

供排水企业运行及管理成果专栏

潘铁津, 解斌, 朱汉斌, 等. 基于 CCTV 和 XGBoost 的管道缺陷评估及预测[J]. 净水技术, 2026, 45(4): 181-188, 195.

Pan T J, Xie B, Zhu H B, et al. Pipeline defect assessment and prediction based on CCTV and XGBoost[J]. Water Purification Technology, 2026, 45(4): 181-188, 195.

基于 CCTV 和 XGBoost 的管道缺陷评估及预测

潘铁津^{1,*}, 解斌¹, 朱汉斌², 黄俊², 余亚莉¹

(1. 深圳市光明区环境水务有限公司, 广东深圳 518000; 2. 上海慧水科技有限公司, 上海 200090)

摘要 【目的】排水管道系统作为城市的“静脉血管”, 其健康状况直接关系到城市的安全运行与可持续发展。针对管网隐蔽性强、运行环境复杂导致检测困难的问题, 本文旨在构建一套科学合理的管网健康评估模式, 并利用机器学习技术预测未检测管道的健康状况, 为排水管道的智能化管理与安全运维提供理论依据和可靠工具。【方法】以南方某城市近 5 年的闭路电视 (CCTV) 检测数据为基础, 选取管道结构性缺陷作为核心评价因子, 并充分考量缺陷随时间演化的恶化趋势, 综合评估管网健康程度。同时, 引入极端梯度提升 (XGBoost) 机器学习算法, 深入挖掘结构性缺陷与管道属性 (如材质、管径、埋深等) 之间的非线性关联, 建立预测模型, 对尚未开展 CCTV 检测的管道健康状态进行推演。【结果】本文成功构建了包含时间维度的管网健康综合评估体系, 实现了对现有检测数据的量化评价。基于 XGBoost 模型的关联性分析揭示了影响管道健康的关键特征因子, 本模型能够有效利用已知数据对未知管道的结构性缺陷风险进行高精度预测, 显著扩展了评估覆盖范围。【结论】本文提出的健康评估模式与预测方法, 不仅为排水管道的安全运行提供了科学的评估工具, 还实现了从“被动检测”向“主动预测”的转变。本文成果为城市排水系统的精细化管理和基础设施的可持续发展提供了坚实的数据支撑与实际指导意义。

关键词 闭路电视 (CCTV) 管道缺陷 风险评估 极端梯度提升 (XGBoost) 风险预测

中图分类号: TU992 文献标志码: A 文章编号: 1009-0177(2026)04-0181-09

DOI: 10.15890/j.cnki.jsjs.2026.04.021

Pipeline Defect Assessment and Prediction Based on CCTV and XGBoost

Pan Tiejin^{1,*}, Xie Bin¹, Zhu Hanbin², Huang Jun², Yu Yali¹

(1. Shenzhen Guangming District Environmental Water Co., Ltd., Shenzhen 518000, China;

2. Shanghai Huishui Technology Co., Ltd., Shanghai 200090, China)

Abstract [Objective] As the "venous blood vessels" of a city, the health of the drainage pipeline system is crucial to urban safety and sustainable development. Addressing the challenges of strong concealment of pipe networks and complex operating environments, this paper aims to construct a scientific health assessment model and utilize machine learning to predict the health status of uninspected pipelines, providing reliable tools for intelligent management. [Methods] Based on five years of closed-circuit television (CCTV) inspection data from a southern city, structural defects were selected as the core evaluation factor, incorporating the potential deterioration over time to comprehensively assess pipeline health. Furthermore, the extreme gradient boosting (XGBoost) algorithm was employed to mine correlations between structural defects and pipeline attributes, establishing a prediction model for pipelines without CCTV data. [Results] A comprehensive health assessment system incorporating temporal dimensions was successfully constructed. The XGBoost-based analysis identified key factors influencing pipeline health, enabling high-precision prediction of structural defect risks in uninspected pipelines, thereby significantly expanding the assessment coverage. [Conclusion] The proposed assessment model and prediction method provide a scientific tool for safe pipeline operation, facilitating a shift from "passive detection" to "active prediction". These findings offer solid data support and practical guidance for the refined management of urban drainage systems and

[收稿日期] 2024-04-14

[通信作者] 潘铁津 (1990—), 男, 工程师, 主要从事流域水环境治理、市政给水管网运维、市政雨污水管网运维、城市防洪排涝治理、智慧水务等工作, E-mail: 13510603726@163.com。

the sustainable development of infrastructure.

