doi: 10.11720/wtyht.2026.1417
宋洪伟, 夏凡, 李红超, 等. 物探技术结合机器学习方法在垃圾填埋场渗漏点调查中的研究[J]. 物探与化探, 2026, 50(2): 385-398. https://doi.org/10.11720/wtyht.2026.1417
Song H W, Xia F, Li H C, et al. Investigation of landfill leakage points using geophysical exploration and machine learning methods[J]. Geophysical and Geochemical Exploration, 2026, 50(2): 385-398. https://doi.org/10.11720/wtyht.2026.1417

物探技术结合机器学习方法在垃圾填埋场渗漏点调查中的研究

宋洪伟[1], 夏凡[2], 李红超[3], 杨超[4], 桂建业[1]
(1. 中国地质科学院水文地质环境地质研究所 自然资源部地下水科学与工程重点实验室, 河北 石家庄 050061; 2. 河北省生态环境科学研究院 河北省水环境科学实验室, 河北 石家庄 050031; 3. 河北省地质环境监测院, 河北 石家庄 050021; 4. 河北省地矿局 第五地质大队, 河北 唐山 063000)

摘 要: 垃圾填埋场中堆体的压缩沉降可能会致使生活垃圾处理场渗滤液收集管道的变形失效, 进而使得防渗层发生破裂, 垃圾渗滤液发生泄漏。监测渗滤液防渗层损伤的主要方法包括: 从填埋场采集水土样本、通过室内化学分析确定污染物含量和地面地球物理勘探工作。基于上述传统环境地质勘探方法, 本文采用地理信息系统(geographic information system,GIS)技术结合机器学习方法和影响因子预测法, 实现了对填埋场渗滤液泄漏的有效预测。首先, 以 5 m×5 m 的网格分辨率对填埋场区域进行网格划分, 并为每个网格单元分配对应位置坐标信息, 通过机器学习方法建立人工神经网络(artificial neural network,ANN)模型来预测填埋场渗漏点。基于对华北某填埋场的实地调查, 选取了 880 个测试样本和 220 个验证样本。将地下水深度、电阻率、极化率、雷达反射波形同相轴是否异常、同相轴与邻近监测孔位置的关系以及半衰期信息作为输入因子, 输出结果为各网格单元的渗漏概率。比较了 BP 神经网络和 RBF 神经网络两种机器学习方法的预测结果。结果表明: BP 神经网络模型具有较好的预测效果, 地下水位深度、电阻率及电阻率与监测孔位的关系对不透水膜渗流概率的预测影响最大。将每个影响因子的后验概率叠加, 得到了预测模型对渗漏风险区域等级划分图, 达到对填埋区的渗滤液渗漏风险分级监控的目的。

关键词: ANN; 电阻率; 填埋场; GIS; 渗滤液
中图分类号: P631.4; P31 **文献标识码**: A **文章编号**: 1000-8918(2026)02-0385-14

0 引言

近年来, 我国垃圾产生量及垃圾填埋量进入了高峰期。垃圾堆体的压缩沉降可能会致使生活垃圾处理场渗滤液收集管道的变形失效, 还会导致封顶系统中的防渗层发生破裂, 继而会使垃圾渗滤液发生渗漏, 有毒有害的渗滤液可能会通过废弃井、破损井管、引渗井等发生渗漏、地层尖灭形成的“天窗”, 进而引发水污染, 严重威胁地下饮用水安全[1-3]。填埋和焚烧是垃圾处理的主要方式。焚烧能实现有效减量和无害化处理, 但早些年垃圾填埋始终在垃圾处置方法体系中发挥着不可或缺的作用。虽然, 近些年垃圾处理场相继到达设计使用年限, 即将进行封场处理, 但垃圾渗滤液还在不断渗出, 垃圾填埋渗滤液浓度高、成分复杂、毒性大、处理难, 对周边地下水环境会造成威胁[4-7]。

传统的对垃圾填埋场的监测手段主要为现场水、土样采集, 通过室内化学分析测定污染物的含量, 而后进行环境污染评价。当前, 随着地球物理探测技术的不断发展, 综合物探方法在水文地质和环境地质监测领域得到广泛应用[8-10]。电阻率层析成像技术(electrical resistivity tomography, ERT)具有监测效率高、成本低、样本大、信息丰富、可以连续实

