

基于机器学习的城市积水风险预测研究

魏红霞

(山西筑星建筑设计有限公司, 山西 太原 030024)

摘要: 随着城市化进程的加剧,城市道路硬化后,地表的雨水渗透能力显著降低,雨水吸纳能力逐渐减弱,导致地表径流增加,城市内涝风险加剧,积水预测成为城市防洪减灾的重要技术手段。结合机器学习方法,提出了一种综合预测模型,用于模拟降雨过程中的径流量、排水能力以及积水深度的变化。使用某地降雨径流和排水能力参数,使用粒子群优化的 BP 神经网络对积水深度进行预测。通过 2024 年 8 月 24 日的降雨与积水深度的数据实验验证,结果表明粒子群优化的 BP 神经网络在预测准确度上优于传统 BP 网络,为城市积水预测和防洪提供了新的技术思路。

关键词: 道路积水;粒子群优化;城市内涝;防洪减灾

中图分类号: TU998.4

文献标志码: A

文章编号: 1009-7716(2025)11-0175-05

Research on Urban Waterlogging Risk Prediction Based on Machine Learning

WEI Hongxia

(Shanxi Zhuxing Architectural Design Co., Ltd., Taiyuan 030024, China)

Abstract: With the acceleration of urbanization, after the hardening of urban roads, the rainwater infiltration capacity of the surface has significantly decreased, and the rainwater absorption capacity has gradually weakened, leading to an increase in surface runoff and exacerbating the risk of urban waterlogging. Waterlogging prediction has become an important technical means for urban flood control and disaster reduction. Combined with the machine learning methods, a comprehensive prediction model is proposed for simulating changes in runoff, drainage capacity and waterlogging depth during rainfall. Using rainfall-runoff and drainage capacity parameters from a certain area, a particle swarm optimization (PSO)-based BP neural network is used to predict the waterlogging depth. The experimental verification with rainfall and waterlogging depth data on August 24, 2024 shows that the PSO-based BP neural network is superior to the traditional BP network in prediction accuracy, providing a new technical approach for urban waterlogging prediction and flood control.

Keywords: road waterlogging; particle swarm optimization; urban waterlogging; flood control and disaster reduction

0 引言

随着城市化进程的加快,道路硬化现象日益普遍,导致城市道路的雨水渗透能力显著降低,雨水吸纳能力逐渐减弱^[1]。导致城市内涝问题日益突出,由于降雨强度超过排水系统容量而引发的积水现象,对城市交通、居民生活和基础设施造成严重影响^[2]。近年来,在全球气候变暖态势持续加剧与城市化进程不断加速的背景下,极端天气降雨事件频发,根据世界气象组织(World Meteorological Organization, WMO)的报告,全球范围内极端降雨事

件的发生频率在过去十年中增加了约 30%,城市内涝问题日益严重。这对城市积水深度预测提出了更高的要求^[3-7]。

积水预测是城市防洪减灾的重要技术手段,能够为应急管理和决策提供科学依据。通过预测降雨径流和积水深度,可以提前采取措施,减少内涝对城市的影响。例如,提前疏导交通、部署应急救援力量和优化排水系统运行等。此外,准确的积水预测还可以为城市规划和排水系统设计提供参考,提高城市应对极端降雨事件的能力^[8-11]。

传统的积水预测方法主要基于物理模型,通过计算降雨径流和排水能力来模拟积水过程。然而,物理模型的优点在于其基于物理规律,能够提供直观的解释,但对参数的依赖性较强,对于复杂地形呈

收稿日期: 2025-06-10

作者简介: 魏红霞(1983—),女,硕士,工程师,从事城市气候与内涝模拟研究工作。

现非线性关系,使水文物理模型的建立存在一定的局限性。近年来,机器学习方法在非线性建模和预测中展现出良好的性能,尤其是神经网络、支持向量机和决策树等方法在降雨与积水预测中的应用取得了显著成果^[9]。将粒子群(Particle Swarm Optimization, PSO)与BP(Backpropagation)神经网络的结合,优化神经网络的权值和阈值,提高输入输出量的关联度,从而有效提高预测精度。文章通过结合物理模型和机器学习方法,提出了一种综合预测模型,旨在提高降雨与积水预测的精度和可靠性,为城市防洪减灾提供技术支持。通过物理模型计算降雨径流和排水能力,结合粒子群优化的BP神经网络对积水深度进行预测,可以充分发挥物理模型和机器学习方法的优势,克服各自的局限性,不仅能够提供直观的物理解释,还能有效处理非线性关系,提高预测精度,对不同的地形地貌的积水预测具有较强的适用性。