Keywords closed-circuit television (CCTV) pipeline defect risk assessment extreme gradient boosting (XGBoost) risk prediction

排水管网作为城市的重要基础设施,承担着安全输送雨污水的责任,保障着城市的健康和安全^[1-2]。根据《中国城市建设统计年鉴数据》(2023),2023 年全国城市排水管道长度已达 95.25 万 km。然而,由于管道的隐蔽性和运行环境的复杂度,易出现安全隐患而又不易被察觉,包括管道老化、腐蚀、淤积等问题^[3-4],因此,通常采用管道闭路电视(CCTV)检测方式来进行检测。通过检测,可以有效识别管道的结构性缺陷(错位,变形和破裂等)和功能性缺陷(沉积、障碍物和结垢等)^[5]。同时,也已出台相关规范和标准来指导如何开展后续的管道修复和养护工作。但上述方式只是对管道的当前状态做了定义,未能对管道的健康风险(例如考虑恶化情况)进行评估和预测,存在一定的不足。

针对管道的健康风险预测,国内外已有相关研究。徐得潜等^[6]采用排水管网的地理信息系统(GIS)数据,运用层次分析法确定污水管道各风险因素的权重,并借助灰色关联度法构建了管网健康风险评估模型。李晓峰^[7]基于贝叶斯理论从管径、管材、管龄、接口方式、覆土深度等 8 个指标构建污水管道的风险预测模型,对苏州市某城镇污水管网进行预测,预测效果良好。Alsaqqar 等^[8]采用神经网络劣化模型对巴格达市污水管道的劣化因素进行

拟合分析,预测精度达到 80%。然而,在这些研究中存在一些潜在的局限性,例如层次分析法受主观影响较大,建立的模型难以移植;李晓峰^[7]的风险预测并未基于通用的标准体系,难以复用;Alsaqqar 等^[8]预测了管道劣化的概率,但未直接预测管网的缺陷等级。综上,目前尚未有基于标准体系的适用性广、可操作性强的排水管道健康度评估模型。

S 市 G 区计划花费 5 年时间完成所有排水管道的 CCTV 检测工作,到目前为止已完成 60%,存储了大量的管道缺陷数据。本文以管网健康运营为目标,结合 CCTV 检测成果,归纳 S 市 G 区的排水管网缺陷特征,形成一套基于管道恶化概率的风险评估方法。另外,利用极端梯度提升(XGBoost)机器学习方法,研究结构性缺陷与管道特性之间的关联性,基于此预测出未检测管道的结构风险。

1 基于 CCTV 的管道缺陷风险评估

1.1 排水管道缺陷分布

S 市 G 区已完成 CCTV 检测的管道总长为 1 260 km,有缺陷的管道占比为 30%。其中,57%为结构性缺陷,43%为功能性缺陷。错口、变形和破裂,占有结构性缺陷的 66%,沉积、障碍物和结垢,占有功能性缺陷的 87%。缺陷类型分布情况如图 1 所示。




图 1 缺陷类型分布情况

Fig. 1 Distribution of Defect Types

《城镇排水管道检测与评估技术规程》(CJJ 181—2012)中提到,针对结构性缺陷和功能性缺陷,分别计算出一个关键指标,即修复指数(RI)和养护指数(MI),来定义管道的健康风险,同时给出

了相关运维建议。指标计算如式(1)、式(2)。

$$R_1 = 0.7F + 0.1K + 0.05E + 0.15T \quad (1)$$

$$M_1 = 0.8G + 0.15K + 0.05E \quad (2)$$

其中: R_1 ——RI 值;

M_1 ——MI 值;
 F ——管道结构性缺陷参数;
 K ——地区重要性参数;
 E ——管道重要性参数;

T ——土质影响参数;
 G ——管道功能性缺陷参数,且取值均在 0~10。
 R_1 和 M_1 的分级和修复建议如表 1 所示。

表 1 R_1 、 M_1 的分级和修复建议

Tab. 1 Classification and Repair Recommendations for R_1 and M_1

等级	R_1	修复建议及说明	M_1	养护建议及说明
I	$R_1 \leq 1$	结构条件基本完好,不修复	$M_1 \leq 1$	没有明显需要处理的缺陷
II	$1 < R_1 \leq 4$	结构在短期内不会发生破坏现象	$1 < M_1 \leq 4$	没有立即进行处理的必要,但宜安排处理计划
III	$4 < R_1 \leq 7$	结构在短期内可能会发生破坏,应尽快修复	$4 < M_1 \leq 7$	根据基础数据进行全面考虑,应尽快进行处理
IV	$R_1 > 7$	结构已经发生或即将发生破坏,应立即修复	$M_1 > 7$	输水功能受到严重影响,应立即进行处理

