

基于 BP 神经网络的雨水管网充满度预测

盛 政¹, 王浩正¹, 胡 坚²

(1. 江苏满江春城市规划设计研究有限责任公司, 江苏 镇江 212000; 2. 镇江市住房和城乡建设局, 江苏 镇江 212000)

摘要: 以镇江市某小区雨水管为研究对象, 基于水动力学机理模型, 指导设定 BP 神经网络的输入与输出, 并在 Google 的 TensorFlow 平台下进行程序设计以及神经网络的训练和验证, 完成对管网下一时刻充满度的预测。结果表明, 在一定边界条件下, BP 神经网络能够较好地完成学习与训练, 且预测误差较小, 满足实际应用所需的精度要求。

关键词: BP 神经网络; 雨水管网; 充满度; TensorFlow 平台

中图分类号: TU992 **文献标识码:** C **文章编号:** 1000-4602(2018)23-0130-04

Prediction of Storm Sewer Capacity Based on BP Neural Network

SHENG Zheng¹, WANG Hao-zheng¹, HU Jian²

(1. Jiangsu Manjiangchun Urban Planning and Design Co. Ltd., Zhenjiang 212000, China; 2. Zhenjiang Housing and Urban-Rural Development Bureau, Zhenjiang 212000, China)

Abstract: Using the storm sewer data of a residential district in Zhenjiang, the input and output of BP neural network were set based on the hydrodynamic mechanism model, and the program design and neural network training and verification were conducted under Google's TensorFlow platform to predict the next moment capacity of the storm sewer. The results indicated that the BP neural network could complete the learning and training satisfactorily under certain boundary conditions. The forecast error was small, which could meet the requirement of practical application.

Key words: BP neural network; storm sewer network; capacity; TensorFlow platform

城市排水管网系统是重要的城市基础设施, 也是城市水污染防治和排水防涝的骨干工程, 其输入水源来自于自然降雨(雪)、生活污水及工业废水等, 同时又受管道漏损、河道顶托、海水潮汐等复杂因素影响, 系统排水流量具有非线性的特点。目前, 行业内大都采用基于水动力学汇流模拟方法的机理模型来进行排水管网建模^[1], 但应用效果和应用层次参差不齐, 主要原因有:①机理模型所需基础数据量大、来源复杂, 其中结构型数据多来源于测绘或图纸, 专业参数多来源于专业人员的经验, 准确性不够, 导致模型的计算结果偏差较大, 管理部门无法根据模型结果进行决策;②当机理模型参与计算的节点数较大时, 计算所需时间通常较长, 甚至超过传感

器采样周期, 导致预测失去意义。

对于以上问题, 人工神经网络可以有针对性地解决:①人工神经网络不需要所有设施和节点的结构化数据, 从本质上说, 它只是一种数据分析和挖掘方式, 一些非线性的数学运算和数据处理, 它会不会去拟合机理模型中质量守恒和能量守恒方程无从知晓, 因为其中间的求解计算参数是一系列的权重和偏置, 可以认为是一个黑箱模型;②人工神经网络的应用分为训练和预测两步, 训练过程可能很长(取决于样本的大小、训练次数、隐藏层数量、激励函数、求导步长等), 但训练结果通过保存在实际应用时进行加载并预测, 所需时间通常较短, 可以满足实时性要求。因此, 有必要通过实际案例来探讨如何采

用人工神经网络建立城市排水系统黑箱模型,包括如何应用雨水管网实时监测数据,如何选择输入层、隐藏层、输出层,如何设置损失函数等。

1 试验区概况

选取镇江华润新村小区的雨水管网系统作为试验区,由 36 根雨水管道和 36 个检查井组成,雨水管道断面形状均为圆形,直径均为 400 mm, 小区面积约为 5.88 hm²。试验区通过 1 个出水口连接到市政管网,该出水口处设有液位计,可观测管网的液位变化,液位计的数据采样间隔为 5 min。试验区附近安装有一台雨量计,可采集逐分钟降雨数据。试验区雨水管网系统平面布置如图 1 所示。