1 理论基础

1.1 物理模型

降雨径流计算是水文模型和城市内涝模拟的核心环节,其核心是通过量化降雨转化为地表径流的过程,通过计算降雨径流和排水能力来模拟积水过程^[10-12]。为排水系统设计、洪水风险评估等提供依据。水文物理模型主要参数包括降雨量、径流系数、汇水面积、地形坡度、管径和曼宁系数等。

1.1.1 降雨径流

降雨径流是降雨过程中地表径流的流量,计算公式如下:

$$Q = \frac{C \cdot P \cdot A}{3.6}$$

式中: Q 为径流量, m^3/s ; C 为径流系数; P 为降雨量, mm/h ; A 为汇水面积, km^2 。

径流系数 C 是地表径流量与降雨量的比值,反映了地表径流的产生效率。不同土地利用类型和下垫面条件下的径流系数有所不同。例如,不透水表面(如混凝土和沥青)的径流系数较高,而植被覆盖区域的径流系数较低。

1.1.2 排水能力计算

排水能力是排水系统的最大排水流量^[13-15],计算公式如下:

$$Q_{\text{drain}} = \pi \cdot D^2 \cdot v$$

式中: Q_{drain} 为排水能力, m^3/s ; D 为管径, m ; v 为流速, m/s 。

流速 v 的计算公式为: $v = \frac{1}{n} \cdot R^{2/3} \cdot S^{1/2}$,其中, R 为水力半径, m ; S 为地形坡度(小数); n 为曼宁系数。

曼宁系数 n 是反映管道粗糙度的参数,不同材质和状况的管道具有不同的曼宁系数。例如,混凝土管道的曼宁系数较低,而老旧铸铁管道的曼宁系数较高。

1.1.3 积水深度计算

积水深度是径流量与排水能力的差值在时间上的累积,计算公式如下:

$$H = \frac{V_{\text{accumulated}}}{A_{\text{m}}}$$

式中: H 为积水深度, m ; $V_{\text{accumulated}}$ 为累积积水体积, m^3 ; A_{m} 为汇水面积, m^2 。

1.2 机器学习模型

在人工智能技术领域中,机器学习模型占据重要地位。它通过从海量数据中自主提炼模式和规律,建立输入与输出之间的复杂函数关系,尤其在处理非线性问题、挖掘数据深层特征和实现精准预测方面展现出强大优势。

1.2.1 BP神经网络

BP神经网络作为深度学习领域的经典模型,是一种多层前馈神经网络,通过独特的反向传播机制和梯度优化策略,最小化预测误差,实现了复杂非线性映射的高效学习。

BP神经网络的构架由输入层、隐含层(单层或多层)及输出层组成,层间通过权重系数实现连接,而同层神经元之间无连接关系。其中,输入层接收数据输入,隐含层通过激活函数完成非线性变换,输出层则用于产生预测结果。

BP网络的训练包含前向传导与反向传导两个阶段。前向传导阶段:输入数据从输入层进入网络,经隐含层的加权求和与激活函数运算后,逐层传递至输出层形成结果;反向传导阶段:先计算输出层的预测误差,再依据链式法则逐层推导各层的误差项,最后通过最大梯度下降算法更新网络权重,以实现误差最小化。这种迭代优化过程使网络能够持续调整参数,提升对输入输出数据的映射精度。

1.2.2 粒子群优化

粒子群优化是一种群体智慧范畴的寻优算法,通过模拟鸟群迁徙的群体行为,搜索全局最优解^{[9][15-18]}。PSO算法中,每个粒子代表一个候选解,具有特定的位置和速度属性。粒子在搜索空间中飞