S 市 G 区中 CCTV 管道的 R_1 、 M_1 分布如图 2 所示, R_1 大于 4 的管道占总管道的 7%,应尽快修复,以保

障雨污水的安全输送; M_1 大于 4 的管道占总管道的 5%,应尽快疏通,防止输水能力不足导致雨季内涝。




图 2 CCTV 管道的 R_1 、 M_1 分布

Fig. 2 Distribution of R_1 and M_1 in CCTV Pipelines

1.2 排水管道缺陷风险评估

利用数理统计方法,通过对大量缺陷数据的分析,发现管道结构性缺陷 F 均值同部分管道属性存在较为明显的关联性,能在一定程度上表征对缺陷恶化的影响^[9]。因此,在 R_1 的基础上,引入缺陷恶化的可能性,从而制定出一种新的健康风险评估方法。

1.2.1 F 均值同管道属性之间的关联性

通过分析 F 均值在各种属性中的分布情况,寻找出高 F 均值管道显现的属性特征。为了避免引入不必要的噪声,剔除了 F 为 0 的样本。依次分析不同管长、管径、管材、埋深、系统类别、市政小区分类和坡度下, F 均值的分布,结果如图 3 所示。

各属性下的 F 均值分布如表 2 所示,不同管长、管径、管材、埋深以及管道类别下的 F 均值有一定的倾向性。另外, M_1 作为评估管道输水能力的重要参数,是一个可靠的指标,而且输水能力受阻也会影响管道结构性缺陷的持续恶化^[10]。最终,本文

中,选定管长、管径、管材、埋深、管道类别和 M_1 6 个指标,作为影响缺陷恶化的特征因子。同时,结合 F 均值的极差、相关学者研究成果以及水司运维人员分析决策,分配各特征因子的权重,最终计算出管道的特征因子总分。总分越高,表明缺陷恶化的可能性更大,计算如式(3)。

$$W = \sum_{i=1}^{i=\text{num}(A)} \alpha_i \times A_i \quad (3)$$

其中: W ——特征因子总分;

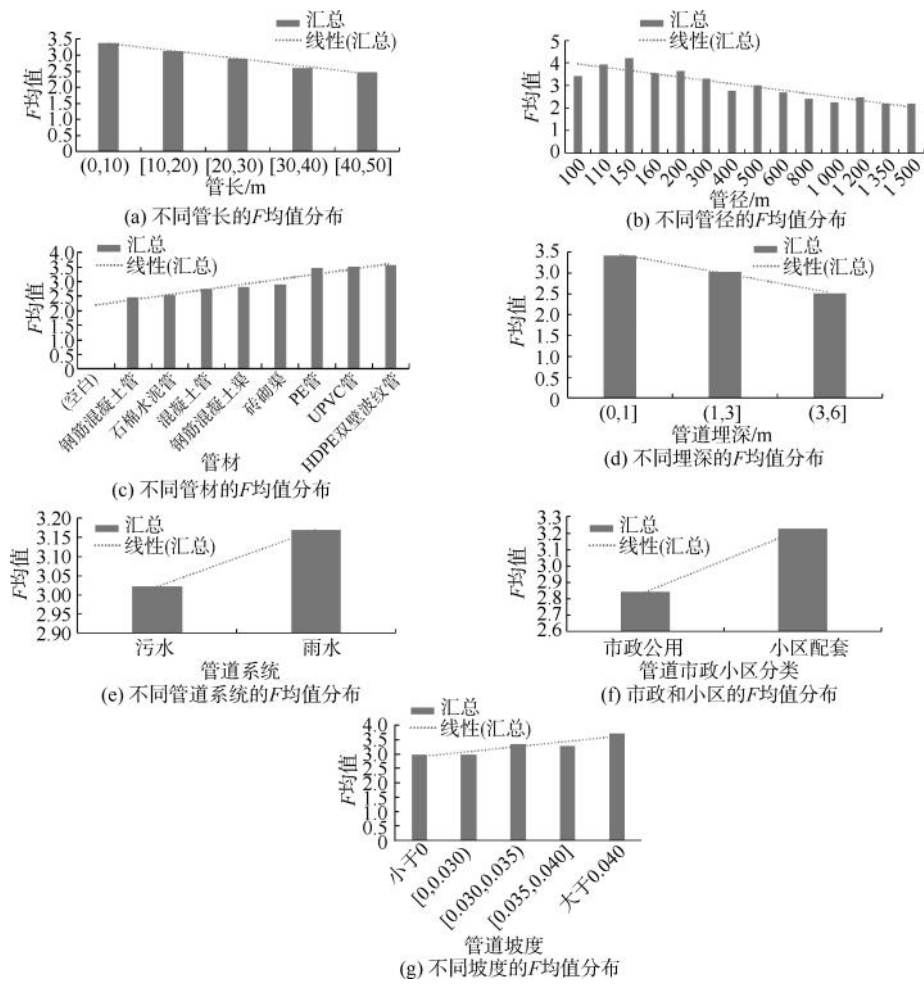
α_i ——第 i 个特征因子的权重;

