

基于级联物理信息神经网络的库岸边坡瞬态渗流模拟

甘龙厚^{1,2}, 彭铭^{1,2*}

1. 同济大学土木工程防灾减灾全国重点实验室, 上海 200092

2. 同济大学土木工程学院, 上海 200092

摘要: 降雨与库水位作为库岸滑坡的主要诱因, 通过改变边坡内渗流行为, 进而影响边坡稳定性。因此, 准确表征库岸边坡内渗流场的时空演化特征是开展稳定性分析的关键。然而, 在降雨与库水位的联合作用下, 边坡渗流过程受动态渗透边界控制, 呈现显著的非平稳特征(如边界条件突变、水头响应滞后等), 给传统数值方法的稳定求解带来了挑战。针对上述问题, 本文提出一种级联物理信息神经网络模型(Cascading physics-informed neural network, CPINN)。该方法采用“分段建模-顺序训练-状态传递”的级联策略, 分阶段学习由动态边界引起的非平稳物理过程。将全时间域按照渗透边界或入渗方式在时间上的阶段性变化划分为多个子时段, 并为每个时段分别构建子 PINN 模型; 训练时引入时间顺序推进机制, 在保证物理约束一致性的前提下, 实现各子模型之间的连续衔接与信息传递; 预测时根据目标区段调用对应子模型, 使框架既能捕捉水头随时间变化的全局趋势, 又能反映不同渗透边界下的局部瞬态响应。结果表明, 级联 PINN 有效解决了动态边界问题、显著降低了求解难度, 并实现降雨与水位联合作用下库岸边坡瞬态渗流的准确模拟, 为此类具有动态边界变化的复杂渗流问题提供了一种高效稳定的建模策略。

关键词: 库岸边坡; 非饱和瞬态渗流; 数值模拟; 深度学习; 物理信息神经网络

中图分类号: P642

收稿日期: 2026-3-2

Unsaturated transient seepage simulation of reservoir bank slope using a cascading physics-informed neural network (CPINN)

Longhou Gan^{1,2}, Ming Peng^{1,2*}

1. State Key Laboratory of Disaster Reduction in Civil Engineering, Tongji University, Shanghai 200092, China

2. College of Civil Engineering, Tongji University, Shanghai 200092, China

Abstract: Rainfall and reservoir water-level fluctuations influence reservoir bank slope stability through their alteration of seepage behavior within the slope. Therefore, accurately characterizing the spatiotemporal evolution of the seepage field is essential for slope stability analysis. However, under the combined effects of rainfall infiltration and reservoir water-level variations, the seepage process is governed by dynamic hydraulic boundary conditions and exhibits pronounced non-stationary characteristics (e.g., abrupt changes in boundary conditions and lag in hydraulic head response), which pose significant challenges to the stable solution of conventional numerical simulation methods. To address this issue, this study proposes a cascading physics-informed neural network (CPINN) framework. The proposed method adopts a cascading strategy of “segmented modeling-sequential training-state transfer” to learn non-stationary physical processes induced by dynamically varying boundary conditions in a stage-wise manner. Specifically, the entire time domain is divided into multiple sub-intervals according to the temporal evolution of seepage boundary conditions or infiltration patterns, and a dedicated sub-PINN model is constructed for each interval. During training, a sequential time-marching mechanism is introduced to ensure continuous information transfer and consistent physical constraints among successive sub-models. During prediction, the corresponding sub-model is activated based on the target time interval, enabling the framework to capture both the global temporal evolution of hydraulic head and the local transient responses under different seepage boundary conditions. The results demonstrate that the proposed CPINN effectively addresses dynamic boundary conditions, significantly reduces the difficulty of solving, and achieves high-accuracy simulation of transient seepage in reservoir bank slopes under the combined effects of rainfall and reservoir water-level fluctuations. This approach provides an efficient and robust modeling strategy for complex seepage problems involving dynamically evolving boundary conditions.

Key words: Reservoir bank slope; Unsaturated transient seepage; Numerical simulation; Deep learning; Physics-informed neural network (PINN)

基金项目: 国家自然科学基金-联合基金重点项目(U23A2044)

作者简介: 甘龙厚(2001-), 男, 博士研究生, 从事库岸滑坡灾害机理与风险评估研究。E-mail: 2310487@tongji.edu.cn, ORCID: 0009-0005-9269-0997

通讯作者: 彭铭(1981-), 男, 教授, 从事地质灾害机理与防治研究。E-mail: pengming@tongji.edu.cn

0 引言

库区滑坡灾害频发,对生命财产安全、水工结构、生态环境构成严重威胁。例如,在我国三峡库区,已记录的库岸滑坡数量接近 5000 例 (Tang et al., 2019)。大量研究表明,降雨入渗和库水位波动是库岸滑坡的主要诱发因素 (唐辉明等, 2022; 李长冬等, 2022; Zhu et al., 2024)。季节性降雨与周期性库水位变化引起边坡内部渗流场的瞬态变化,显著影响岩土体的应力变形行为,并逐渐削弱岩土体的强度,破坏边坡的稳定性 (彭铭等, 2025; 吴益平等, 2026; 邓志平等, 2026; 沈颜参等, 2026)。因此,准确表征渗流场的空间分布和时间演化特征,对于可靠评估滑坡危险性和有效降低灾害风险具有重要意义。