行,通过调整速度和位置不断逼近最优解。PSO 算法的主要步骤包括粒子群初始化、适应度值计算、更新个体最优解和群体全局最优解、优化调整粒子速度和位置等。

(1) 粒子群初始化

在可预测解空间内随机生成规模为 N 的粒子群。每个粒子的位置 X_i 需满足问题定义域要求,即 $x_{\min} \leq X_i \leq x_{\max}$; 速度 V_i 通常限定在 $v_{\min} \leq V_i \leq v_{\max}$ 区间,防止粒子搜索时出现过度跳跃。

(2) 适应度函数评估

根据具体优化目标定义适应度函数 $F(X)$,用于量化每个粒子位置的优劣程度。 $F(X)$ 为目标函数值,计算每个粒子的适应度后,将当前最优解对应的粒子分别标记为个体初始最优解 $pbest$ 和全局初始最优解 $gbest$ 。

(3) 个体最优解更新

将每个粒子当前位置的适应度与全局最优位置的适应度进行比较,若当前位置更优,则更新该粒子的 $pbest$:

$$pbest_{ij} = \begin{cases} x_{ij}, & \text{当 } F(x_{ij}) < F(pbest_{ij}) \\ pbest_{ij}, & \text{其他情况下} \end{cases}$$

式中: i 表示粒子编号, j 表示解空间维度。

(4) 全局最优解更新

代入所有粒子的 $pbest$,找出其中适应度函数 $F(X)$ 最佳的 $F(pbest)$,将其确定为全局最优解:
 $gbest = \arg(\min_{i=1}^N F(pbest_i))$

(5) 速度与位置迭代更新

更新粒子的速度和位置的方法用以下公式:

$$v_{ij}(t+1) = w \cdot v_{ij}(t) + c_1 r_1 (pbest_{ij} - x_{ij}(t)) + c_2 r_2 (gbest_j - x_{ij}(t))$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1)$$

式中: w 为惯性权重,控制粒子对上一次速度的继承程度,较大的 w 利于大范围全局搜索,较小的 w 则侧重局部精细寻优; c_1 和 c_2 是学习因子,一般取值在 1.5~2.0 之间,分别调节粒子向个体最优和全局最优学习的强度; r_1 和 r_2 是 $[0, 1]$ 区间内相互独立的随机数,为搜索过程引入随机性; t 代表当前迭代次数。

(6) 迭代终止判定

当满足以下条件之一时,算法停止迭代:

达到预先设定的最大迭代次数;

全局最优解在连续多代迭代中无明显改善;

适应度值达到预先设定的精度要求。

1.2.3 粒子群优化的 BP 神经网络

基本的 BP 神经网络依靠反向传播算法调整网络参数,但其性能高度依赖初始权重和阈值的选取。由于参数随机初始化,网络在训练过程中会陷入局部最优解,导致预测网络参数精度受限。此外,BP 神经网络采用最速梯度下降法进行参数更新,学习率若设置不当,容易出现收敛速度缓慢甚至不收敛的问题。

粒子群优化 BP 神经网络 (PSO-BP) 是一种将 PSO 算法与传统 BP 神经网络相融合的智能算法,通过 PSO 算法对 BP 神经网络的初始权重和阈值进行,有效克服了 BP 神经网络易陷入局部最优解、收敛速度慢的缺陷,显著提升模型的预测精度和泛化能力。

在 PSO-BP 模型中,每组粒子代表一组 BP 神经网络的权重和阈值。在迭代过程中,粒子根据个体最优解和整个种群的全局最优解来更新自己的速度和位置。寻找使 BP 神经网络预测误差最小的参数组合。