A_i ——第 i 个特征因子的分值。

A ——特征因子。

各特征因子的赋分如表 3 所示,特征因子权重分布如表 4 所示。

本文中,1 260 km CCTV 检测管道的特征因子总分的分布如图 4 所示。其中总分小于 12.9 的占比为 47.40%,总分小于 13.2 的占比为 54.63%。基



注:PE 为聚乙烯,UPVC 为硬聚氯乙烯,HDPE 为高密度聚乙烯。

图 3 各属性下的 F 均值分布

Fig. 3 Distribution of F -Means across Different Attributes

表 2 各属性下的 F 均值分布统计

Tab. 2 Statistics of F -Means Distribution across Various Attributes

管道属性	描述	F 均值	F 均值的极差
管长	管长越小	F 均值越大	0.9
管径	管径越小	F 均值越大	2
管材	UPVC 管、HDPE 双壁波纹管、PE	F 均值偏大	1
	钢筋混凝土管、PE 双壁波纹管	F 均值偏小	1
	钢筋混凝土管、PE 双壁波纹管	F 均值偏小	1
埋深	埋深越小	F 均值越大	1
管道类别	市政/小区	小区 F 均值偏大(弱)	0.4
系统类别	污水/雨水	无明显关联	—
坡度	—	无明显关联	—

表 3 各特征因子的赋分

Tab. 3 Scoring for Each Feature Factor

属性	内容	分值 A
管径/mm	(0, 200]	4
	(200, 500]	3
	(500, 800]	2
	(800, +∞)	1
管长/m	(0, 10)	4
	[10, 20)	3
	[20, 30)	2
	[30, +∞)	1
管材	HDPE 双壁波纹管	4
	PE 管	4
	UPVC 管	4
	混凝土渠	3

(续表3)

属性	内容	分值 A
	砖砌渠	3
	钢筋混凝土渠	2
	混凝土管	2
	石棉水泥管	2
	其他	2
	钢筋混凝土管	1
埋深/m	(0,1]	4
	(1,3]	3
	(3,6]	2
	(6,+∞)	1
管道类别	小区	4
	市政	2
M_1	(9,10]	4
	(8,9]	3
	(6,8]	2
	(0,6]	1

表4 各特征因子的权重

Tab. 4 Weight for Each Feature Factor		
属性	权重	权重 α
管径	3	15%
管长	1	5%
管材	3	15%
埋深	2	10%
管道类别	1	5%
M_1	10	50%

于样本分布考量,本文认为总分排在前 50%的管道恶化概率较高,因此,特征因子总分大于等于 13.2 的管道,才会考虑将当前的 R_1 进行等级跃迁,计算如式(4)。

$$D = \begin{cases} \min(a \times R_1, 10) & (W \geq 13.2) \\ R_1 & (W < 13.2) \end{cases} \quad (4)$$

其中: D ——管道风险值;
 a ——放大系数。




图4 CCTV管道的特征因子总分分布

Fig. 4 Distribution of Total Scores for CCTV Pipeline Feature Factors

1.2.2 管道缺陷风险评估计算

本文中, D 值是对 R_1 的扩展,根据 R_1 的分级和修复建议制定了风险等级的划分和处置对策,具体如表5所示。

等级跃迁的管道数量,同后续运维工作的增加量有关,通过跃迁后,尽快修复管道数量将增加。本

文中,考虑工作量提升 10%,来计算 a 值。方法是对特征因子总分进行排序,不断提升 a 值,直到 R_1 等级跃迁的管道数量达到当前Ⅲ级和Ⅳ级管道总数的 10%,最终 a 取值为 2.11。新的健康风险评估方法下,管道的风险分布如图5所示。中风险+高风险的管道从之前的 7%,提升到 11%,增加了 8 090