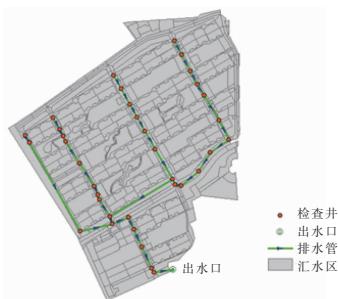


图 1 雨水管网系统示意

Fig. 1 Sketch diagram of storm sewer network

2 BP 神经网络结构

BP 神经网络是一种按误差逆传播算法训练的多层前馈网络,是应用最广泛的神经网络模型之一;学习规则使用最速下降法,通过反向传播不断调整网络的权值和阈值,使网络的误差平方和最小;由输入层、隐藏层和输出层组成,层与层之间采用全连接方式,同层之间不存在相互连接。图 2 为研究区雨水管网系统充满度预测用 BP 神经网络结构。

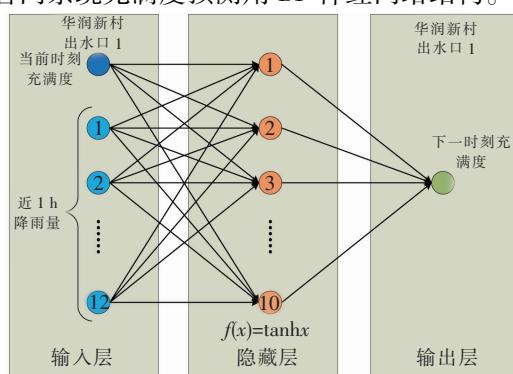


图 2 BP 神经网络结构

Fig. 2 BP neural network structure

① 输入层

雨水管网入流主要来自于降雨,因此输入层为降雨量时间序列和出水口上游管道的充满度,降雨量时间序列为 1 h,采样频率为 5 min,充满度由液位换算而得,其值等于实测液位减去管底标高再除以管道高度。选择充满度而非液位,原因为充满度是一个归一化指标,在训练中可以更快地收敛,缩短训练时间^[2]。

降雨量与出水口充满度的实测数据如图 3 所示。在旱季,管网充满度基本趋于零,而在降雨期间,管网出水口充满度增大,随着降雨量的减小,管网逐渐恢复排水能力,充满度逐渐减小。

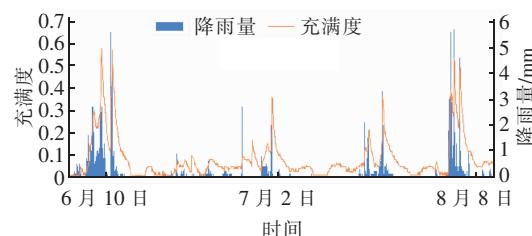


图 3 降雨量和出水口充满度的变化曲线

Fig. 3 Curves of rainfall and outlet capacity

模拟时间步长的选取应与管网规模以及管内流速相关,当管网规模较大或流速较慢时,应适当调大时间步数。过短的时间步长会导致无法体现降雨对下游管网充满度峰值的延后效应;过长的时间步长则会影响训练效率,距当前时间越久的降雨数据其影响效果也会越低,即权重值会越低。根据实测历史数据,试验区出水口充满度峰值时间相较于降雨量的峰值时间延迟 0.5 ~ 1 h,故选择 1 h 的降雨序列数据,频率为 5 min,即 12 个时间步长,加上本段管道充满度的当前状态,共 13 个输入自变量。

② 隐藏层

若隐藏层神经元数量较小,对网络识别样本及完成训练都不利,并且隐藏层神经元数量较小的神经网络的容错性也较低;若隐藏层神经元数量较多,网络训练过程中迭代次数将增加,训练时间延长,泛化能力降低,并且最终导致预测能力相对下降。参考经验公式 $m = \sqrt{n + o} + a^{[3]}$,其中, n 为输入自变量数 13, o 为输出自变量数 1, a 取值范围为 [1, 10]。根据公式算得 m 的取值范围为 [5, 14], 试验案例的隐藏层神经元数取 10。

③ 输出层

输出层为出水口下一时刻的充满度。

3 模型训练

基于 Google 第二代人工智能学习系统 TensorFlow 构建 BP 神经网络模型。TensorFlow 具有使用灵活、方便移植、效率高等优点^[4], 目前支持 C++ 和 Python 两种编程语言。考虑到 Python 语言的简洁性以及数据批处理上的优势, 故采用 Python 进行程序设计及模型训练与验证, 训练结果通过 TensorFlow 提供的图表工具——TensorBoard 进行可视化。

