



DOI:10.13364/j.issn.1672-6510.20180167

## 基于径向基神经网络的污水管网堵塞诊断方法

刘文亮

(天津市排水管理处, 天津 300202)

**摘要:** 为了对城市污水管网堵塞故障进行准确诊断,提出了基于径向基神经网络的污水管网堵塞故障诊断方法.采用节点液位高度为输入变量,构造了径向基神经网络故障诊断模型.基于管网水力模型构造了故障训练集,应用于某典型环状管网故障训练与诊断,采用训练后的模型对 5 组数据进行故障识别,均准确预测定位了堵塞故障管段,验证了方法的有效性.

**关键词:** 污水管网; 径向基神经网络; 故障诊断; 堵塞

**中图分类号:** TU992.4      **文献标志码:** A      **文章编号:** 1672-6510(2019)04-0076-05

## Diagnosing Sewer Network Blocking Based on RBF Neural Network

LIU Wenliang

(Tianjin Drainage Management Office, Tianjin 300202, China)

**Abstract:** In order to diagnose blocking in city sewer network accurately and quickly, a blocking diagnosing model based on RBF neural network was proposed with the sewer level of network nodes as input parameters. A training set was obtained based on network hydraulic model which was applied to typical looped network blocking fault diagnosis and training. Five selected blocking fault cases were then diagnosed accurately, which validates the effectiveness of the proposed method.

**Key words:** sewer network; RBF neural network; fault diagnosis; blocking

污水管网是城市基础重要设施,长期运行、雨天水量增加等易导致管网堵塞、污水冒溢现象,造成城市安全隐患.污水管网系统是一个复杂的非线性、随机系统,污水在管网流动及污水水位受降水、污水流量负荷、管网流阻等多因素影响,有一定的流动规律,又表现出较强的波动性和随机性.对污水管网运行健康状态的监测,特别是污水管网堵塞故障及时准确定位具有重要意义<sup>[1]</sup>.

对管网上、下游节点流量进行监测,是确定污水管网是否堵塞的直接手段,如文献[2]报道:通过安装 37 台管道流量计,对 Costa do Estoril 截流系统进行了监测,需在污水管网中同步安装很多管道流量计,极其费时费力且成本高昂.对污水管网特征参数进行选点实测,再建立管网流动状态故障诊断模型,对管网运行状态进行分析预测,既可以节省实测设备前期投资以及后期维护的费用,又可以充分利用实测数

据,达到事半功倍的效果.污水井内水位是反映管网流通状态的重要参数,随着物联网技术成熟发展,基于无线数据传输的低功耗液位测量技术成为污水管网状态监测的新手段,具有低功耗无需直接供电、结构紧凑便于在井盖安装实施等显著优点,使得基于污水井液位并结合管网流量作为特征参数的污水管网流动建模成为可能.

现有的污水管网节点流量建模主要是确定性建模,然而,污水在管网中流动受多因素影响,直接确定性建模需要大量的水文资料,实测数据难以获得,且污水管网流程呈现较强的随机性,难以准确确定建模.对于不易建立精确数学模型、具有多种不确定性和非线性的系统,应用人工神经网络智能预测方法往往可以处理传统方法难以解决的问题,人工神经网络以其可学习的特性和其高度并行的结构所带来的容错性强、并行计算、便于用大规模并行实现等优点,

收稿日期: 2018-05-30; 修回日期: 2018-10-31

基金项目: 国家水体污染控制与治理科技重大专项资助项目(2015ZX07203-011)

作者简介: 刘文亮(1978—),男,天津人,高级工程师,liuwenliang1978@126.com

及其可逼近任意非线性函数的能力, 在供水系统管网压力预测、管网优化设计、管网泄漏预测、污染源追踪等方面, 人工神经网络都取得了有效应用<sup>[3-4]</sup>. 基于物联网技术的无线液位监测为神经网络训练提供大量有效数据, 使得基于人工神经网络的污水管网堵塞诊断成为可能, 目前尚未见到相关研究报道. 多层感知器是神经网络应用最广泛的一种, 但多层感知器采用的误差反向传播算法容易陷入局部最小值且需要较长训练时间, 径向基网络有与多层感知器相当的非线性映射能力, 径向基函数具有在微小局部范围内生效的非零响应的局部特性, 可以在学习过程中获得高效化. 径向基神经网络(RBF)学习过程中只需要调整隐含层径向基函数中的参数及隐含层到输出的连接权值, 训练速度快, 具有较高的效率, 且能够实现较高精度的预测.