对于岩土体等多孔介质材料,通常采用渗流偏微分方程 (如 Richards 方程) 描述其瞬态渗流过程。渗流偏微分方程的求解方法主要包括解析解与数值解两类。解析解方法通过对渗流控制方程进行严格的数学推导,为渗流过程的内在物理机制提供了清晰的理论认识 (詹良通等, 2010; 韩佳明等, 2023; 江文豪等, 2025)。然而,该方法的适用性依赖于一系列理想化假设,在复杂几何形态、动态边界条件及强非线性问题中适用性受限。数值解方法,如有限差分法 (the finite difference method, FDM) 和有限元法 (the finite element method, FEM), 通过对控制方程进行离散以获得近似解,在处理复杂边界条件和非线性问题方面具有较强的灵活性 (荣冠等, 2005; Zhu et al., 2019; Li et al., 2022; Sun et al., 2024)。然而,该类方法通常计算成本较高,且在强非线性或瞬态问题中可能面临收敛性和稳定性挑战,尤其在反演分析、可靠度分析等需要大量重复计算的应用场景中,难以满足高效计算的需求。近几年,快速发展的数据驱动方法 (如机器学习) 通过从时间序列数据中提取潜在模式,构建非线性预测模型,为复杂渗流问题提供了新的解决思路 (Orland et al., 2020; Wei et al., 2021; Ng et al., 2023)。虽然它们提供了较高的计算效率,尽管该类方法在计算效率方面具有明显优势,但传统神经网络模型对训练数据的质量与数量高度敏感,其“黑箱”特性往往难以显式约束物理规律,可能导致物理一致性不足、预测结果缺乏可靠性以及泛化能力下降。

融合物理信息的神经网络 (Physics-informed neural network, PINN) 为非饱和瞬态渗流模拟提供了一种新的框架。PINN 模型可将渗流偏微分方程 (partial differential equation, PDE) 直接嵌入到损失函数中,确保模型训练过程不仅由数据拟合引导,而且受物理机

制约束引导,较适用于数据有限或物理模型不完整的场景,因此在土石坝、边坡等非饱和土渗流问题中得到了广泛应用 (Chen et al., 2023; Gao et al., 2023; Lan et al., 2024; Lv et al., 2024; Yang et al., 2025)。然而,现有研究多集中于稳态渗流或固定边界条件场景,对于真实工程中普遍存在的动态渗流边界条件 (如季节性降雨、周期性库水位涨落等) 关注较少。在此类工况下,非饱和渗流 PDE 的边界条件随时间持续变化,渗流过程呈现明显的非平稳特征。传统 PINN 在处理动态边界约束时,往往难以有效表征由边界演化引起的非平稳物理过程,易出现收敛速度缓慢、训练过程不稳定、预测精度低等问题。若针对不同渗流阶段构建多个独立的 PINN 模型,不仅会显著增加计算与训练成本,难以保证预测结果在时间上的连续性,还可能导致模型间误差累积放大。因此,亟需发展一种高效且稳定的建模方法,以提升 PINN 在复杂动态渗流边界条件下的预测能力。

因此,为解决传统 PINN 模型在处理动态渗透边界时存在的效率低、精度差等问题,本文提出了一种级联 PINN 框架。该框架以动态渗透边界的阶段性变化为主线,将全时间域划分为若干物理行为相对一致的子时段,并通过“分段建模-顺序训练-状态传递”的级联方式,分阶段学习由边界切换引起的非平稳渗流过程。针对每个子时段分别构建子 PINN 模型,使其聚焦于该阶段对应的边界条件与局部瞬态响应;同时在相邻时段之间引入连续性约束,以保证水头演化的时间连续性与物理一致性。基于此,本文进一步通过收敛性、渗流场空间分布及孔压时序响应等多个层面对所提方法进行验证,以实现降雨与水位联合作用下库岸边坡非饱和瞬态渗流的准确模拟。

1 PINN 方法

为实现复杂动态边界条件下渗流过程的稳定高效模拟,本研究基于 PINN 的强非线性拟合能力与物理约束机制,结合级联策略提升模型在动态渗流边界条件下的 PDE 求解性能。该框架能够在有限观测数据条件下,准确模拟降雨与库水位联合作用下边坡内部的渗流演化过程。最后通过典型案例验证该方法的准确性与有效性。

1.1 非饱和渗流偏微分控制方程 (PDE)

对于岩土体等多孔介质材料,基于质量守恒原理和达西定律,可建立其二维非饱和渗流控制方程 (Richards 方程):

$$\frac{\partial}{\partial x} \left(k \frac{\partial \psi}{\partial x} \right) + \frac{\partial}{\partial z} \left(k \frac{\partial \psi}{\partial z} + k \right) = \frac{\partial \theta}{\partial t} \quad (1)$$