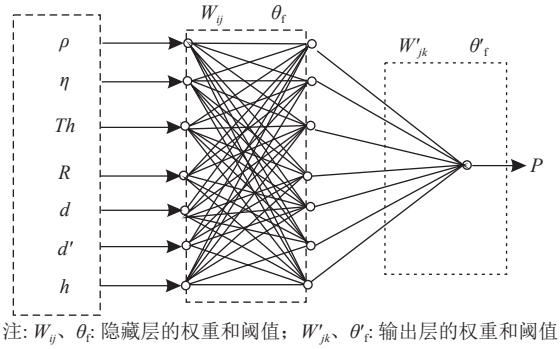
收稿日期: 2025-12-10; **修回日期**: 2026-01-22
基金项目: 国家自然科学基金项目(42277460); 深地国家科技重大专项课题(2024ZD1003300)
第一作者: 宋洪伟(1982-), 男, 硕士, 高级工程师, 从事水工环物探研究工作。Email: shw2180@163.com
通讯作者: 夏凡(1983-), 女, 硕士, 高级工程师, 从事地下水环境研究工作。Email: fanlevip2000@163.com

时动态监测地下水污染扩散趋势等优点[11-12]。利用电阻率层析成像技术的平行剖面网格,建立电阻率分布剖面和三维体积模型,可以更好地了解垃圾填埋场内部的防渗情况[13-14]。此外,ERT技术还广泛应用于考古、矿产勘探、环境污染调查、地下水勘探等工作[15-17]。但当ERT应用于污染调查时,特别是在地表附近区域,由于电阻率变化剧烈,容易产生严重失真。因此,ERT研究中地下电阻率变化的高分辨率信息,主要取决于数据质量、数据密度、电极配置及间距的选择[18]。而新兴的机器学习技术已经发展到可以很好地配合各领域专业技术在一些无法通过常规手段取得定量数据的工作中很好地完成了研究任务,如预测泉水的分布、估算水资源量、预测尾矿废水污染扩散渗漏概率[19-21]、预测矿产储量[22],如利用化学分析、多变量统计和GIS对灌溉土壤进行盐碱化风险评估[23];采用机器学习时间序列预测算法进行降雨量预测[24-25]。

通过机器学习建立的模型可有效地推广于风险防控工作中,本文将直流电法和探地雷达法获取的物性参数,以及调查所得的水文地质参数作为影响因子,建立ANN神经网络模型,将以上影响因子作为模型的输入神经元,利用GIS技术栅格化的场地中各个网格单元的渗漏风险等级作为输出神经元,对河北省某生活垃圾填埋场进行了有效的渗漏风险预测,划分了重点防控区域。

1　人工神经网络

人工神经网络(ANN)是一种复杂的网络系统,其通过大量简单神经元相互连接,模拟人脑进行信息处理,如图1所示。BP神经网络作为单向多层前馈网络,包含输入层、隐藏层(中间层)和输出层3个或更多层级。其核心原理是通过反向传播误差并同步修正参数,从而实现或近似目标输入—输出映射关系。因此,BP神经网络在事件概率预测中展现出良好的稳定性和时效性[26-27]。影响BP神经网络模型输出的主要因素包括以下几点:



注: W_{ij}、θ_f: 隐藏层的权重和阈值; W'_{jk}、θ'_f: 输出层的权重和阈值

图1　神经网络结构

Fig. 1　ANN model

①输入节点"ρ"、"n"、"Th"、"R"、"d"和"h"的物理意义(如连续/离散性质、维度一致性)直接影响模型表示原始数据的能力。②输入数据的质量:数据中的噪声、缺失值或异常值会通过权重传递放大误差,例如,"h"(高度)中的测量偏差可能会导致隐藏层神经元激活函数的输出偏离预期。③权重与阈值的定义:隐藏层连接权重 W_{ij} 决定了输入信号的传递强度;权重绝对值越大,表明对应输入变量对神经元输出的影响越显著,阈值 θ_f 控制神经元激活的难度(例如在Sigmoid函数中,过高的阈值可能导致神经元长期处于抑制状态)。④神经元数量和网络深度:隐藏层神经元的数量将直接影响模型的非线性拟合能力,数量太少可能导致欠拟合(无法捕捉复杂规律),太多可能导致过拟合(过度依赖训练数据噪声)。⑤输出层权重和阈值:输出层权重 W_{jk}' 和阈值 θ_f' 决定了隐藏层输出与最终结果"P"之间的映射关系,隐藏层和输出层使用的激活函数(如RELU、Sigmoid)会影响梯度传播的效率和输出范围。⑥优化算法和学习率:权重和阈值更新取决于优化器(如SGD、Adam)和学习率,过高学习率可能引起参数振荡,而过低的学习率会减慢收敛速度,最终影响模型收敛后的输出稳定性。⑦训练数据的规模和分布:训练样本的数量、类别平衡和特征相关性会影响参数学习的充分性。通过详细阐述这些因素,可以系统地解释图1中ANN模型输出"P"的不确定性来源,为模型优化提供明确的指导方向。