训练样本采用镇江 2017 年 6 月—8 月的 7 场降雨资料, 降雨日期分别为 6 月 10 日、6 月 19 日、7 月 2 日、7 月 9 日、7 月 10 日、7 月 29 日和 8 月 8 日, 实测降雨数据见表 1, 镇江 1 年一遇 2 h 的总降雨量为 29.5 mm, 峰值雨强为 73.9 mm/h。

表 1 训练降雨数据

Tab. 1 Training rainfall data

项目	总降雨量/mm	降雨历时/h	峰值雨强/(mm·h ⁻¹)
2017-06-10	117.05	12	67.2
2017-06-19	6.5	1	10.8
2017-07-02	32.5	5	32.4
2017-07-09	15	3	25.2
2017-07-10	26.8	4	39.6
2017-07-29	4.6	0.5	28.8
2017-08-08	90.6	9	68.4

以训练集中的某一条样本为例进行详细说明, 见表 2(注: 降雨量单位为 mm)。

表 2 样本说明

Tab. 2 Sample description

样本列名	时间	数值
时刻 1 降雨量	2017-07-02T00:00	0.2
时刻 2 降雨量	2017-07-02T00:05	0.3
时刻 3 降雨量	2017-07-02T00:10	0.1
时刻 4 降雨量	2017-07-02T00:15	0.4
时刻 5 降雨量	2017-07-02T00:20	0.5
时刻 6 降雨量	2017-07-02T00:25	0.3
时刻 7 降雨量	2017-07-02T00:30	0.2
时刻 8 降雨量	2017-07-02T00:35	0.2
时刻 9 降雨量	2017-07-02T00:40	0.2
时刻 10 降雨量	2017-07-02T00:45	0.1
时刻 11 降雨量	2017-07-02T00:50	0.1
时刻 12 降雨量	2017-07-02T00:55	0.2
当前时刻充满度	2017-07-02T00:55	0.165 0
下一时刻充满度	2017-07-02T01:00	0.157 5

通过输入上述 7 场降雨的时间序列以及当前时

刻的出水口上游管道充满度, 由 BP 神经网络预测下一时刻的充满度, 然后通过与实测值对比来进行模型训练和参数优化。选取均方误差(MSE)作为模型精度的评价指标, 即作为神经网络训练的损失函数。

均方误差 MSE 的计算公式如下^[5]:

$$MSE = \frac{1}{n} \sum_i [G(x_i) - y_i]^2 \quad (1)$$

式中: n 为样本数量; G 为预测模型, 根据矩阵 X 输出预测向量 $G(x)$ 。

设定训练次数为 5 000 次, 训练学习效率为 0.001, 训练方法为梯度下降法, 训练完成后通过 TensorBoard 输出结果如图 4 所示。可知, 均方误差 MSE 小于 0.000 1, 输出充满度预测精度可以达到均方根误差在 $0.01(\sqrt{0.000 1})$ 以内, 模型学习到了输入与输出之间的相关性。

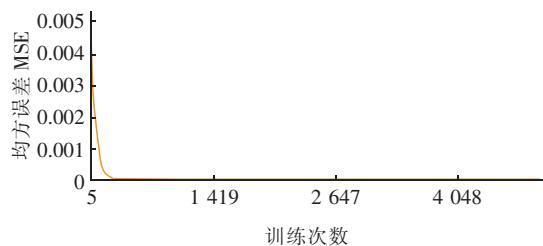
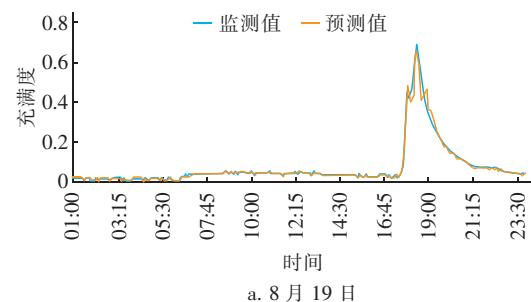