式中, k 为渗透系数, θ 为体积含水量, ψ 为压力水头, (x, z) 表示平面坐标位置, t 为时间。非饱和土的土水特征曲线与渗透系数可分别通过式 (2) 和式 (3) 描述, 从而模拟土体含水率与基质吸力之间的函数关系:

$$k = k_s e^{\alpha \psi} \quad (2)$$

$$\theta = \theta_r + (\theta_s - \theta_r) e^{\alpha \psi} \quad (3)$$

式中, k_s 为饱和渗透系数, α 为减饱和系数, θ_s 为饱和体积含水量, θ_r 为残余体积含水量。将式 (2) 和式 (3) 代入式 (1), 可进一步得到二维非饱和渗流的控制方程:

$$\frac{\partial^2 \psi}{\partial x^2} + \frac{\partial^2 \psi}{\partial z^2} + \alpha \left[\left(\frac{\partial \psi}{\partial x} \right)^2 + \left(\frac{\partial \psi}{\partial z} \right)^2 + \frac{\partial \psi}{\partial z} \right] = \frac{\alpha(\theta_s - \theta_r)}{k_s} \frac{\partial \psi}{\partial t} \quad (4)$$

该方程的解析需要明确的边界条件, 边界条件可分为第一类边界条件 (即 Dirichlet 条件, 如水头边界) 和第二类边界条件 (即 Neumann 条件, 如流量边界) 以及初始条件。水头边界与流量边界是非饱和渗流建模中必不可少的约束条件。水头边界可以用数学表达式

表示为:

$$\psi_\Gamma(x, z, t) = H \quad (5)$$

流量边界条件:

$$k \cdot \frac{\partial \psi_\Gamma}{\partial \mathbf{n}} = q \quad (6)$$

初始条件:

$$\psi(x, z, 0) = h(x, z) \quad (7)$$

式中, 其中 ψ_Γ 表示边界处的压力水头, H 为规定的边界水头, $\mathbf{n}$ 是边界的单位法向量, q 是边界流量。

1.2 PINN 求解偏微分方程

PINN 求解渗流偏微分方程的基本原理如图 1 所示。首先构造输出结果为孔隙水压力水头 $\hat{\psi}$ 的神经网络模型 $NN(x, z, t; \theta)$, 准备训练数据集, 通过最小化损失函数对神经网络模型进行训练, 当损失函数未收敛时, 则通过反向传播更新网络参数, 以使损失值下降, 直至损失函数收敛, 训练结束, 最终得到最优参数 θ^* 。在模型训练中, 参数通过优化算法逐步更新。由于训练初期损失值通常较高, 为了加速收敛, 首先采用 Adam 优化器进行初步优化。在 Adam 优化阶段, 通常设置初始学习率为 0.001, 然后通过动态调整学习率, 快速降低损失值。模型的损失函数 $L(x, z, t; \theta)$ 由数据损失 (L_{data})、偏微分方程损失 (L_{PDE})、初始条件损失 (L_{IC}) 和边界条件损失 (L_{BC}) 组成:

$$L(x, z, t; \theta) = \lambda_{\text{data}} L_{\text{data}} + \lambda_{\text{PDE}} L_{\text{PDE}} + \lambda_{\text{IC}} L_{\text{IC}} + \lambda_{\text{BC}} L_{\text{BC}} \quad (8)$$

$$L_{\text{data}} = \frac{1}{N_{\text{data}}} \sum_{i=1}^{N_{\text{data}}} \left\| \psi(x_i, z_i, t) - \hat{\psi}(x_i, z_i, t) \right\|_2^2 \quad (9)$$

$$L_{\text{PDE}} = \frac{1}{N_{\text{PDE}}} \sum_{i=1}^{N_{\text{PDE}}} \left\| \frac{\partial^2 \hat{\psi}}{\partial x_i^2} + \frac{\partial^2 \hat{\psi}}{\partial z_i^2} + \alpha \left[\left(\frac{\partial \hat{\psi}}{\partial x_i} \right)^2 + \left(\frac{\partial \hat{\psi}}{\partial z_i} \right)^2 + \frac{\partial \hat{\psi}}{\partial z_i} \right] - \frac{\alpha(\theta_s - \theta_r)}{k_s} \frac{\partial \hat{\psi}}{\partial t} \right\|_2^2 \quad (10)$$

$$L_{\text{IC}} = \frac{1}{N_{\text{IC}}} \sum_{i=1}^{N_{\text{IC}}} \left\| \psi(x_i, z_i, 0) - \hat{\psi}(x_i, z_i, 0) \right\|_2^2 \quad (11)$$

$$L_{\text{BC}} = \frac{1}{N_{\text{head}}} \sum_{i=1}^{N_{\text{head}}} \left\| \hat{\psi}_\Gamma(x_i, z_i, t) - H(x_i, z_i, t) \right\|_2^2 + \frac{1}{N_{\text{flux}}} \sum_{i=1}^{N_{\text{flux}}} \left\| k \frac{\partial \hat{\psi}_\Gamma}{\partial \mathbf{n}} - q \right\|_2^2 \quad (12)$$

式中, λ_{data} 、 λ_{PDE} 、 λ_{IC} 和 λ_{BC} 分别为对应部分损失的权重, N_{data} 为表示训练集的样本点数量, N_{PDE} 和 N_{IC} 为内部采样点的数量, N_{flux} 和 N_{head} 分别为流量和水头边界条件处的样本数量。

