DOI:10.20040/j.cnki.1000-7709.2025.20240606

基于物理信息神经网络的水库调度研究

王飞龙,胡 挺,肖扬帆

(中国长江三峡集团有限公司,湖北 宜昌 430010)

摘要:传统的水库调度智能模型多是以前馈神经网络或循环神经网络为代表的黑箱模型,模型的可解释性较差,缺乏内部规律的探索。因此,基于物理神经网络基本原理,结合水库调度方程,以出库流量误差及出力误差之和为模型总误差,建立了包含水库调度方程的物理机制神经网络,并以向家坝水库为例,对比了不含水库调度方程的神经网络,讨论了模型隐藏层数及隐藏层神经元个数对模型精度的影响。结果表明,包含水库调度方程的神经网络模型验证效果优于一般前馈神经网络,验证误差率为3%,隐藏层数和神经元个数太少会导致模拟效果较差,而太多的隐藏层数和神经元个数可能对模型精度提升不大,选择合适的隐藏层数和神经元个数是提高模型精度的手段之一。

关键词:水库调度;物理约束;物理信息神经网络;前馈神经网络;PDE

中图分类号:TV697.1^{+}1 **文献标志码**:A **文章编号**:1000-7709(2025)04-0213-04

1 引言

基于动态规划、POA等传统水库调度方法[1-2]及不断改进的优化调度模型[3]已较为广泛地应用于水库科学调度中,能较全面指导中长期的水库调度运用,而在实时调度运用较少。随着智能调度技术的兴起,出现了以循环神经网络为代表的深度学习水库调度模型,亦应用于实时水库调度研究中[4-5],但其网络结构为黑箱模型,可解释性差,未能将水库调度方程结合到神经网络结构中。随着神经网络模型理论的不断更新,出现了基于物理机制的物理信息神经网络(PINN)。在流体力学方面,勒放等[6]构建了两个并行的神经网络求解浅水波方程,模型较好地克服了浅水波方程激波与稀疏波问题;方卫华等[7]利用PINN神经网络求解规则断面的圣维南方程,表明PINN对非恒定流模拟具有较好的适应性;XIANG Z等[8]采用损失函数的加权组合方式有效提高了PINN神经网络训练效率。除了将PINN运用至求解偏微分方程外,也有利用加深PINN网络结构来求解偏微分方程,如采用神经算子[9]或迁移学习[10],不过目前复杂PINN结构效果是否优于简单PINN结构尚无明确定论。尽管目前出现了较多利用PINN求解不同领域偏微分方程的研究,但将PINN模型运用至实际工程案例较少,一方面是实际工程边界更加复杂,运用PINN在处理边界条件时较为困难;另一方面是传统的PINN主要解决固定的偏微分方程,而实际案例可能并非固定方程组。此外,将PINN运用至水库调度亦鲜见报道。鉴此,本文以向家坝水库为例,利用PINN网络结构,搭建一种基于PINN的水库调度模型,为后续不断改进及拓展PINN在水库调度领域应用提供借鉴。

2 数据和原理

2.1 数据来源

向家坝水电站位于云南省水富市,为金沙江下游最后一级电站,2012年建成投运使用。本文收集了2021、2022年向家坝水库入库流量、出库流量、电站出力资料及水库特性曲线(水位库容曲线、尾水位流量曲线、水头损失曲线、出力系数曲线),其中水库入出库流量、出力资料来自三峡集团,特性曲线取自初步设计资料。

2.2 PINN基本原理

神经网络模型具有强大的非线性拟合能力,理论上能拟合任意目标函数,物理机制神经网络则通过将偏微分方程的物理方程、边界约束编入

收稿日期:2024-04-02,**修回日期**:2024-07-03

基金项目:国家重点研发计划(2021YFC3200303);国家自然科学基金项目(U2340205)

作者简介:王飞龙(1995-),男,工程师,研究方向为水力学及河流动力学,E-mail:2500474271@qq.com

中国知网 https://www.cnki.net

神经网络结构中的损失函数，通过训练损失函数，从而学习物理方程的约束达到不断逼近物理方程的效果。PINN 通常将有限元方法计算偏微分方程的数值解及边界条件作为输入条件，用偏微分方程等式、边界条件及数值作为损失函数，损失函数为：

$$L_{\mathrm{loss}_u}=L_{\mathrm{loss}_{u_x}}+L_{\mathrm{loss}_{u_t}}+L_{\mathrm{loss}_x} \tag{1}$$