相比传统 BP 神经网络,PSO-BP 在复杂非线性问题的求解中优势显著。它不仅能够有效避免陷入局部最优,还能提升网络收敛速度,提高预测的准确性和稳定性。

2 实验

2.1 数据准备

实验数据包括降雨量、汇水面积、地形坡度、管径和曼宁系数等参数,以及对应的积水深度数据。数据来源包括气象站观测数据、城市排水系统设计参数和实地测量数据。实验数据为 2020 年 8 月 26 日山西大同市区某点 24 小时降雨量数据、水文参数(径流系数 0.8、汇水面积 0.15 km²、地形坡度 1.0%、管径 0.5 m 和曼宁系数 0.013)以及对应的积水深度数据。

2.2 物理模型实验

物理模型通过理论计算实现,计算降雨径流、排水能力和积水深度。主要步骤包括初始参数、径流计算、排水能力计算和积水深度计算。经计算表明,物理模型能够有效计算出降雨过程中的动态变化。降雨量、积水深度如图 1 所示。在降雨强度较高时,物理模型能够较好地预测积水深度的变化趋势,但在复杂地形和非线性关系中会存在一定的误差。

物理模型可计算降雨径流、排水能力和积水深度。能够有效模拟降雨径流和排水能力的变化,但




图1 降雨与积水物理模型仿真结果

在复杂地形环境下对积水深度的预测精度受到参数选择的影响。实验结果表明,物理模型能够有效计算出降雨过程中的动态变化。在降雨强度较高时,模型能够较好地预测积水深度的变化趋势,但在地形坡度变化较大的区域,模型预测的积水深度与实际观测值存在较大偏差。此外,模型对短时强降雨事件的响应速度模拟不够准确,导致预测结果滞后于实际变化。

2.3 机器学习模型实验

2.3.1 标准BP神经网络

标准BP神经网络通过MATLAB实现,训练过程中调整网络权重使预测误差最小。实验数据取与物理模型实验数据相同。数据分为训练集(前20个样本)和测试集(全部24个样本),用于模型训练和验证。数据经过归一化处理,从而来提高模型的训练效率和预测精度。仿真结果如图2所示,结果表明,标准BP网络能够较好地拟合训练数据,但在测试数据上的预测精度有限,主要由于网络容易陷入局部最优。通过调整学习速率和增加训练次数,可以一定程度上提高预测精度,但仍难以满足高精度预测的要求。




图2 BP神经网络预测结果

2.3.2 粒子群优化的BP神经网络

粒子群优化的BP神经网络通过PSO算法改变网络权重和阈值,提高预测结果精度。经MATLAB仿真后,结果如图3所示。数据分析显示,PSO优化后的BP网络在测试数据上的预测精度较标准BP网络有明显提高。PSO算法有效的提高了网络的全局搜索能力,有效的规避了局部最优问题,使网络更精准地捕捉积水深度的动态变化特性。




图3 PSO-BP神经网络预测结果

3 结果分析

标准BP神经网络虽然在训练数据上表现出良好的拟合效果,但在测试数据上的预测精度有限,主要由于网络容易陷入局部最优。实验结果表明,标准BP网络在测试集上的均方误差(Mean Squared Error, MSE)为0.006293,说明模型在普适性上存在不足。通过调整网络结构和训练参数,可以一定程度上提高预测精度,但仍难以满足高精度预测的要求。

PSO优化后的BP神经网络在测试数据上的预测精度显著提高,能够更好地捕捉积水深度的动态变化。实验结果表明,PSO优化后的BP网络在测试集上的MSE降低到0.003530,相比标准BP网络提高了约44.3%。PSO算法通过优化网络权重和阈值,有效提高了网络的全局搜索能力,避免局部最优,使网络更好地适应非线性关系。

对比物理模型和机器学习模型的结果,物理模型在降雨强度较高时能够较好地模拟积水深度的变化,但对复杂地形和非线性关系的适应性较差。机器学习模型,尤其是PSO优化的BP神经网络,能够更好地处理非线性关系,预测精度更高。例如,在地形较为复杂的区域,PSO优化的BP网络能够更准确地预测积水深度的变化,而物理模型中参数的简化使预测结果存在较大的偏差。此外,机器学习模型