1.3 级联 PINN 模型

受频繁降雨、库水位波动等影响, 库岸边坡的入渗方式与渗透边界会随时间不断变化, 使得瞬态渗流场具

有强烈的非线性和时变特征。传统 PINN 模型往往依赖固定的水头边界或流量边界, 因此在处理这种“动态渗透边界问题”时收敛慢、精度差, 甚至无法有效学习水头的动态演化规律。

为解决这一问题, 本文提出了一种级联 PINN 模型 (图 2)。利用入渗方式或渗透边界在时间上的阶段性变化, 将全时间域划分为若干物理行为相对一致的子时

段。在训练策略上,级联 PINN 采用时间顺序训练机制:首先对第一个时间段的子模型进行训练,当其满足收敛标准后,将其学习到的网络参数传递给下一个时间段的子模型作为初始信息状态。后续各时间段依次重复该流程,使所有子模型在保证物理规律一致性的前提下逐段推进。在每个后续时间段的训练中,引入级联连续性损失,以连接相邻的 PINN 模型,从而消除级联训练所引起的不连续性。为此,在空间域中通过随机抽样生成连续性采样点,前一时段末尾的标签值由前一模型的预测结果提供。级联连续性项随后被纳入损失函数,以确保相邻子时域界面处水头与流量的一致性:

$$L_n(x, z, t_{n-1}-t_n; \theta_n) = \lambda_{\text{data}} L_{\text{data}} + \lambda_{\text{PDE}} L_{\text{PDE}} + \lambda_{\text{IC}} L_{\text{IC}} + \lambda_{\text{BC}} L_{\text{BC}} + \lambda_{\text{II}} L_{\text{II}} + \lambda_{\text{CC}} L_{\text{CC}} \quad (13)$$

$$L_{\text{CC}}(x, z, t_{n-1}-t_n) = \frac{1}{N_{\text{CC}}} \sum_{i=1}^{N_{\text{CC}}} \|\hat{\psi}_{n-1}(t_{n-1}) - \hat{\psi}_n(t_{n-1})\|_2^2 + \frac{1}{N_{\text{flux}}} \sum_{i=1}^{N_{\text{flux}}} \left\| k \frac{\partial \hat{\psi}_{(n-1)\Gamma}(t_{n-1})}{\partial n} - k \frac{\partial \hat{\psi}_{n\Gamma}(t_{n-1})}{\partial n} \right\|_2^2 \quad (14)$$

式中, L_{CC} 表示级联网络中的连续性损失, λ_{CC} 为对应的权重, N_{CC} 表示采样点的数量。此外,为了减少时间域界面附近的误差累积,尽可能优先使用现有观测数据作为连续性目标,而非模型预测值,这有助于抑制误差传播。级联 PINN 通过“分段建模-顺序训练-状态传递”的方式,使每个子模型都能够继承上一个时间段的状态信息,保证水头演化在相邻时段之间的时间连续性;针对特定阶段的动态边界独立学习,显著降低全域训练的难度;避免跨越多个动态边界变化导致的梯度冲突或收敛缓慢问题,从而提供了一种高效且稳定的建模策略。




图1 物理信息神经网络 (PINN) 求解非饱和渗流偏微分方程示意图

Fig. 1 Schematic diagram of PINN models for unsaturated seepage problem




图2 级联 PINN 模型框架示意图

Fig. 2 A cascading PINN framework

2 算例验证

2.1 无限长边坡降雨入渗模拟

选用典型的均质无限长边坡案例 (詹良通等, 2010),

测试 PINN 在模拟降雨入渗工况下非饱和瞬态渗流的性能, 如图 3 所示。假定斜坡非饱和土层的垂直厚度为 $D=200 \text{ cm}$, 倾角为 30° , 如图 3 所示。计算中采用饱和渗透系数 $k_s=3.0 \times 10^{-4} \text{ cm/s}$, 减饱和度系数 $\alpha=0.01/\text{cm}$, θ_s-

$\theta_r=0.3$,坡度 $\beta=30^\circ$,孔隙水压力水头 $\psi(z^*=0)=-100\text{ cm}$ 。
计算中初始雨强 $q_a=0$ (即假定边界无降雨也无蒸发),
后期暴雨工况,雨强 $q_b=1.8\times 10^{-4}\text{ cm/s}$ 。




图 3 均质无限长斜坡示意图

Fig. 3 Coordinate system for a homogeneous infinite slope

为验证模型的可行性,采用 FEM 与 PINN 模拟结果的进行对比分析。使用 FEM 模拟结果制作训练集,随机均匀采样选取了 50 个数据点(共 500 条数据),利用 PINN 模型进行训练和模拟。图 4 为模型训练时的损失函数变化曲线,从图中可以明显地看出在第 5000 次训练时,模型的各部分损失值已基本收敛。图 5 中给出了在不同时刻,FEM 和 PINN 模拟得到的孔隙水压力沿垂直斜坡面方向的分布情况(相邻曲线时间间隔均为 2 h),两种方法的计算结果基本吻合。在降雨入渗条件下,随着时间的推移,斜坡土体中的负孔隙水压力在不断减小,降雨入渗对孔隙水压力分布的影响深度逐渐增大。




