练集和验证集的损失曲线，可以看出二者同步下降并趋于稳定，表明网络训练过效果良好，没有出现拟合等现象。




图6 MPINN 损失曲线

Fig. 6 MPINN loss curves

图7展示了孔隙水压力、土压力的正向预测效果，以及渗透系数、压缩模量的直接反演效果。正向预测值与实测数据的拟合度达到了 $R^2 > 0.97$ ，逆向反演值与现场检测数据的拟合度达到了 $R^2 > 0.93$ 。可以看出，MPINN在正向和逆向任务中均表现出较高精度，充分体现了基于MPINN的多源数据同化方法在复杂多场耦合问题求解中的优势。

图8展示了竣工期(2021年12月)时典型断面(心墙断面、3-3断面)的孔隙水压力与土压力预测结果和测点残差绝对值分布。MPINN利用稀疏监测、检测数据重构出了心墙全域的孔隙水压力场和土压力场，实现了对心墙的透彻感知。




图7 MPINN 训练结果

Fig. 7 The training results of MPINN




图8 典型断面多场分布云图与测点残差绝对值分布

Fig. 8 Multi-field contour maps of typical cross sections and distributions of absolute residual at monitoring points

4.3 模型对比分析 为了验证 MPINN 的优越性,以孔隙水压预测为例,对比了其与有限元法(Finite Element Method, FEM)、深度神经网络(Deep Neural Network, DNN)^[42]、时空图神经网络(Spatio-Temporal Graph Neural Network, STGNN)^[43]、PINN^[22]的预测精度。采用 ABAQUS 软件进行 FEM 数值模拟,其余方法均采用成熟的 Python 机器学习库。具体结构及训练时间见表 3。

表3 不同模型结构设置及训练时间

Table 3 Different model architectures and training time

方法	结构设置	计算时间/s
FEM	渗透系数和压缩模量参数设置为检测数据的均值,控制方程为比奥固结理论的方程	54842
DNN	5个隐藏层,每层有50个神经元,激活函数为 tanh,训练轮次为1000,优化器为 Adam,学习率为0.001	2052
STGNN	3个1D卷积层,2个GCN层,通道数为50,卷积核大小为4,激活函数为 tanh,训练轮次为1000,优化器为 Adam,学习率为0.001	4786
PINN	5个隐藏层的神经网络,每层有50个神经元,激活函数为 tanh,训练轮次为1000,优化器为 Adam,学习率为0.001,渗透系数和压缩模量参数设置为检测数据的均值	6965
MPINN	5个隐藏层的神经网络,每层有50个神经元,激活函数为 tanh,训练轮次为1000,优化器为 Adam,学习率为0.001,随机场展开项数为30,渗透系数和压缩模量随机场均值和方差设置为检测数据的均值和方差	7250

从图9可知,考虑了土体非均质性的MPINN在孔隙水压力的预测中表现最好,计算MAE均值,得到MPINN的预测精度相比FEM、DNN、STGNN、PINN分别提升了71.43%、65.21%、43.61%、31.58%。选择某一测点,图10展示了不同模型对该测点时序预测值与监测值的对比情况,实线为模型交叉验证试验的均值,阴影部分为模型交叉验证试验的标准差带。可以看出MPINN的孔隙水压预测值与监测数据最为一致,且预测误差带最窄,表现出最佳的预测准确性和鲁棒性。




图9 不同模型的MAE对比

Fig. 9 MAE comparison among different models




图10 不同模型孔隙水压力预测值与监测值对比

Fig. 10 Comparison between prediction and reference of pore water pressure among different models

5 结论

透彻感知是实现大坝数字化、网络化和智能化运行管理的基础,而如何同化大坝多源数据仍是当前研究的难点。本文提出了一种基于MPINN的多源数据同化方法,研究了非均质心墙堆石坝的应力-渗流多场耦合问题,得到如下主要结论:

(1)提出了一种结合应力-渗流多场耦合模型与参数随机场的MPINN方法,将心墙孔隙水压力、土压力监测数据与渗透系数、压缩模量检测数据联合纳入网络训练。通过自定义梯度令随机场变量与网络参数共同更新,实现了压力的正向预测与参数场的逆向反演。

(2)在物理定律和多源数据的双重约束下,MPINN可以准确预测孔隙水压力场与土压力场的时空分布与演化规律。与FEM、DNN、STGNN和PINN相比,MPINN的预测精度分别提升了71.43%、65.21%、43.61%和31.58%。

(3)随机变量的训练结果对场分布具有显著影响,本文所采用的MPINN方法能够通过迭代训练直

接反演参数分布,但尚未充分考虑随机场不确定性及测量误差对物理过程的影响。未来工作可进一步引入概率建模方法,以量化先验知识不确定性对模型的影响。

参 考 文 献:

- [1] 李国英. 推进安全大坝、生态大坝、智能大坝建设[J]. 中国水利, 2025(16): 1-3. (LI G Y. Promote the construction of safe, ecological, and smart dams[J]. China Water Resources, 2025(16): 1-3. (in Chinese))
- [2] 钟登华, 张天鸿, 余红玲, 等. 智能时代与大坝工程建设智能化研究进展[J]. 水利学报, 2025, 56(1): 1-19. (ZHONG D H, ZHANG T H, YU H L, et al. Advancements in intelligent dam engineering construction in the intelligence era[J]. Journal of Hydraulic Engineering, 2025, 56(1): 1-19. (in Chinese))
- [3] 中国大坝工程学会. 智能大坝建设的重大意义及其相关问题探讨[J]. 中国水利, 2025(16): 4-9, 30. (Chinese National Committee of Large Dams. Discussion on significance of smart dam construction and related issues[J]. China Water Resources, 2025(16): 4-9, 30. (in Chinese))
- [4] 马刚, 艾志涛, 郭承乾, 等. 高土石坝变形监测研究进展[J]. 水利学报, 2024, 55(10): 1174-1186. (MA G, AI Z T, GUO C Q, et al. Review on deformation monitoring for high earth-rock dams[J]. Journal of Hydraulic Engineering, 2024, 55(10): 1174-1186. (in Chinese))
- [5] 周伟, 马刚, 安妮, 等. 高堆石坝变形监测和变形预测关键技术及工程应用[J]. 水利规划与设计, 2022(11): 54-60. (ZHOU W, MA G, AN N, et al. Key technology and application analysis of deformation monitoring and prediction of high rockfill dam[J]. Water Resources Planning and Design, 2022(11): 54-60. (in Chinese))
- [6] 景来红, 陶玉波. 智能大坝建设要求和思路探讨[J]. 中国水利, 2025(16): 15-22. (JING L H, TAO Y B. Exploration on the construction requirements and design concepts of intelligent dams[J]. China Water Resources, 2025(16): 15-22. (in Chinese))
- [7] ZHENG X Q, YAN B, WANG W, et al. Seepage-deformation coupling analysis of a core wall rockfill dam subject to rapid fluctuations in the reservoir water level[J]. Water, 2024, 16(11): 1621.
- [8] 汪小刚. 高土石坝几个问题探讨[J]. 岩土工程学报, 2018, 40(2): 203-222. (WANG X G. Discussion on some problems observed in high earth-rockfill dams[J]. Chinese Journal of Geotechnical Engineering, 2018, 40(2): 203-222. (in Chinese))
- [9] RAJIB A I, ASSUMANING G A, CHANG S Y, et al. Use of multiple data assimilation techniques in groundwater contaminant transport model[J]. Water Environment Research, 2017, 89(11): 1952-1960.
- [10] 李新, 刘丰, 方苗. 模型与观测的和弦: 地球系统科学中的数据同化[J]. 中国科学: 地球科学, 2020, 50(9): 1185-1194. (LI X, LIU F, FANG M. Harmonizing models and observations: Data assimilation in Earth system science[J]. Scientia Sinica: Terrae, 2020, 50(9): 1185-1194. (in Chinese))
- [11] 孙博闻, 杨晰涓, 暴柱, 等. 基于数据同化的深水湖库水温中短期预报[J]. 水利学报, 2022, 53(12): 1445-1455. (SUN B W, YANG X Y, BAO Z, et al. Medium and short term prediction of water temperature in deep water lake-reservoir based on data assimilation[J]. Journal of Hydraulic Engineering, 2022, 53(12): 1445-1455. (in Chinese))
- [12] XIE Y X, CHEN S R, ZHOU F, et al. Development of a hybrid algal population prediction (HAPP) model by algae growth potential estimation and time series regression and its application in one reservoir in China[J]. Water Research, 2025, 287: 124419.
- [13] WANG Z J, MA G, AI Z T, et al. Noise adaptive spatiotemporal neural networks for deformation prediction of high rockfill dams[J]. Expert Systems with Applications, 2025, 294: 128836.
- [14] WANG B W, SUN Z B, JIANG X Y, et al. Kalman filter and its application in data assimilation[J]. Atmosphere, 2023, 14(8): 1319.
- [15] WANG N Z, CHANG H B, ZHANG D X. Deep-learning-based inverse modeling approaches: A subsurface flow example[J]. Journal of Geophysical Research: Solid Earth, 2021, 126(2): e2020JB020549.
- [16] SANTOS J E, XU D, JO H, et al. PoreFlow-Net: A 3D convolutional neural network to predict fluid flow through porous media[J]. Advances in Water Resources, 2020, 138: 103539.