表 5 各特征因子的权重
Tab. 5 Weight for Each Feature Factor

风险等级	D	风险状况	处置对策
高风险	[7,10]	严重不符合国家现行标准规范安全要求,管网存在普遍的病害与损坏现象,随时可能发生突发事件,直接影响系统安全和整体功能	应立即采取维修或改造更新措施,加强检测和监测频率
中风险	[4,7)	不符合国家现行标准规范安全要求,管网已发生严重的劣化或病害,有可能发生风险事件,影响系统安全和整体功能	1~2年内重点区域应采取维修或改造更新措施,定期检测和监测
低风险	[1,4)	符合国家现行标准规范的安全要求,少量管段存在结构安全隐患,基本处于系统安全、整体可靠状态	组织定期巡查维护,对重点区域管道可组织实施检测或监测
无风险	[0,1)	符合国家现行标准规范的安全要求,管段不存在结构安全隐患,处于系统安全、整体可靠状态	正常按计划巡查




图 5 CCTV 管道风险分布

Fig. 5 Distribution of CCTV Pipeline Risk

根管道的修复工作。

2 基于 XGBoost 的管道缺陷风险预测

CCTV 检测的周期较长且成本较高。当前待检测排水管道的选取较为主观,易造成检测资源浪费。如果在检测前,能够先对管道缺陷风险进行预测,那么检测工作将更具有针对性和计划性,从而能够有效降低运维成本。从长远来看,降低事故率所产生的费用能够抵消检测投资,研究^[11]表明,事后紧急抢修费用明显高于主动维护的费用,超一倍以上。本文选用 XGBoost 机器学习方法,通过构建管道的结构性缺陷风险预测框架,提前预测出可能存在的缺陷等级(针对未开展 CCTV 检测的管道),从而提高检测的效率,降低检测成本。

2.1 XGBoost 简介

XGBoost 是梯度提升框架下的一种集成学习算法。它的原理是通过迭代训练多个弱学习器(通常是决策树)来实现对目标函数的拟合,同时引入正则化项,提高了模型泛化能力^[12]。其在大规模数据集和复杂特征空间中表现出色,这使得它在管网健

康风险预测这类需要处理大量数据和复杂关系的问题上成为理想的选择,同时它还提供了直观的特征重要性和模型解释能力,方便决策者理解模型预测过程以及重要的决策因子。因此本文采用 XGBoost 模型搭建管网健康风险智能预测算法,以实现管网的风险预测。

2.2 数据预处理

在数据预处理过程中,为避免样本量分布不平衡所产生的负面影响,选择剔除各特征中样本量过少的小类别,只保留样本量充足的主要类别以构成最终模拟样本池。经筛选后,总计 73 269 根(原 80 133 根)管道数据样本用于建模分析。基于特征对管道状态和性能的潜在影响,并经过综合考虑和专业判断,选择管长、管径、管材、埋深、管道类别、坡度以及所属社区七大属性作为输入特征,选择 F 值作为模型的预测目标。另外,选择 80%的数据用于建立映射关系,20%的数据用于测试映射关系,以评估模型在新数据上的泛化能力,此分割方式有助于确保模型在真实环境中的稳健性和准确性。最后将各类别 F 的正确率和召回率作为评价指标。

(1)管径、管长、埋深、坡度数据归一化

使用 Min-Max Scaling 对输入参数中管径、管长、埋深、坡度这 4 列数据进行归一化,将不同特征之间的数值范围映射到相似的尺度上,以确保它们对模型的影响平等。

(2)管材、管道类别、所属社区数据编码

使用 pandas 库中的 get_dummies 方法对文本数据管材、管道类别、所属社区进行独热编码,将文本数据中每个类别转换为一个二进制特征,每个特征表示一个类别,实现文本转数字从而参与后续的机器学习模型。

2.3 模型评价

精准率和召回率计算分别如式(5)和式(6)。

$$N_{\text{precision}} = \frac{T_p}{T_p + F_p} \times 100\% \quad (5)$$

其中: $N_{\text{precision}}$ ——精准率;