式中，L_{loss_u} 为目标函数；$L_{\mathrm{loss}_{u_x}}$ 为方程等式损失；$L_{\mathrm{loss}_{u_t}}$ 为边界条件损失；L_{loss_x} 为数值损失。

优化总损失函数 L_{loss_u} 达到最小，使得预测值与真实值尽量接近，其基本结构见图 1。图 1 中，$N_{\mathrm{N}}(x,t)$ 为前馈神经网络；x 为输入变量值；t 为时间；σ 为神经元；u 为预测值；$\partial u/\partial t$、$\partial u/\partial x$、$\partial u^2/\partial x^2$ 分别为 u 的一阶时间偏导、一阶 x 偏导、二阶 x 偏导；R 为偏导函数；$M_{\mathrm{MSE}_{\{R\}}}$ 为偏导函数误差；$M_{\mathrm{MSE}_{\{u,BC,IC\}}}$ 为边界值与初始值误差；M_{MSE} 为所有误差之和；ε 为容许误差值。

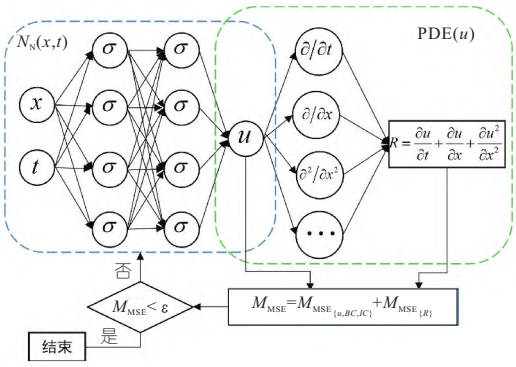


图 1 PINN 网络模型基本结构

Fig. 1 Basic structure of PINN network

2.3 水库调度方程

拟定的水库调度方程包含水量平衡方程、尾水位方程、水位库容方程、毛水头方程、水头损失方程、出力系数方程、出力方程，各方程的计算公式分别为：

$$V_{t+1}=V_t+(Q_{\mathrm{in}}-Q_{\mathrm{out}})\Delta t \tag{2}$$

$$Z_{\mathrm{down}}=f(Q_{\mathrm{out}}) \tag{3}$$

$$Z_{\mathrm{up}}=\varphi(V) \tag{4}$$

$$H=Z_{\mathrm{up}}-Z_{\mathrm{down}} \tag{5}$$

$$H_{\mathrm{loss}}=\phi(H) \tag{6}$$

$$k=\gamma(H) \tag{7}$$

$$H_{\mathrm{net}}=H-H_{\mathrm{loss}} \tag{8}$$

$$N=kQ_{\mathrm{out}}H_{\mathrm{net}} \tag{9}$$

式中，V_{t+1}、V_t 分别为 $t+1$、t 时刻库容，m^3；Q_{in}、Q_{out} 分别为入、出库流量，m^3/s；Δt 为时间，s；Z_{down} 为下游水位，m；f 为尾水位函数，一般为尾水位流量曲线；Z_{up} 为库水位，m；φ 为水位库容函数，一般为水位库容曲线；H_{loss} 为水头损失，m；ϕ 为水头损失函数，一般为毛水头与水头损失曲线；k 为出力系数；γ 为出力系数函数，一般为毛水头与出力系数曲线；N 为出力，kW；H_{net} 为净水位头，m。

本文考虑水库无弃水情况下的工况，因此以出库流量代替发电流量。

3 PINN 与水库方程耦合过程

3.1 模型构建

水库实际调度过程中一般根据来水预报和电网出力要求后制定相应的下泄规则，因此以入库流量、电站出力为输入条件，出库流量作为预测变量。以向家坝 2021 年 1 月 1 日～6 月 30 日数据进行训练，用 2022 年 1 月 1 日～6 月 16 日数据进行验证，具体过程见图 2。由图 2 可看出，出库流量过程与出力过程保持相同的趋势。