本文以基于污水井液位结合部分特征管段流量为监测参数, 构建基于径向基神经网络的污水管网堵塞诊断方法, 并对方法的有效性进行验证.

## 1 模型构建

### 1.1 管网水力模型

污水管网典型结构包括树形结构和环状结构, 图1给出的是典型环状污水管网结构. 管网相邻节点间流动关系如图2所示,  $p_i$  为节点*i*的静压,  $\rho$  为污水密度,  $V_i$  为平均速度,  $h_i$  为污水井液位高度,  $H_i$  为污水井海拔高度(表征坡度),  $\Delta p_{i,i+1}$  为管段阻力损失, 节点间流动规律遵循不可压流动伯努利方程.

对于污水管网流动, 可采用节点分析法对流动规律进行求解, 对于具有  $n+1$  个节点/ $b$  根管段的管网, 无泵管段管网流动采用如下矩阵方程组描述<sup>[5-6]</sup>:

$$\begin{cases} \mathbf{FG} = \mathbf{Q} \\ \mathbf{BZ} = \mathbf{0} \\ \mathbf{Z} = \mathbf{Z}_w \end{cases} \quad (1)$$

式中:  $\mathbf{F}$  为  $n \times b$  基本关联矩阵, 其元素  $f_{ij}$  取值为:  $f_{ij} = 1$ , 节点*i*与管段*j*相连, 且流动方向为离开节点*i*;  $f_{ij} = -1$ , 节点*i*与管段*j*相连, 且流动方向为流向节点*i*;  $f_{ij} = 0$ , 节点*i*与管段*j*不相连.  $\mathbf{G}$  为  $b \times 1$  阶管段流量列向量, 每个元素代表对应管段流量.  $\mathbf{Q}$  为  $n \times 1$  阶节点流量列向量, 每个元素代表对应节点流量.  $\mathbf{B}$  为  $(b-n) \times b$  阶基本回路矩阵, 其内部元素对应边处于环路上且与环取向相同时, 元素取值为 1; 内

部元素对应边处于环路上且与环取向相反时, 元素取值为 -1; 不在环路上时, 元素取值为 0.  $\mathbf{Z}$  为  $b \times 1$  阶管段进出口压差列向量.  $\mathbf{0}$  为  $(b-n) \times 1$  的 0 向量.  $\mathbf{Z}_w$  为  $b \times 1$  阶管段阻力损失列向量. 对于污水管网流动, 管内污水流动阻力一般以沿程阻力为主, 局部阻力占比较小, 可根据海澄-威廉公式对管段阻力损失进行计算<sup>[5]</sup>. 该方程组共有  $2b+n$  个方程与  $2b+n$  个变量, 方程组封闭具有唯一解, 可以求得污水管网稳态下的节点及管段压力、液位高度、流量等流动特征参数.




图1 典型环状污水管网结构

Fig. 1 Schema of looped sewer network




图2 管网相邻节点流动关系

Fig. 2 Schema of two sewer network adjacent nodes

### 1.2 管网堵塞诊断模型

直接分析管网流动状态需要大量的水文资料、管网信息等, 往往难以准确获得, 使得准确求解流动状态存在较大困难. 管道堵塞会导致管段阻力损失变大, 进而引起液位变化, 同时液位变化受污水流量、降水、季节等多因素影响, 表现出较强的随机性和非确定性. 基于人工神经网络的智能诊断是解决该问题有效途径, 基于物联网技术的无线液位监测可为神经网络训练提供大量有效数据, 可通过自主学习提高诊断的准确性.

径向基神经网络具有良好的模式分类能力,它是一个三层前向网络,对于具有  $n+1$  个节点,  $b$  根管段的管网、第一层为输入层,输入层变量为  $n+1$  个节点液位高度  $h_1, \dots, h_{n+1}$ ; 第二层为隐含层,第三层为输出层,输出层为  $b$  个管段是否堵塞的诊断结果  $y_1, \dots, y_b$ , 网络结构如图 3 所示.  $\Omega$  为输出权矩阵,即  $\Omega = (\omega_{ij})_{N \times b}$  ( $i=1, \dots, N$ ;  $j=1, \dots, b$ ),  $\omega_{ij}$  为隐含层第  $i$  个节点与输出层第  $j$  个节点之间的输出权值.  $\Phi_i$  ( $i=1, \dots, N$ ) 为基函数,即隐节点的激活函数,一般采用 Gauss 函数,即

$$\Phi(r) = e^{-r^2/2\delta^2} \quad (2)$$

式中:  $\delta$  为扩展常数.