图 4 PINN 训练过程中的损失值

Fig. 4 Loss values during PINN training




图 5 FEM 和 PINN 模拟的不同时刻孔隙水压力分布对比

Fig. 5 Simulation comparison of FEM and PINN

2.2 砂槽瞬态渗流模拟

选用砂槽实验案例(荣冠等,2005)作为变水头作用下瞬态渗流的验证,如图 6 所示。砂槽模长 315 cm,宽 23 cm,高 33 cm。模型材料采用均匀砂,孔隙率为 0.44,饱和渗透系数为 $3.3\times 10^{-1}\text{ cm/s}$,非饱和砂土的土水特征关系见表 1。计算的初始条件是采用上下游为 10 cm 时的压力水头,自由面上的负压按节点至零压面的高度确定。模拟过程为上游零时刻水位骤升至 30 cm。




图 6 砂槽实验

Fig. 6 Sandbox experiment

表 1 砂土的非饱和土水特征关系

Table 1 Soil-water characteristic relationship of sand

饱和度	负压 / KPa	相对渗透系数
1.00	0.000	1.00
0.82	0.325	0.97
0.64	0.650	0.94
0.50	0.910	0.20
0.45	1.000	0.13
0.18	10.000	0.01

为验证模型的可行性,同样采用 FEM 与 PINN 的模拟结果进行对比分析。使用 FEM 模拟结果制作训练集,采用随机均匀采样的方式在砂槽内选取了 100 个数据点(共 1000 条数据),如图 8 (a) 所示,利用 PINN

训练和模拟在变水头作用下砂槽内的瞬态渗流过程进行。图 7 为 PINN 模型训练时的损失函数变化曲线, 从图中可以明显地看出模型迭代训练不足 12000 次时, 总损失就已经下降至 3.5×10^{-5} 。两种模拟方法的自由面变化计算结果见图 6, 二者结果基本吻合。不同时刻砂槽内孔压分布的模拟结果如图 8 所示, 可见 PINN 方法在数据有限的情况下, 准确的还原了变水头作用下砂槽内的瞬态渗流过程, 与 FEM 模拟的结果误差较小, 最大误差不超过 0.07, 且误差多集中在边界区域, 故 PINN 模型能够很好的成为数值模型的代理模型。




图 7 PINN 训练过程中的损失值

Fig. 7 Loss values during PINN training




图 8 不同时刻孔压分布的 FEM 和 PINN 模拟结果比较

Fig. 8 Comparison of pore pressure distribution at different times between FEM and PINN

3 库岸边坡瞬态渗流模拟

3.1 计算工况与级联子域划分

为检验本文提出的 CPINN 模型在复杂动态边界条件下的适用性与鲁棒性, 选取三峡库区某典型库岸边坡 (Xiong et al., 2019) 作为研究对象, 开展降雨入渗与水位变化联合作用下的瞬态渗流模拟。边坡几何模型如图 9 所示, 坡体内布置有 11 个孔压监测点, 用于捕捉渗流场的时空演化特征。结合图 10 所示工况可以看出, 研究时段内库水位升降与降雨过程交替出现, 渗透边界具有显著的阶段性与非平稳性。为此, 本文依据边界条件的变化特征, 将整个 0~350 min 的模拟时程划分为 9 个连

续子时段, 其中子域 1 至子域 5 对应一个完整的库水位波动过程, 即“平稳-上升-平稳-下降-平稳”五个阶段; 子域 6 至子域 9 对应两次降雨入渗及其间歇静置过程。针对每个子时段分别构建一个子 PINN 模型, 形成 CPINN-9, 并采用“分段建模-顺序训练-状态传递”的级联策略完成训练与预测。具体工况如下: (1) 0-51 min: 初始水位 35 cm 静置; (2) 51-86 min: 水位上升至 50 cm; (3) 86-147 min: 50 cm 水位静置; (4) 147-177 min: 水位下降至 35 cm; (5) 177-238 min: 35 cm 水位静置; (6) 238-268 min: 第一次降雨, 降雨强度 0.13 cm/min; (7) 268-298 min: 降雨停止后保持 35 cm 水位静置; (8) 298-328 min: 第二次降雨, 降雨强度 0.17 cm/min,

降雨时长 30 min; (9) 328-350 min: 降雨停止后保持 35 cm 水位静置。模型左侧、右侧和底部均为不透水边界, 在坡面的相应部位分别设置降雨流量边界和水头边界, 坡体砂性土材料饱和渗透系数为 1.16×10^{-2} cm/s, 孔隙比 0.7, 非饱和土水特征曲线如图 11 所示。