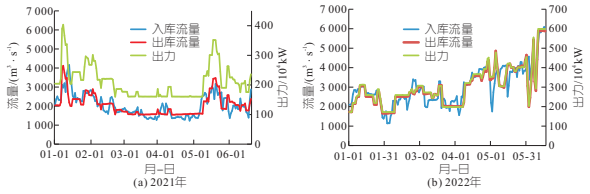


图 2 2021、2022 年消落期向家坝入出库流量和出力过程

Fig. 2 Inflow and outflow flow and output process of Xiangjiaba during decline period in 2021 and 2022

根据神经网络能拟合非线性函数的能力，通过将入库流量和电站出力输入就能得到出库流量，因此将经过神经网络反向传播后的出库流量认为是已知变量，代入到水量平衡方程中即可得到下一时刻库容，然后再通过式(2)～(9)进一步求出电站出力，将计算的电站出力与实际出力的差值作为误差项之一，称为 PDE 误差。同时，将前馈神经网络计算的出库流量与实际流量作差，其差值也作为误差项。最后将出力误差项与出库流量误差项求和，得到网络总的误差，流程见图 3。图 3 中，L_{loss1}、L_{loss2} 分别为出库流量预测值、电站出力预测值与实际值误差项；L_{loss} 为总误差项。通过不断训练网络，就能使前馈神经网络学习到水库调度的一系列方程。

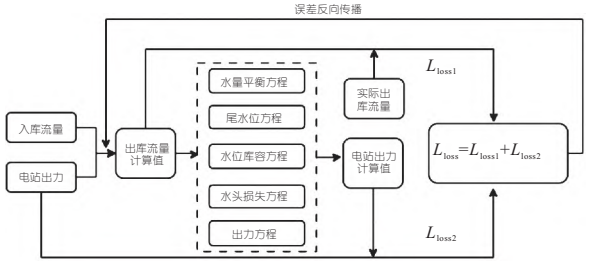


图 3 水库调度方程与 PINN 网络耦合过程

Fig. 3 Coupling process of reservoir operation equation and PINN network

模型采用 Pytorch 构架进行编写，在网络模

中国知网 https://www.cnki.net

型结构设计方面,首先对数据进行归一化,这样可以增加模型稳定性,此外,模型计算完出库流量后需对计算的出库流量进行反归一化,再代入电站出力计算过程,得到计算的电站出力后需对计算出力进行归一化,并与归一化的实际出力作差求得 L_{loss2};归一化的实际流量与计算流量作差得到 L_{loss1},总的误差损失 $L_{loss}=L_{loss1}+L_{loss2}$。

3.2　模型验证

耦合水库调度的 PINN 神经网络模型采用 8 层隐藏神经网络,每层神经元个数为 30 个,训练集预测值与真实值对比见图 4(a),损失函数训练过程见图 5。当训练次数达到 60 后损失函数变化较小,基本稳定。预测值与真实值较为吻合,计算的出库流量平均绝对误差为 52 m^3/s,最大偏高 279 m^3/s,最大偏低 325 m^3/s,误差率为 2%。验证集计算的出库流域与真实值对比见图 4(b)。由图 4(b)可知,计算的出库流量平均绝对误差为 84 m^3/s,最大偏高 423 m^3/s,最大偏低 186 m^3/s,误差率为 3%。所构建的包含水库调度方程的 PINN 神经网络能较好地模拟向家坝水库的真实出库流量情况。

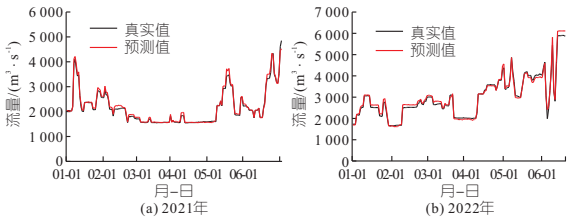


图 4　模型训练、验证真实值与预测值对比

Fig. 4　Comparison between actual and predicted values of model training and validation