- [17] ZHOU X H, MCCLURE J E, CHEN C, et al. Neural network-based pore flow field prediction in porous media using super resolution[J]. *Physical Review Fluids*, 2022, 7(7): 074302.
- [18] ERSHADNIA R, MOEINI F, ABOLFAZL HOSSEINI S, et al. Predicting multiphase flow behavior of methane in shallow unconfined aquifers using conditional deep convolutional generative adversarial network [J]. *Journal of Hydrology*, 2024, 641: 131674.
- [19] ZHANG J J, CAO C L, NAN T C, et al. A novel deep learning approach for data assimilation of complex hydrological systems[J]. *Water Resources Research*, 2024, 60(2): e2023WR035389.
- [20] KHEIRY M, KALATEH F. A comparative analysis of deterministic and probabilistic approaches for estimating seepage flow in earth dams using a hybrid finite element method[J]. *Machine Learning and Data Science in Geotechnics*, 2025, 1(1): 10–27.
- [21] GONG W B, ZUO L L, LI L, et al. Prediction of stratified ground consolidation via a physics-informed neural network utilizing short-term excess pore water pressure monitoring data [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2025, 40(2): 147–165.
- [22] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. *Journal of Computational Physics*, 2019, 378: 686–707.
- [23] WANG N Z, KONG X Z, ZHANG D X. Physics-informed convolutional decoder (PICD): A novel approach for direct inversion of heterogeneous subsurface flow[J]. *Geophysical Research Letters*, 2024, 51 (13) : e2024GL108163.
- [24] 方卫华, 徐孟启. 基于 PINNs 的圣维南方程组数据同化方法[J]. *水资源保护*, 2023, 39(3): 24–31, 64. (FANG W H, XU M Q. Data assimilation method of Saint-Venant equations based on PINNs[J]. *Water Resources Protection*, 2023, 39(3): 24–31, 64. (in Chinese))
- [25] WANG N Z, CHANG H B, ZHANG D X. Efficient uncertainty quantification for dynamic subsurface flow with surrogate by Theory-guided Neural Network[J]. *Computer Methods in Applied Mechanics and Engineering*, 2021, 373: 113492.
- [26] HE Q Z, BARAJAS-SOLANO D, TARTAKOVSKY G, et al. Physics-informed neural networks for multiphysics data assimilation with application to subsurface transport[J]. *Advances in Water Resources*, 2020, 141: 103610.
- [27] 闫澍旺, 朱红霞, 刘润, 等. 关于土层相关距离计算方法的研究[J]. *岩土力学*, 2007, 28(8): 1581–1586. (YAN S W, ZHU H X, LIU R, et al. Study on methods for estimating correlation distance of soil layers[J]. *Rock and Soil Mechanics*, 2007, 28(8): 1581–1586. (in Chinese))
- [28] 闫澍旺, 贾晓黎, 郭怀志, 等. 土性剖面随机场模型的平稳性和各态历经性验证[J]. *岩土工程学报*, 1995 (3): 1–9. (YAN S W, JIA X L, GUO H Z, et al. Examination of stationarity and ergodicity on soil profile[J]. *Chinese Journal of Geotechnical Engineering*, 1995(3): 1–9. (in Chinese))
- [29] LIU Y, WANG X M, MA G, et al. Carbon emissions and vegetation dynamics: Assessing the spatiotemporal environmental impacts of hydropower dams in the Lancang River Basin[J]. *Forests*, 2024, 15(5): 872.
- [30] CHO S E, PARK H C. Effect of spatial variability of cross-correlated soil properties on bearing capacity of strip footing[J]. *International Journal for Numerical and Analytical Methods in Geomechanics*, 2010, 34(1): 1–26.
- [31] 陈立宏, 陈祖煜, 张进平, 等. 小浪底大坝心墙中高孔隙水压力的研究[J]. *水利学报*, 2005, 36(2): 219–224. (CHEN L H, CHEN Z Y, ZHANG J P, et al. Study on high pore pressure in clay core wall of earth dam in Xiaolangdi Project[J]. *Journal of Hydraulic Engineering*, 2005, 36(2): 219–224. (in Chinese))
- [32] 陈向浩, 邓建辉, 陈科文, 等. 高堆石坝砾石土心墙施工期应力监测与分析[J]. *岩土力学*, 2011, 32(4): 1083–1088, 1094. (CHEN X H, DENG J H, CHEN K W, et al. Stress monitoring and analysis of gravelly soil corewall in high rockfill dam during construction[J]. *Rock and Soil Mechanics*, 2011, 32(4): 1083–1088, 1094. (in Chinese))
- [33] 陈继平, 曹林曦, 刘明华, 等. 砾石土心墙堆石坝施工期孔隙水压力分析[J]. *岩土力学*, 2008, 29(S1): 176–180. (CHEN J P, CAO L X, LIU M H, et al. Pore water pressure analysis during construction of gravelly soil corewall rockfill dam[J]. *Rock and Soil Mechanics*, 2008, 29(S1): 176–180. (in Chinese))
- [34] 吴继业, 马刚, 艾志涛, 等. 时空融合的堆石坝变形预测模型及在安全监测中的应用[J]. *水利学报*, 2024,