图 3 广义径向基神经网络结构

Fig. 3 Generalized radial basis neural network structure

隐含层基函数中心可通过随机选取固定中心和自组织选取中心确定. 本文采用 K-means 自组织聚类方法<sup>[7]</sup>选取隐含层神经元径向基函数的数据中心,按照各个数据中心之间的欧几里德距离计算隐含层神经元的扩展常数;采用监督学习算法修正输出层权值,利用梯度法对权值进行调整. 将第  $k$  次迭代的数据中心用  $c(k)$  标识 K-means 聚类算法步骤如下:

(1) 选择  $N$  个不同向量作为对初始聚类中心  $c_i(0)$  ( $i=1, \dots, N$ ), 赋小随机数作为初始值;

(2) 计算输入样本与聚类中心的欧几里德距离

$$\|h_i - c_j(k)\| \quad (i=1, \dots, n+1; j=1, \dots, N)$$

(3) 进行相似性匹配,  $j^l$  代表竞争获胜神经元, 满足

$$j^l = \min_c \|h_i - c_j(k)\| \quad (i=1, \dots, n+1)$$

时,  $h_i$  就属于  $j^l$  类, 把全部样本划分为  $N$  个子集:  $U_1(k), U_2(k), \dots, U_N(k)$ , 子集构成典型聚类域;

(4) 采用各聚类域样本平均方法更新聚类中心,  $U_j(k)$  代表第  $j$  个聚类域,  $N_j$  代表第  $j$  个聚类域样本数, 则

$$c_j(k+1) = \frac{1}{N_j} \sum_{h \in U_j(k)} h$$

(5) 重复步骤(2), 直至  $c(k)$  变化量小于规定值.

确定聚类中心后, 即可确定扩展常数  $\delta$ , 采用基于 LMS 算法<sup>[8]</sup>, 由监督学习调整输出层权值, 目标是使得实际输出与期望输出之间的均方误差 (误差容限) 最小,  $e_i$  为第  $i$  个训练样本所得结果与期望结果之间的误差. 通过学习常数  $\eta$  调整学习速率<sup>[8]</sup>.

$$E = \frac{1}{2} \sum_{i=1}^P e_i^2 \quad (3)$$

基于径向基神经网络的污水管网堵塞诊断流程如图 4 所示, 训练数据可通过经过实测数据修正的水力模型计算构建和基于液位与堵塞故障长期监测积累大数据进行构建. 对输入数据进行归一化处理, 避免不同数据差异过大.

$$\bar{h}_i = \frac{h_i - h_{\min}}{h_{\max} - h_{\min}} \quad (4)$$

式中:  $h_{\max}$  和  $h_{\min}$  为输入数据集最大值与最小值;  $h_i$  为数据原始值;  $\bar{h}_i$  为归一化值.

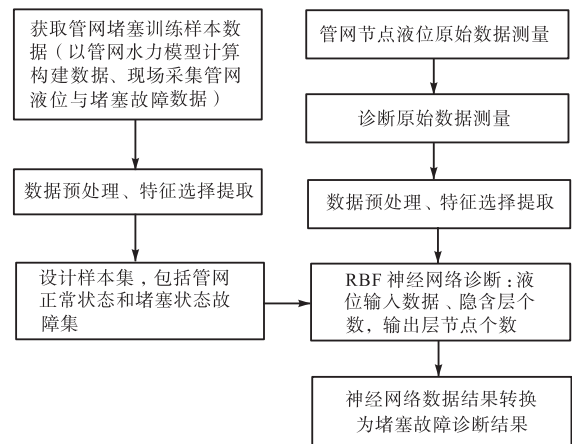


图 4 基于径向基神经网络的污水管网堵塞诊断流程

Fig. 4 Blocking fault diagnosis procedure for sewer network based on RBF neural network

## 2 案例分析

为验证方法的有效性, 构建训练集和样本集进行检验. 以图 1 所示的管网为例, 共包括 9 个节点, 11 个管段, 输入变量为 9 个节点的液位高度, 即  $h_1, \dots, h_9$ , 输出变量即为故障类型, 见表 1.  $y_0 \sim y_{11}$  的变化范围为 0~1, 无堵塞管网正常状态,  $y_0$  期望为 1.  $y_1 \sim y_{11}$  为表中对应管段对应故障状态, “0”表示没有堵塞, “1”表示严重堵塞.