图 9 库岸边坡模型




图 10 模拟工况

Fig. 10 Simulated conditions

3.2 模型训练与收敛性分析

图 12 给出了传统 PINN 与 CPINN-9 的训练损失演化过程。可以看出, 在库水位波动与降雨交替作用下, 渗流边界条件随时间频繁切换, 导致待求解渗流场表现出显著的非平稳性。对于传统 PINN 而言, 单一网络需要在统一参数空间内同时拟合多个阶段的边界约束与物理响应, 因而易出现损失下降缓慢、局部震荡明显和收敛效率偏低等问题。相比之下, CPINN-9 将全时域问题分解为若干物理行为相对一致的子问题, 各子网络仅需学习对应阶段内的局部动态边界与渗流响应, 显著降低了训练难度。从图 12 还可进一步发现, 随着级联训练的推进, 后续子网络通常能够在更少迭代步内达到稳定状态, 表明前一阶段学习得到的状态信息和网络参数可为后一阶段提供有效的初始条件, 从而提高整体训练效率并增强收敛稳定性。

3.3 渗流场模拟结果对比

图 13 比较了 FEM、传统 PINN 与 CPINN-9 在若干代表性时刻得到的孔压分布与浸润线形态。总体来看, CPINN-9 的结果与 FEM 高度一致, 不仅较好再现了坡体内部孔压场的空间分布特征, 而且能够准确追踪浸润

线在水位升降与降雨作用下的动态演化过程; 传统 PINN 则在多个时刻均表现出较明显偏差, 尤其在边界条件发生切换及局部梯度变化较强的区域, 误差更为突出。从渗流场演化规律看, 在库水位由 35 cm 上升至 50 cm 并维持的阶段, 坡体表层浸润线随外部水位抬升而逐步上移, 但由于坡体内部渗流传导具有滞后性, 深部区域的响应相对缓慢; 在库水位回落阶段, 表层浸润线先行下降, 而深部孔压仍维持较高水平, 表现出明显的滞后释放特征。两次降雨过程中, 降雨入渗均引起坡体浅部浸润线持续抬升和孔隙水压力增加, 且第二次降雨强度更大, 对浅部渗流场的扰动更为显著。上述结果表明, CPINN-9 能够较好地捕捉库水位波动与降雨入渗共同作用下边坡渗流场的阶段性演化特征。




图 11 土水特征曲线

Fig. 11 Soil-water characteristic curve

3.4 孔压时序演化与模型精度评估

为进一步评价模型对时序响应的刻画能力, 提取 4 个典型孔压测点的模拟结果并与 FEM 进行对比, 结果如图 14 所示。可以看出, CPINN-9 在各测点处均较准确地再现了孔压曲线的总体变化趋势、峰谷位置及关键转折时刻, 说明该方法不仅能够保证相邻子时段之间的时间连续性, 而且能够维持较高的预测精度。相比之下, 传统 PINN 在边界条件由库水位波动转入降雨入渗时误差显著增大, 局部曲线甚至出现不稳定波动, 反映出单一网络在跨阶段学习多类动态边界时容易受到梯度冲突和误差累积的影响。为进一步说明子域划分方式对模拟效果的影响, 本文还构建了仅包含两个子网络的 CPINN-2; 其中子域 1 至子域 5 合并表征库水位变化过程, 子域 6 至子域 9 合并表征降雨入渗过程。结果表明,

CPINN-2 的精度虽优于传统 PINN，但仍低于 CPINN-9。这说明，级联框架的优势不仅来自网络数量的增加，更关键的是按照渗透方式或渗透边界突变点对时间域

进行合理划分，使各子模型对应相对一致的物理过程。因此，针对动态渗透边界问题，基于物理阶段划分的细粒度级联建模是提升模拟精度与训练稳定性的关键。




图 12 传统 PINN 和 CPINN-9 训练过程对比

Fig. 12 Comparison of training process between PINN and CPINN-9




图 13 不同时刻孔压分布的 FEM、传统 PINN 和 CPINN-9 模拟结果比较

Fig. 13 Comparison of pore pressure distribution at different times among FEM, PINN and CPINN-9




图 14 孔压演化的 FEM、传统 PINN 和 CPINN 模拟结果比较

Fig. 14 Comparison of pore pressure at different times among FEM, PINN and CPINN

4 结论与展望

针对传统 PINN 模型在动态边界条件下易出现收敛缓慢、精度下降和训练不稳定等问题, 本文提出了一种用于模拟降雨与水位联合作用下库岸边坡非饱和瞬态渗流过程的 CPINN 模型。该模型以动态渗透边界的阶段性变化为依据, 通过“分段建模-顺序训练-状态传递”的级联机制实现对非平稳渗流过程的分段求解, 并从模型收敛性、渗流场空间分布及孔压时序响应等方面验证了其有效性。主要结论如下:

(1) 传统 PINN 通过在损失函数中嵌入渗流偏微分方程、初始条件和边界条件, 能够在有限观测数据条件下较好重建稳定边界作用下的瞬态渗流过程, 可作为复杂动态边界渗流模拟的基础框架。但当边界条件随时间频繁变化时, 单一网络在跨阶段学习非平稳物理过程方面仍存在明显局限。

(2) CPINN 通过将动态渗透边界主导的全时域问题划分为多个物理行为相对一致的子时段, 并采用“分段建模-顺序训练-状态传递”的级联策略, 在相邻子时段之间建立连续性约束, 从而有效缓解了传统 PINN 在动态边界条件下易出现的梯度冲突、收敛缓慢和训练不稳定问题, 显著降低了全域训练难度并提升了求解稳定性。