- 55(5): 564–576. (WU J Y, MA G, AI Z T, et al. Spatial-temporal fusion model for deformation prediction of rockfill dams and its application in safety monitoring[J]. Journal of Hydraulic Engineering, 2024, 55(5): 564–576. (in Chinese))
- [35] 何宁, 李登华, 陈鸽, 等. 土石坝安全监测数据处置与评价技术研究进展[J]. 水利水运工程学报, 2025(5): 88–100. (HE N, LI D H, CHEN G, et al. Advances in data processing and evaluation techniques for safety monitoring of earth-rock dams[J]. Hydro-Science and Engineering, 2025(5): 88–100. (in Chinese))
- [36] BIOT M A. General theory of three-dimensional consolidation[J]. Journal of Applied Physics, 1941, 12(2): 155–164.
- [37] 谭晓慧, 董小乐, 费锁柱, 等. 基于KL展开的可靠度分析方法及其应用[J]. 岩土工程学报, 2020, 42(5): 808–816. (TAN X H, DONG X L, FEI S Z, et al. Reliability analysis method based on KL expansion and its application[J]. Chinese Journal of Geotechnical Engineering, 2020, 42(5): 808–816. (in Chinese))
- [38] VANMARCKE E H. Probabilistic modeling of soil profiles[J]. Journal of the Geotechnical Engineering Division, 1977, 103(11): 1227–1246.
- [39] HUANG J S, GRIFFITHS D V, FENTON G A. Probabilistic analysis of coupled soil consolidation[J]. Journal of Geotechnical and Geoenvironmental Engineering, 2010, 136(3): 417–430.
- [40] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436–444.
- [41] 张明亮, 宿晓辉, 吴正桥, 等. 代古寺面板堆石坝渗流场有限体积法数值分析[J]. 水利水运工程学报, 2023(6): 205–212. (ZHANG M L, SU X H, WU Z Q, et al. Numerical analysis of seepage field of Daigusi concrete face rockfill dam by finite volume method[J]. Hydro-Science and Engineering, 2023(6): 205–212. (in Chinese))
- [42] TRIPATHY R K, BILIONIS I. Deep UQ: Learning deep neural network surrogate models for high dimensional uncertainty quantification[J]. Journal of Computational Physics, 2018, 375: 565–588.
- [43] JIN G Y, LIANG Y X, FANG Y C, et al. Spatio-temporal graph neural networks for predictive learning in urban computing: A survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(10): 5388–5408.

Research on multi-source data assimilation for core wall rockfill dams based on MPINN

SUN Mingyue¹, MA Gang^{1,2,3}, ZHANG Yi¹, ZHOU Wei^{1,2,3}, CHANG Xiaolin^{1,2,3}

(1. State Key Laboratory of Water Resources Engineering and Management, Wuhan University, Wuhan 430072, China;

2. Institute of Water Engineering Sciences, Wuhan University, Wuhan 430072, China;

3. Key Laboratory of Rock Mechanics in Hydraulic Structural Engineering of Ministry of Education, Wuhan University, Wuhan 430072, China)

Abstract: Thorough perception of hydraulic structures is essential for building their digital twins and promoting high-quality water resources development. With the advancement of dam safety monitoring and the establishment of integrated “sky-space-ground-water-structure based” sensing networks, effectively assimilating multi-source data to achieve full-domain perception has become a key research focus. This study proposes a Multiphysics-Informed Neural Network (MPINN) data assimilation framework, which embeds stress-seepage coupling theory and random field parameters into neural networks to integrate physical consistency with data-driven flexibility. Taking the Lianghekou core wall rockfill dam as an example, the MPINN was used to assimilate monitoring data of pore water pressure, earth pressure in the gravelly soil core wall, as well as detection data of permeability coefficient and compression modulus to reconstruct the full-field pore water pressure and earth pressure distributions within the core wall from sparse data. Comparative experiments showed that the MPINN outperforms other methods in both prediction accuracy and robustness, verifying the effectiveness of the data assimilation. This provides a new pathway for achieving thorough perception and offers technical support for the development of digital twin projects and intelligent dams.

Keywords: intelligent dam; rockfill dams; thorough perception; data assimilation; multi-field coupling; Multiphysics-Informed Neural Network (MPINN)

(责任编辑: 王 婧)