T_p ——样本为正且预测为正的样本个数;

F_p ——样本为假但预测为正的样本个数。

$$N_{\text{recall}} = \frac{T_p}{T_p + F_N} \times 100\% \quad (6)$$

其中: N_{recall} ——召回率;

F_N ——样本为正但预测为假的样本个数。

2.4 基于 XGBoost 的多分类预测

管网运维决策需要对各风险等级管道有效识别与响应,理想的智能评估模型应当在保证整体判断准确性的同时,也关注对每类样本的预测性能。为此,本文在 XGBoost 模型构建中引入了网格搜索算法,以实现模型超参数的自动化优化,从而最优化模型性能。该算法可以在给定候选值范围内,遍历多个超参数组合,训练并验证不同模型,从中寻找最佳参数配置^[13]。本试验的搜索范围覆盖了学习率、树最大深度以及决策树数量 3 个维度。采用网格搜索算法对超参数进行优化,参数网格定义如下:(1)学习率为[0.01, 0.05, 0.1, 0.2];(2)树深度为[5, 6, 7];(3)模型决策树数量为[100, 200, 300, 400]。最终,当学习率为 0.01、树深度为 6、模型决策树数量为 200 时,获得了测试集误差最小的 XGBoost 分类模型。将优化后的模型对测试集进行测试,测试集的分布和预测结果分布如表 6 所示。

表 6 测试集样本分布

Tab. 6 Distribution of Testing Set Samples

F 值	测试集 F 占比	预测结果 F 分布
0	69.10%	98.94%
1	14.80%	1.00%
3	8.50%	0
6	4.50%	0.06%
10	3.10%	0

由表 6 可知,本文的管网健康评估样本集呈现出不同风险等级分布不均的特点。仅有 7.6% 的样

本为中高风险管道。由图 6 可知,模型在 F 为 0 的样本上预测结果良好,但在其余分类有较大不足。鉴于管网运维决策需要对各风险等级管道有效识别与响应,理想的智能评估模型应当在保证整体判断准确性的同时,也关注对每类样本的预测性能,但类别数据分布极度不均衡正在严重制约模型对少数中高风险样本的学习与泛化,区分无风险管道和低风险管道的可行性也较低。为实现较好的模型预测性能,本文选择将轻微风险($F \leq 3$)样本与无风险样本合并,构成新的主类别,而中高风险($F > 3$)则组合为新的中高风险类别,再增加样本重采样步骤,增大训练集中的少数类样本比例。这一重新分类和重采样的过程,等效地增加了关键少数类在数据集中所占的比例,同时多分类问题转变为二分类问题,有望增强模型对中高风险样本的学习特征与判断能力。




图 6 多分类预测结果评价

Fig. 6 Evaluation of Multi-Class Prediction Results

2.5 基于 XGBoost 的二分类预测

从管网安全管理的视角,识别 $F > 3$ 的中高风险管道样本尤其重要,这部分管道一旦发生事故,后果会更为严重。样本分布中,近 92% 的数据 $F \leq 3$,仅 7.6% 的数据 $F > 3$,为进一步提升模型对关键少数类样本的学习与判断能力,在样本数据层面,采用重采样策略对数据集进行预处理,由于欠采样会损失低风险样本数据,减少这一类别中的有效信息量,不利于模型对正常工作状态进行全面的判断^[14]。本文采用随机过采样提升少数类的占比,将 $F \leq 3$ 标记为 0, $F > 3$ 标记为 1,进行二分类预测。模型预测结果如图 7 所示。

在包含 14 654 条管道样本的数据测试集上,其中 92.4% 的样本为低风险状态($F \leq 3$),剩余 7.6% 为中高风险状态($F > 3$)。构建的 XGBoost 评估模型在该测试集上的预测结果显示,共有 11 310 条




图 7 二分类预测结果评价

Fig. 7 Evaluation of Two-Class Prediction Results

(77.18%)管道被判定为低风险,3 344 条(22.8%)被判定为高风险。对于低风险样本,模型判断正确率达到 94.6%,召回率为 20.9%。这意味着绝大多数的低风险管道状态可以得到较为可靠的预测。小比例但极为关键的高风险样本,模型判断正确率达到 15.0%,召回率为 45.1%。对于全样本中仅占比为 7.6%的高风险管道,能够实现 15.0%的正确率且召回率达到 45.1%,已属于较好的模型泛化性能。在实际应用中,可优先对预测出的高风险管道制定检测和修复计划,相较随机地毯式 CCTV,实现搜索高风险管道的效益翻倍。值得强调的是,在追求对关键少数高风险样本的最大可能捕捉时,数据的充分性和质量是至关重要的,提高模型的捕捉能力需要积累更多且具有代表性的记录数据。未来研究可继续增强模型对高风险管道的学习能力,以更全面地理解和预测潜在风险。