(3) 在三峡库区典型库岸边坡算例中, CPINN 在浸润线演化、孔压空间分布及监测点孔压时序响应等方面均与 FEM 结果保持较高一致性, 整体表现优于传统 PINN 和粗分段的 CPINN-2。结果表明, 合理依据边界条件突变对时间域进行细致划分, 有助于提升模型对动态边界切换和局部瞬态响应的刻画能力, 从而实现降雨与水位联合作用下库岸边坡非饱和瞬态渗流的准确模拟。

未来工作可进一步将 PINN 模型拓展至非均质多

地层边坡、多物理场耦合作用下的真实库岸边坡场景, 同时引入现场实时监测数据开展反演与预测研究, 以提升模型在实际工程中的泛化能力与应用价值。

Reference

- Chen, Y., Xu, Y., Wang, L. and Li, T., 2023. Modeling Water Flow in Unsaturated Soils through Physics-Informed Neural Network with Principled Loss Function. *Computers and Geotechnics*, 161: 105546. <https://doi.org/10.1016/j.compgeo.2023.105546>
- Deng Zhiping, Wan Minhao, Pan Min, et al. Slope Reliability Analysis Considering Degradation and Spatial Variability of Subsidence Zone Parameters. *Chinese Journal of Earth Science*, 2026, 51(2): 547-559 (in Chinese with English abstract).
- Gao, Y., Qian, L., Yao, T., Mo, Z., Zhang, J., Zhang, R., Liu, E., Li, Y. and Yaseen, Z.M., 2023. An Improved Physics-Informed Neural Network Algorithm for Predicting the Phreatic Line of Seepage. *Advances in Civil Engineering*, 2023: 1-11. <https://doi.org/10.1155/2023/5499645>
- Han Jia-ming, Dong Zhao, Su San-qing, et al, 2023. Analytical Solution of Rainfall Infiltration in Homogeneous Unsaturated Slope and Its Application in Loess Slope. *Chinese Journal of Rock and Soil Mechanics*, 44(01): 241-250 (in Chinese with English abstract).
- Jiang Wen-hao, Wang Hao, Liao Guang-zhi, Chen Bin-hua, 2025. Analytical Solutions for One-Dimensional Transient Seepage of Water in the Two-Layered Unsaturated Soils under Time-Varying Rainfall Conditions. *Chinese Journal of Rock and Soil Mechanics*, 46(09): 1-17 (in Chinese with English abstract).
- Lan, P., Su, J. and Zhang, S., 2024. Surrogate Modeling for Unsaturated Infiltration via the Physics and Equality-Constrained Artificial Neural Networks. *Journal of Rock Mechanics and*