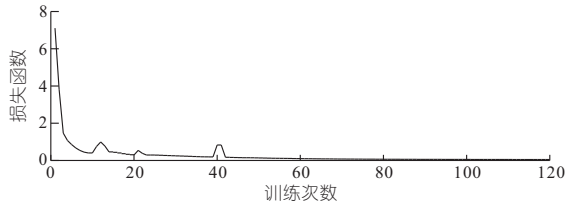


图 5　损失函数训练过程

Fig. 5　Training process of loss function

4　模型讨论

4.1　与不含 PDE 误差项的网络对比

将包含调度方程的神经网络结构称为含 PDE 误差项的网络。不含 PDE 误差项的神经网络即为一般的前馈神经网络,网络误差项仅为出库流量误差,采用与 PDE 神经网络相同神经元个数及训练次数,重新训练不含 PDE 误差项的神经网络,验证集结果对比见图 6。由图 6 可知,有无

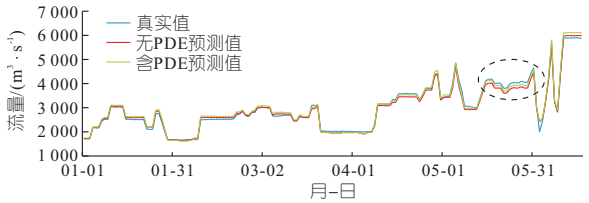


图 6　有无 PDE 的预测值与真实值对比

Fig. 6　Comparison between predicted and true values with and without PDE

PDE 误差项的网络结构预测值与真实值的趋势保持一致,且预测值与真实值也较为接近,试验误差均在 3%左右,含 PDE 的预测结果比无 PDE 的预测结果更接近真实值(图 6 中标注的虚线)。

4.2　不同网络层数精度对比

试验包含了 2、3、5、8、10 层隐藏层,每层隐藏层的神经元个数为 30 个,不同隐藏层数网络结构模拟对比结果见图 7。由图 7 可看出,3～8 层的网络层数比 2、10 层模拟效果好,隐藏层数太少则不能得到较为精确的解,隐藏层数太多则可能出现过拟合现象。对于含 PDE 误差项的神经网络,选择合适的隐藏层数对模型精度会产生一定影响。由表 1 可知,3 层隐藏层数效果最好,计算流量平均绝对误差为 58 m^3/s。

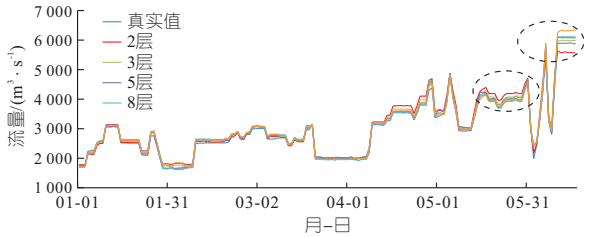


图 7　不同隐含层数结构模拟效果对比

Fig. 7　Comparison of simulation effects of different hidden layer structures

表 1　不同隐藏层数误差对比

Tab. 1　Comparison of errors in different hidden layers

m

月份	不同隐藏层数误差				
	2 层	3 层	5 层	8 层	10 层
1	56	54	77	79	73
2	64	66	69	85	94
3	43	52	49	73	61
4	149	80	56	45	48
5	127	42	73	83	69
平均误差	88	58	65	73	69

4.3　隐藏层不同神经元个数精度对比

以 3 层隐藏层模型为例,分别构建了隐藏层神经元个数为 5、20、30、50 个的 PINN 神经网络并进行训练及验证,其中验证集不同隐藏层神经元个数的模拟效果对比见图 8。由图 8 可看出,当每层隐藏层神经元个数为 5 时的模拟效果最差,基本不能模拟真实出库流量的趋势,随着神经元个数的增加,模拟值也逐渐接近真实值。当每

中国知网　https://www.cnki.net

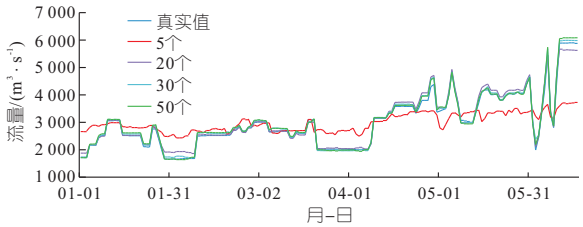


图 8 隐藏层不同神经元个数模拟效果对比

Fig. 8 Comparison of simulation effects of different numbers of neurons in hidden layer