3 结论与展望

本文通过对南方 S 市 G 区排水管道近 5 年 CCTV 检测结果的深入分析,全面了解了现有管网的缺陷分布情况。通过数理统计方法,详细研究了结构性缺陷参数 F 与各管道属性之间的相关性,明确了管道风险特征因子,并成功构建了一套科学合理的管道健康风险评估公式,为管道安全运营提供了可靠的评估工具。另外,通过引入 XGBoost 机器学习方法,对未来开展 CCTV 检测的管道提前进行风险预测,将有助于提升后续管道检测的效率,也为未来城市排水系统的智能化管理奠定了坚实基础。

未来的研究方向可以集中在进一步优化预测模型,提高对高风险管道的学习能力,并通过更大规模的数据集验证和优化模型的泛化性能。同时,结合

实际操作,探索该模型在城市排水系统中的扩展应用,为城市基础设施的可持续发展和安全运行提供更多实际指导。本文的成果对于城市排水系统的管理和维护具有重要的实际意义,期待能够为相关领域的从业者和决策者提供有益的参考。

参考文献

- [1] 雷芳芳. CCTV 技术在福州市排水管道检测中的应用研究[J]. 给水排水, 2019, 55(S1): 275-276.
Lei F F. Research on the application of CCTV technology in Fuzhou drainage pipeline detection [J]. Water & Wastewater Engineering, 2019, 55(S1): 275-276.
- [2] 陆露,高峰,郭娟,等. 排水管网运维管理问题分析与对策研究[J]. 中国给水排水, 2022, 38(2): 8-13.
Lu L, Gao F, Guo J, et al. Problem analysis and countermeasure research for sewer operation and maintenance management [J]. China Water & Wastewater, 2022, 38(2): 8-13.
- [3] 陈俊宇. 排水管网病害分析及改造策略研究[J]. 给水排水, 2023, 59(9): 137-143.
Chen J Y. Drainage network disease analysis and reconstruction strategy research [J]. Water & Wastewater Engineering, 2023, 59(9): 137-143.
- [4] 刘艳海,李鸿,郭帅. 南、北方 3 个城市排水管道缺陷统计分布特征比较研究[J]. 合肥工业大学学报: 自然科学版, 2023, 46(7): 930-935.
Liu Y H, Li H, Guo S. Comparative study on statistical distribution characteristics of drainage pipeline defects in three southern and northern cities [J]. Journal of Hefei University of Technology: Natural Science, 2023, 46(7): 930-935.
- [5] 张学慧,刘存辉,宋国勇. 深圳市某片区缺陷管网分析与研究[J]. 水利规划与设计, 2023(8): 71-75, 126.
Zhang X H, Liu C H, Song G Y. Analysis and research on defective pipeline networks in a certain district of Shenzhen city [J]. Water Resources Planning and Design, 2023(8): 71-75, 126.
- [6] 徐得潜,张倩. 基于 AHP-GR 的合流制污水管道风险评估[J]. 安全与环境学报, 2019, 19(4): 1149-1154.
Xu D Q, Zhang Q. Risk assessment of combined sewer pipes based on AHP-GR [J]. Journal of Safety and Environment, 2019, 19(4): 1149-1154.
- [7] 李晓峰. 城镇污水管网健康状况评价与修复技术优选研究[D]. 苏州: 苏州科技大学, 2019.
Li X F. Study on the evaluation of the health status and optimization of repair technology of urban sewage pipe network [D]. Suzhou: Suzhou University of Science and Technology, 2019.