表1 故障期望输出

Tab. 1 Failure expectation output

代号	故障	正常期望输出	堵塞故障期望输出
$y_0$	正常状态	1	0
$y_1$	<1-2>	0	1
$y_2$	<1-3>	0	1
$y_3$	<2-4>	0	1
$y_4$	<3-4>	0	1
$y_5$	<3-5>	0	1
$y_6$	<4-6>	0	1
$y_7$	<5-6>	0	1
$y_8$	<6-7>	0	1
$y_9$	<7-8>	0	1
$y_{10}$	<7-9>	0	1
$y_{11}$	<8-9>	0	1

基于前节给出了管网水力模型, 在给定入口流量、管网特征尺寸、坡度等信息条件下, 可直接获得各节点液位高度. 先计算出给定入口流量正常状态下的液位高度  $h_1, \dots, h_9$ , 改变某一管段海澄-威廉系数, 增加该管段阻力损失模拟堵塞状态, 获得该管段堵塞状态对应的管网各节点液位高度  $h_1, \dots, h_9$ , 这样可以构造出大量的训练样本集. 实际工程应用中, 也可基于液位高度与堵塞故障积累数据作为训练样本集, 增强方法应用的针对性.

根据管网水力计算模型并通过二维插值构造 200 个正常工况和故障工况样本集, 典型示例见表 2.

表2 故障训练样本集(部分)

Tab. 2 Failure training samples (part)

序号	液位高度/m										故障名称
	$h_1$	$h_2$	$h_3$	$h_4$	$h_5$	$h_6$	$h_7$	$h_8$	$h_9$		
1	0.51	0.34	0.85	0.71	1.27	0.88	0.92	0.50	1.40	正常状态	
2	0.82	1.10	0.98	0.31	1.39	0.76	0.81	0.48	1.20	$y_3 = 1$	
3	1.11	1.22	1.07	1.50	1.44	0.27	0.78	0.46	0.87	$y_3 = 1$	

选取前 195 个作为训练集, 后 5 个作为检验集进行方法验证. 根据已经设计好的故障集, 利用 Matlab R2016 编写神经网络故障诊断程序, 可以得到故障诊断结果. 通过设置不同神经元个数  $N$ , 进行学习训练, 系统训练误差曲线随神经元个数变化如图 5 所示, 随着神经元个数增加误差逐渐降低, 神经元数量为 120 个时, 误差可达  $1 \times 10^{-9}$  量级.

经水力模型构造的训练样本集学习后, 选择 5 组数据进行堵塞故障定位检验, 故障诊断结果见表 3. 对 5 组数据均进行了准确识别, 故障诊断结果表明, 基于径向基神经网络可以很好地对污水管网堵塞故

障模式进行识别.




图5 训练误差随神经元数量的变化

Fig. 5 Training error variants with the number of neurons

表3 污水管网堵塞故障诊断结果

Tab. 3 Blocking fault diagnosis results for sewer network

序号	径向基神经网络输出结果												诊断结果	实际故障
	$y_0$	$y_1$	$y_2$	$y_3$	$y_4$	$y_5$	$y_6$	$y_7$	$y_8$	$y_9$	$y_{10}$	$y_{11}$		
1	0.416	0.456	0.029	<u>0.989</u>	0.458	0.150	0.100	0.091	0.440	0.476	0.176	0.116	<2-4> 堵塞	<2-4> 堵塞
2	0.097	0.450	0.227	0.211	0.055	0.250	0.121	0.044	0.228	0.288	0.474	<u>0.917</u>	<8-9> 堵塞	<8-9> 堵塞
3	0.187	0.023	0.480	0.280	0.062	<u>0.994</u>	0.385	0.293	0.156	0.252	0.550	0.387	<3-5> 堵塞	<3-5> 堵塞
4	0.136	0.597	0.511	0.593	<u>0.988</u>	0.530	0.361	0.097	0.331	0.773	0.014	0.736	<3-4> 堵塞	<3-4> 堵塞
5	0.144	<u>0.995</u>	0.275	0.284	0.649	0.391	0.158	0.251	0.052	0.034	0.164	0.444	<1-2> 堵塞	<1-2> 堵塞