层神经元个数为 30 时，出库流量平均绝对误差最小；当每层神经元个数为 50 时，模型精度提升较小(表 2)。因此，隐藏层神经元个数太少不能准确模拟出真实值，太多则可能会影响计算效率，对模型精度提升不大，选择合适的隐藏层神经元个数对兼顾模型精度和计算效率具有重要意义。

表 2 不同隐含层神经元个数模拟误差对比

Tab. 2 Comparison of simulation errors for number of neurons in different hidden layers m

月份	不同神经元个数模拟误差			
	5 个	20 个	30 个	50 个
1	467	62	54	71
2	382	81	66	71
3	300	33	52	58
4	386	124	80	60
5	649	109	42	41
平均误差	437	82	58	60

5 结论

a. 基于物理机制神经网络模型原理，结合水库调度方程，以出力损失误差和出库流量误差之和为模型总误差，构建了以向家坝入库流量和电站出力为输入条件、出库流量为输出的 PINN 神经网络，模型能较好模拟出向家坝的出库流量过程，误差率为 3%。相较于一般前馈神经网络，含物理方程的神经网络模拟效果较好。

b. 不同隐藏层数及隐藏层不同神经元个数对影响模型精度和计算效率具有关键作用，选择合适隐藏层数和隐藏层神经元个数是兼顾模型精度和效率的手段之一。

参考文献：

[1] 王峰，王建平，王亦宁，等. 改进的显随机动态规划在梯级水库优化调度中的应用[J]. 中国农村水利水电，2023(8)：7-12.

[2] 杨斌斌，孙万光. 改进 POA 算法在流域防洪优化调度中的应用[J]. 水电能源科学，2010，28(12)：36-38，115.

[3] 汪涛，徐杨，刘亚新，等. 基于多种群引力粒子群算法的金沙江下游—三峡梯级水库群优化调度[J]. 长江科学院院报，2023，40(12)：30-36，58.

[4] 徐刚，舒远丽，任玉峰，等. 基于深度学习的三峡水库实时防洪调度模型[J]. 水力发电学报，2022，41(3)：60-69.

[5] 汤正阳，张迪，林俊强，等. 基于循环神经网络算法的水库调度模拟[J]. 水电能源科学，2021，39(5)：83-86，70.

[6] 靳放，郑素佩，封建湖，等. 求解浅水波方程的并行物理信息神经网络算法[J]. 计算力学学报，2024，41(2)：352-358.

[7] 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.

[8] XIANG Z，PENG W，ZHENG X，et al. Self-adaptive loss balanced physics-informed neural networks for the incompressible Navier-Stokes equations [J]. 2021. DOI：10. 48550/arXiv. 2104. 06217.

[9] 李道伦，沈路航，查文舒，等. 基于神经算子与类物理信息神经网络智能求解新进展[J]. 力学学报，2024，56(4)：875-889.

[10] 郭远，傅卓佳，闵建，等. 迁移学习物理信息神经网络用于长时间非线性波传播模拟[J]. 力学学报，2024，56(3)：763-773.

Research on Reservoir Operation Based on Physical Information Neural Networks

WANG Fei-long，HU Ting，XIAO Yang-fan

(China Three Gorges Corporation，Yichang 430010，China)

Abstract：The traditional intelligent model of reservoir operation is mostly a black box model represented by feedforward neural network or recurrent neural network. The interpretability of the model is poor and lacks the exploration of internal laws. In view of this，based on the basic principles of physical neural networks，combined with the reservoir operation equation，this paper takes the sum of the outflow error and the output error as the total error of the model，and establishes a physical mechanism neural network containing the reservoir operation equation. Taking Xiangjiaba Reservoir as an example，the neural network without the reservoir operation equation is compared，and the impact of the number of hidden layers and the number of hidden layer neurons on the accuracy of the model is discussed. The results show that the verification effect of the neural network model containing the reservoir operation equation is better than that of the general feedforward neural network，and the verification error rate is 3%. Too few hidden layers and the number of neurons will lead to poor simulation results，while too many hidden layers and the number of neurons may not improve the accuracy of the model. Choosing the appropriate hidden layers and the number of neurons is one of the means to improve the accuracy of the model.

Key words：reservoir operation；physical constraints；physical information neural network；feedforward neural network；PDE

中国知网 https://www.cnki.net