对短时强降雨事件的响应速度模拟更为准确,能够及时捕捉积水深度的快速变化。

4 讨论

4.1 模型优缺点

尽管粒子群神经网络模型在城市内涝积水深度预测中取得了较好的效果,但本研究仍存在一定的局限性。在数据获取方面,虽然收集了降雨、地形、排水管网等多源数据,但部分数据的精度和完整性仍有待提高。例如,排水管网数据中可能存在部分管道信息缺失或不准确的情况,这会影响模型对排水系统运行状况的准确评估,进而影响内涝积水深度的预测精度。在一些老旧城区,由于排水管网建设年代久远,相关资料保存不完整,导致部分管道的管径、材质等信息难以准确获取,使得模型在处理这些区域的数据时存在一定的误差。

4.2 未来研究方向

未来的研究可以进一步优化物理模型的参数选择,提高其在复杂地形中的适用性。还可以探索物理模型和机器学习模型的融合方法,充分发挥两者的优点,克服各自的局限性,进一步提高预测精度。

5 结论

文章结合物理模型和机器学习方法,提出了一种综合预测模型,用于降雨与积水的动态预测。实验结果表明,通过实时监测多源数据,并将其输入到粒子群神经网络模型中,能够提前数小时甚至数天预测城市内涝积水深度,准确的内涝积水深度预测能够为城市管理者提供及时、可靠的预警信息,帮助他们有针对性地组织人员和物资进行排水抢险工作,提高排水系统的运行效率,减少积水的形成和积聚,降低城市内涝的风险。避免因内涝导致的交通

瘫痪、基础设施损坏和人员伤亡等问题。提前做好防范准备,减少内涝灾害带来的损失。

参考文献:

- [1] 丁一,赵碧莹,闫爱霞,等.基于多技术融合的内涝风险预警系统研究[J].信息技术,2025(3):8-15.
- [2] 薛丰昌,杨猛,陈剑飞,等.城市内涝监测点积水深度 LSTM 预测模型[J].测绘科学,2025,50(3):159-167.
- [3] 盛志军,周雨,孟明华,等.基于随机森林算法的城市内涝风险预估方法及应用——以南昌市为例[J].暴雨灾害,2025,44(1):93-101.
- [4] 林凯荣,欧阳佳娜,马旭民,等.基于深度学习的城市内涝积水水深预测模型[J].水资源保护,2025,41(1):56-63.
- [5] 丁华龙.深圳市降雨-内涝灾情时空分布特性及致灾雨量分析[J].水上安全,2024(22):112-114.
- [6] 许绘香,刘炜.基于长短期记忆网络的城市积水内涝风险预警[J].计算机仿真,2024,41(9):505-509.
- [7] 郭亮,孟昭辉,孙志豪,等.基于城市内涝模拟的管网排水能力及内涝风险评估研究[J].给水排水,2024,60(7):121-129.
- [8] 陈鹏,梁馨月,孙滢悦.土壤渗透性变化对城市暴雨内涝积水过程影响研究:以长春市南关区为例[J].水利水电技术(中英文),2025,56(3):87-97.
- [9] 吴颖.基于机器学习的城市内涝风险评估与预测研究[D].北京:北京建筑大学,2024.
- [10] 周鹏.基于小样本学习的路面积水检测的研究[D].中原工学院,2024.
- [11] 梁鑫,侯精明,陈光照,等.考虑降雨空间分布的城市内涝对模式雨型响应特征分析[J].水利水运工程学报,2024(2):44-54.
- [12] 徐灵华,曾云辉,胡腾宇,等.连续道路上多雨水口径流特性数值模拟研究[J].天津建设科技,2023,33(5):7-13.
- [13] 肖桐,余敦先,夏军,等.不同降雨情况对武汉市主城区典型区域积水过程影响分析[J].武汉大学学报(工学版),2023,56(8):969-977.
- [14] 姚樱.雨水口对城市道路路面雨水排放的影响[J].智能建筑与智慧城市,2023(3):169-171.
- [15] 邢健,任贺靖,晏清洪,等.基于 SWMM 模型的道路积水分析[J].科技创新与应用,2020(6):48-50.
- [16] 刘嘉晨.基于多技术的路面积水监测预警系统的设计与实现[D].内蒙古大学,2019.