### 3 结论

城市污水管网系统是一个复杂的多变量非线性

系统, 采用传统的预测方法要得到精确的堵塞预测模型并不容易, 故障诊断及预测精确程度难以保证. 本文提出基于径向基神经网络的污水管网堵塞故障诊断方法, 建立了基于神经网络的管网预测模型, 以管

网水力分析模型构造了故障诊断训练集,以节点液位为输入变量,经训练的神经网络模型能够准确识别堵塞管段位置,方法有效.从预测过程和结果分析,基于径向基神经网络污水管网堵塞故障诊断方法操作简单,运行速度快,具有自学习能力.进一步研究时,可构建基于现场液位实测数据训练的污水管网堵塞诊断神经网络模型,推广应用于工程实际.

#### 参考文献:

- [1] 孙红卫. 浅谈我国污水管网建设运营改革之路[J]. 给水排水, 2010, 36(z1): 373-375.
- [2] Almeida M C, Brito R S. System diagnostics using flow data: Quantifying sources and opportunities for performance improvement[C]//Proceedings of the 9th International Conference on Urban Drainage. Portland: American Society of Civil Engineers. 2002: 1-13.

- [3] 常田, 刘书明, 王敏, 等. 基于 BP 神经网络的城市供水管网健康状态评估[J]. 给水排水, 2016(6): 138-141.
- [4] 陆健, 陈卫, 吴志成. 基于 BP 神经网络的供水管网分时段宏观模型研究[J]. 中国给水排水, 2007, 23(3): 99-101.
- [5] 严熙世, 刘遂庆. 给水排水管网系统[M]. 北京: 中国建筑工业出版社, 2002.
- [6] 赵洪宾. 给水管网系统理论与分析[M]. 北京: 中国建筑工业出版社, 2003.
- [7] Kang D, Lansley K. Real-time demand estimation and confidence limit analysis for water distribution systems[J]. Journal of Hydraulic Engineering, 2009, 135(10): 825-837.
- [8] 苏小红, 侯秋香, 马培军, 等. 强神经网络的混合学习算法[J]. 哈尔滨工业大学学报, 2006, 38(9): 132-136.

责任编辑: 常涛, 周建军

(上接第 75 页)

号源激励扬声器, 获取扬声器的时域响应信号, 根据时间关系确定响应信号波形上的最大幅值点所对应的频率, 便可得到对扬声器的谐振频率. 实验表明, 谐振频率检测系统的误差在 12 Hz 以内, 检测系统可以快速准确地测定扬声器的谐振频率.

#### 参考文献:

- [1] 韩捷, 张坡, 尤国雷. 国家标准《扬声器主要性能测试方法》解读[J]. 电声技术, 2012, 36(11): 86-90.
- [2] 沈金颖. 扬声器音质检测系统概述[J]. 西部广播电视, 2013(5): 109-112.
- [3] 朱德铭, 邝永辉, 艾晓晓. 电动式扬声器阻抗曲线分析与测量[J]. 电声技术, 2015, 39(6): 15-19.
- [4] 袁振才. 扬声器阻抗曲线及其应用[J]. 电声技术, 2013, 37(6): 17-21.
- [5] 邓巧玲. PULSE: 多分析仪系统 B&K3560[J]. 日用电

- 器, 1998(1): 44.
- [6] 朱德寿. 基于 PULSE 系统的声级计自动检定测试系统[J]. 电声技术, 2006(9): 67-69.
- [7] Klippel W. Assessment of voice-coil peak displacement X<sub>max</sub>[J]. Journal of the Audio Engineering Society, 2003, 51(5): 307-324.
- [8] Klippel W. Nonlinear large-signal behavior of electrodynamic loudspeakers at low frequencies[J]. Journal of the Audio Engineering Society, 1992, 40(6): 483-496.
- [9] 龙帆, 钱利民, 李迎春. 基于 LabVIEW 和声卡的扬声器检测系统的设计和实现[J]. 微计算机信息, 2006, 22(7-1): 90-92.
- [10] 李佳. 扬声器谐振频率测量系统的开发[D]. 苏州: 苏州大学, 2012.
- [11] 孟涂. 扬声器产品三参数集成测量系统的研究[D]. 天津: 天津科技大学, 2017.

责任编辑: 常涛, 周建军