- Geotechnical Engineering, 16(6): 2282-2295. <https://doi.org/10.1016/j.jrmge.2023.09.014>
- Li Changdong, Tan Qinwen, 2022. Can the Physical Sliding of Hydrodynamic-Driven Landslide Be Predicted? Chinese Journal of Earth Science, 47(10): 3908-3910 (in Chinese with English abstract).
- Li, X., Li, X., Wu, Y., Wu, L. and Yue, Z., 2022. Selection Criteria of Mesh Size and Time Step in FEM Analysis of Highly Nonlinear Unsaturated Seepage Process. Computers and Geotechnics, 146: 104712. <https://doi.org/10.1016/j.compgeo.2022.104712>
- Lv, S., Li, D., Zha, W., Shen, L. and Xing, Y., 2024. Solving Seepage Equation Using Physics-Informed Residual Network without Labeled Data. Computer Methods in Applied Mechanics and Engineering, 418: 116563. <https://doi.org/10.1016/j.cma.2023.116563>
- Ng, C.W.W., Usman, M. and Guo, H., 2023. Spatiotemporal Pore-Water Pressure Prediction Using Multi-Input Long Short-Term Memory. Engineering Geology, 322: 107194. <https://doi.org/10.1016/j.enggeo.2023.107194>
- Orland, E., Roering, J.J., Thomas, M.A. and Mirus, B.B., 2020. Deep Learning as a Tool to Forecast Hydrologic Response for Landslide-Prone Hillslopes. Geophysical Research Letters, 47(16). <https://doi.org/10.1029/2020gl088731>
- Peng Ming, Wang Yue, Ma Chenyi, Shi Zhenming, Zhu Yan, 2025. Review of Risk Assessment and Prevention for Valley Landslide Disaster Chains. Chinese journal of Earth Science, 50(10): 3723-3760 (in Chinese with English abstract).
- Rong Guan, Zhang Wei, Zhou Chuang-bing, 2005. Numerical Analysis of Saturated-Unsaturated Seepage Problem of Rock Slope under Rainfall Infiltration. Chinese Journal of Rock and Soil Mechanics, 26(10): 24-29 (in Chinese with English abstract).
- Shen Yanshen, Zeng Xin, Chen Feifei, et al, 2026. Experimental Study on the Effects of Different Rainfall Patterns on Deformation and Failure of Bedding Rock Slopes with Weak Interlayers. Chinese Journal of Bulletin of Geological Science and Technology, 45(2): 180-195 (in Chinese with English abstract).
- Sun, Y., Li, D., Jiao, L., Liu, Z., Yang, Y., Lyu, J. and Lin, S., 2024. Simulation of Saturated-Unsaturated Seepage Problems via the Virtual Element Method. Computers and Geotechnics, 171: 106326. <https://doi.org/10.1016/j.compgeo.2024.106326>
- Tang Huiming, Li Changdong, Gong Wenping, et al, 2022. Fundamental Attribute and Research Approach of Landslide Evolution. Chinese Journal of Earth Science, 47(12): 4596-4608 (in Chinese with English abstract).
- Tang, H., Wasowski, J. and Juang, C.H., 2019. Geohazards in the Three Gorges Reservoir Area, China – Lessons Learned from Decades of Research. Engineering Geology, 261: 105267. <https://doi.org/10.1016/j.enggeo.2019.105267>
- Wei, X., Zhang, L., Yang, H.-Q., Zhang, L. and Yao, Y.-P., 2021. Machine Learning for Pore-Water Pressure Time-Series Prediction: Application of Recurrent Neural Networks. Geoscience Frontiers, 12(1): 453-467. <https://doi.org/10.1016/j.gsf.2020.04.011>
- Wu Yiping, Yi Yucong, Li Shuo, et al, 2026. Risk Assessment of Rangduchang North Landslide in Wanzhou District, Three Gorges Reservoir area. Chinese Journal of Bulletin of Geological Science and Technology, 45(3): 1-10 (in Chinese with English abstract).
- Xiong, X., Shi, Z., Xiong, Y., Peng, M., Ma, X. and Zhang, F., 2019. Unsaturated Slope Stability around the Three Gorges Reservoir under Various Combinations of Rainfall and Water Level Fluctuation. Engineering Geology, 261: 105231. <https://doi.org/10.1016/j.enggeo.2019.105231>
- Yang, H.-Q., Shi, C. and Zhang, L., 2025. Ensemble Learning of Soil-Water Characteristic Curve for Unsaturated Seepage Using Physics-Informed Neural Networks. Soils and Foundations, 65(1): 101556. <https://doi.org/10.1016/j.sandf.2024.101556>
- Zhan Liang-tong, Jia Guan-wei, Chen Yun-min, FREDLUND D G, 2010. Analytical Solution for Rainfall Infiltration into Infinite Long Slopes Considering Properties of Unsaturated Soil. Chinese Journal of Geotechnical Engineering, 32(08): 1214-1220 (in Chinese with English abstract).
- Zhu, S.R., Wu, L.Z., Shen, Z.H. and Huang, R.Q., 2019. An Improved Iteration Method for the Numerical Solution of Groundwater Flow in Unsaturated Soils. Computers and Geotechnics, 114: 103113. <https://doi.org/10.1016/j.compgeo.2019.103113>
- Zhu, Y., Qiu, H., Liu, Z., Ye, B., Tang, B., Li, Y. and Kamp, U., 2024. Rainfall and Water Level Fluctuations Dominated the Landslide Deformation at Baihetan Reservoir, China. Journal of Hydrology, 642: 131871. <https://doi.org/10.1016/j.jhydrol.2024.131871>

附中文参考文献

- 邓志平, 万旻昊, 潘敏, 等, 2026. 考虑消落带参数退化与空间变异的边坡可靠度分析. 地球科学, 51(2): 547-559.
- 江文豪, 王浩, 廖光志, 等, 2025. 时变降雨场景下双层非饱和土中水分一维瞬态渗流解析解. 岩土力学, 46(09): 1-17.
- 韩佳明, 董照, 苏三庆, 等, 2023. 均质非饱和边坡降雨入渗解析解及在黄土边坡的应用. 岩土力学, 44(01): 241-250.

李长冬, 谭钦文, 2022. 动水驱动型滑坡物理启滑能够预测吗? 地球科学, 47(10): 3908-3910.

彭铭, 王悦, 马晨议, 石振明, 朱艳, 2025. 河谷滑坡灾害链风险评估及防控研究进展. 地球科学, 50(10): 3723-3760.

荣冠, 张伟, 周创兵, 2005. 降雨入渗条件下边坡岩体饱和和非饱和渗流计算. 岩土力学, 26(10): 24-29.

沈颜参, 曾鑫, 陈菲菲, 等, 2026. 不同降雨雨型对含软弱夹层顺层岩质边坡变形破坏影响的试验. 地质科技通报, 45(2): 180-195.

唐辉明, 李长冬, 龚文平, 等, 2022. 滑坡演化的基本属性与研究途径. 地球科学, 47(12): 4596-4608.

吴益平, 易羽聪, 李硕, 等, 2026. 三峡库区万州区瀼渡场北滑坡灾害风险评价. 地质科技通报, 45(3): 1-10.

詹良通, 贾官伟, 陈云敏, FREDLUND D G, 2010. 考虑土体非饱和特性的无限长斜坡降雨入渗解析解. 岩土工程学报, 32(08): 1214-1220.