(下转第 195 页)

- [4] 杨宏, 朱晓辉, 张杰. KMnO_4 氧化 Mn^{2+} 产物 MnO_2 的作用机理研究[J]. 中国给水排水, 2006, 22(S1): 295-299.
Yang H, Zhu X H, Zhang J. Study on mechanism of MnO_2 produced from Mn^{2+} oxidization[J]. China Water & Wastewater, 2006, 22(S1): 295-299.
- [5] 李继震, 于文举, 王志军, 等. 曝气-石灰碱化法除铁除锰、降低水的硬度和溶解性总固体含量的研究[J]. 给水排水, 2000, 26(4): 12-13.
Li J Z, Yu W J, Wang Z J, et al. Fe-Mn removal and hardness-TSS reducing in water[J]. Water & Wastewater Engineering, 2000, 26(4): 12-13.
- [6] 马子川, 谢亚勃. $\text{Mn}(\text{OH})_2$ 空气氧化反应实验与产物表征[J]. 化学研究与应用, 2001, 13(4): 417-418.
Ma Z C, Xie Y B. Air-oxidation of $\text{Mn}(\text{OH})_2$ and characterization of the products[J]. Chemical Research and Application, 2001, 13(4): 417-418.
- [7] 程建国, 林永树, 阳华玲, 等. 石灰絮凝法去除矿坑废水中锰离子的研究[J]. 矿冶工程, 2012, 32(2): 45-48.
Cheng J G, Lin Y S, Yang H L, et al. Removal of Mn ions from mine wastewater by lime flocculation [J]. Mining and Metallurgical Engineering, 2012, 32(2): 45-48.
- [8] 樊玉川. 含锰废水处理研究[J]. 湖南有色金属, 1998, 14(3): 36-38.
Fan Y C. Study on the treatment of wastewater with manganese [J]. Hunan Nonferrous Metals, 1998, 14(3): 36-38.
- [9] 朱乐辉, 黄建, 孟祥超. 矿山高浓度酸性含锰废水处理的研究与工程实施[J]. 工业水处理, 2013, 33(4): 82-84.
Zhu L H, Huang J, Meng X C. Experimental research and engineering practice of the treatment of high-concentration acidic mining wastewater containing manganese [J]. Industrial Water Treatment, 2013, 33(4): 82-84.
- [10] 李一璇. 石灰在深圳梅林水厂污泥调质中的应用[J]. 给水排水, 2010, 46(11): 21-24.
Li Y X. Application of lime in sludge conditioning of Shenzhen Meilin Waterworks[J]. Water & Wastewater Engineering, 2010, 46(11): 21-24.

(上接第 188 页)

- [8] Alsaqqar A S, Khudair B H, Jbbar R K. Rigid trunk sewer deterioration prediction models using multiple discriminant and neural network models in Baghdad City, Iraq[J]. Journal of Engineering, 2023, 23(8): 70-83.
- [9] 邢雯雯. 基于 GA-BP 神经网络模型的排水管道系统健康状况评估[D]. 西安: 长安大学, 2021.
Xing W W. Research on the health assessment model of sewer system based on BP neural network [D]. Xi'an: Chang'an University, 2021.
- [10] 张文俊, 谢震方, 黎雷. 城市污水干管运行风险评估指标体系[J]. 净水技术, 2019, 38(6): 112-117, 121.
Zhang W J, Xie Z F, Li L. Assessment index system of operational risk for urban sewage mains[J]. Water Purification Technology, 2019, 38(6): 112-117, 121.
- [11] 周德敏, 何仁洋, 刘长征, 等. 关于埋地管道检验检测的必要性及建议[J]. 化工设备与管道, 2010, 47(6): 51-54, 63.
Zhou D M, He R Y, Liu C Z et al. On the necessity and suggestions for inspection and testing of buried pipelines [J]. Chemical Equipment and Piping, 2010, 47(6): 51-54, 63.
- [12] Chen T, Guestrin C. XGBoost: A scalable tree boosting system [J]. ACM, 2016. DOI:10.1145/2939672.2939785.
- [13] 孙丽丽, 方宏彬, 朱星星, 等. 基于网格搜索优化的 XGBoost 模型的股票预测[J]. 阜阳师范大学学报: 自然科学版, 2021, 38(2): 97-101.
Sun L L, Fang H B, Zhu X X, et al. Stock prediction using XGBoost model based on grid search optimization[J]. Journal of Fuyang Normal University: Natural Science, 2021, 38(2): 97-101.
- [14] 张美. 基于重采样和集成学习的不平衡数据分类与应用研究[D]. 昆明: 云南财经大学, 2023.
Zhang M. Research on classification and application of unbalanced data based on resampling and ensemble learning [D]. Kunming: Yunnan University of Finance and Economics, 2023.