图 4 训练结果损失函数

Fig. 4 Loss function of training results

4 模型验证

选用 2017 年 8 月 19 日和 9 月 25 日的两场降雨进行模型验证, 其中, 8 月 19 日的总降雨量为 42.4 mm、历时 2 h、峰值雨强为 90 mm/h, 9 月 25 日的总降雨量为 84.5 mm、历时 9 h、峰值雨强为 60 mm/h。验证结果如图 5 所示。8 月 19 日和 9 月 25 日验证结果的均方误差分别为 0.000 2、0.000 5, 大于训练集的均方误差, 但可满足实际应用所需的精度要求。



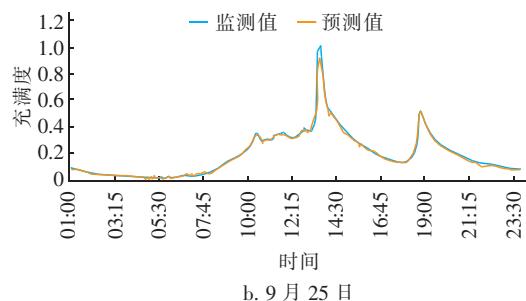


图 5 BP 神经网络模型验证结果

Fig. 5 Verification results of BP neural network model

5 结论与建议

通过建立 BP 神经网络进行雨水管网充满度预测,其输入与输出参数基于机理模型的圣维南方程组而设定,根据圣维南方程组中的连续性方程可以得出,流量与液位依赖于外部入流,并且当前时刻流量与液位的计算依赖于上一时刻的流量与液位。管网之间的传递性表明下游对外部入流有一定延迟性和记忆性,因此,需要将降雨数据以时间序列形式进行学习,以多个变量的方式进行输入。另外,根据机理模型来设计输入层与输出层,才能让神经网络进行更好的学习和训练,收敛到可以满足应用要求的精度。

通过该方法进行雨水管网充满度预测,可以达到实际应用的精度,但该方法有一定的适用范围:①训练与实际预测应用时,管网的运行工况需要保持不变,如管网发生新建、废弃、扩容等情况,需进行样本采集后重新训练;②该方法适用于纯雨水管网,不存在雨污合流情况,或发生雨污合流情况时污水入流有一定规律,当污水入流无规律时,则通过此方法预测会存在较大误差。

此外,该方法还存在优化空间,建议可以从以下几点开展下一步研究:①验证集均方误差大于训练集均方误差,这说明样本量偏小,可随着时间与实测数据的积累来增加训练集样本,通过调整隐藏层数量避免过拟合等方法进行优化。②基于输出对降雨时间序列的依赖关系,可尝试采用更优化的神经网络结构,如 LSTM 神经网络,通过对降雨数据以及上一状态进行记忆,以训练得到更好的预测模型。③损失函数 MSE 的优化替代,可选用在水文领域更为常用的纳什系数 NSE 作为训练标准来进行训练和

验证。

参考文献:

- [1] 黄清雨,董军刚,李梦雅,等. 暴雨内涝危险性情景模拟方法研究——以上海中心城区为例[J]. 地球信息科学学报,2016,18(4):506–513.
Huang Qingyu, Dong Jungang, Li Mengya, et al. Research on the scenario simulation method of rainstorm waterlogging hazard: A case study in the central urban area of Shanghai[J]. Journal of Geo-Information Science, 2016, 18(4):506–513 (in Chinese).
- [2] 高扬,卫峥. 白话深度学习与 TensorFlow[M]. 北京:机械工业出版社,2017.
Gao Yang, Wei Zheng. Deep Learning and TensorFlow [M]. Beijing: China Machine Press, 2017 (in Chinese).
- [3] 丁永生. 计算智能——理论、技术与应用[M]. 北京:科学出版社,2004.
Ding Yongsheng. Computational Intelligence: Theory, Technology and Applications [M]. Beijing: Science Press, 2004 (in Chinese).
- [4] Abadi M, Barham P, Chen J, et al. TensorFlow:a system for large-scale machine learning[A]. OSDI'16 Proceedings of the 12th USENIX Conference on Operating Systems Design and Implementation[C]. Savannah: USENIX Association Berkeley, 2016.
- [5] Downey A B. Think Stats[M]. New York:O'Reilly Media, 2011.



作者简介: 盛政(1981—),男,浙江湖州人,硕士,高工,研究方向为智慧水务。

E-mail:11639583@qq.com

收稿日期:2018-04-08