模型的基本功能是线性的,输出 $\boldsymbol{P}$ 是输入 $\boldsymbol{S}$ 与阈值 θ 的加权和。传递函数根据模型运行情况选择不同函数,隐藏层的最佳神经元数量通过多种循环选择方法确定。模型结构如图1所示:输入元素 $S_i(i=1,2,\cdots,7)$ 分别对应电阻率 ρ、极化率 η、半衰期 Th、雷达波形 R、上游监测井距离 d、下游监测井距离 d' 和地下水深度 h 的集合,输出 $\boldsymbol{P}$ 则对应泄漏概率 p。为避免局部最优解的影响,收集作为输入神经元的数据将根据需求进行归一化处理。

模型的输入和输出以矩阵形式如下所示:

$$\text{输入:}\ \boldsymbol{S}=\begin{bmatrix} S_{11} & \cdots & S_{1n} \\ S_{21} & \cdots & S_{2n} \\ S_{31} & \cdots & S_{3n} \\ S_{41} & \cdots & S_{4n} \\ S_{51} & \cdots & S_{5n} \\ S_{61} & \cdots & S_{6n} \\ S_{71} & \cdots & S_{7n} \end{bmatrix}, \qquad (1)$$

输出：$\boldsymbol{P}=[p_1 \quad p_2 \quad \cdots \quad p_n],(n=1,2,\cdots),$　　（2）

输入神经元矩阵 $\boldsymbol{S}$ 的每一列对应于输出神经元矩阵 $\boldsymbol{P}$ 的列 p(风险水平)。

2　研究区概况

研究区域位于河北省唐山市的一处生活垃圾填埋场，地形地貌受燕山构造运动和渤海湾海相沉积作用影响，形成了构造堆积层、冲积平原及滨海低洼平原，土壤分布随地形由山区向平原过渡呈现多样化特征。研究区地下水主要为第四系松散岩，根据地下水埋藏条件可分为浅层、中层和深层地下水，根据第四系沉积物的岩性及水文地质特征，自上而下可划分为 4 个含水层组(表 1)。

表 1　研究区含水层组信息

Table 1　Information list of aquifer groups in the study area

含水层组	底界面埋深/m	含水层岩性	渗透条件	单井涌水量/($m^3 \cdot d^{-1}$)	水化学条件	其他特点
第一层组	15～40	砂质黏土和黏质砂土	较差	300～600	双层结构，上咸下淡	研究区浅层以粉土为主，地下水为咸水
第二层组	120～170	薄层细砂、粉砂	弱	—	—	海积层约占1/3～1/4
第三层组	250～350	细砂、粉砂	较差	1 200～2 400 局部小于600	—	—
第四层组	350～550	中细砂、细砂	较弱	600～1 200	—	厚层黏土与粉质黏土

研究区位于河北省东部沿海平原，土壤类型以滨海盐土为主，地形 EN 高、WS 低，地势坡度约 1/8 000~1/12 000。研究区填埋场概况见图 2。

图 3 为研究区填埋场平面示意。如图 3 所示，区域地下水位高程范围在 0～−2.0 m 之间，地下水流向为 EN 向 WS。填埋场采用水平和垂直组合衬垫系统进行围堵，主要结构如下：

1)底部水平防渗结构层次及材料：聚丙烯编织布(反滤层)、碎石层(渗滤液导流层)、短纤无纺土工布、光面 HDPE 膜、长纤无纺土工布、粗砂层(地

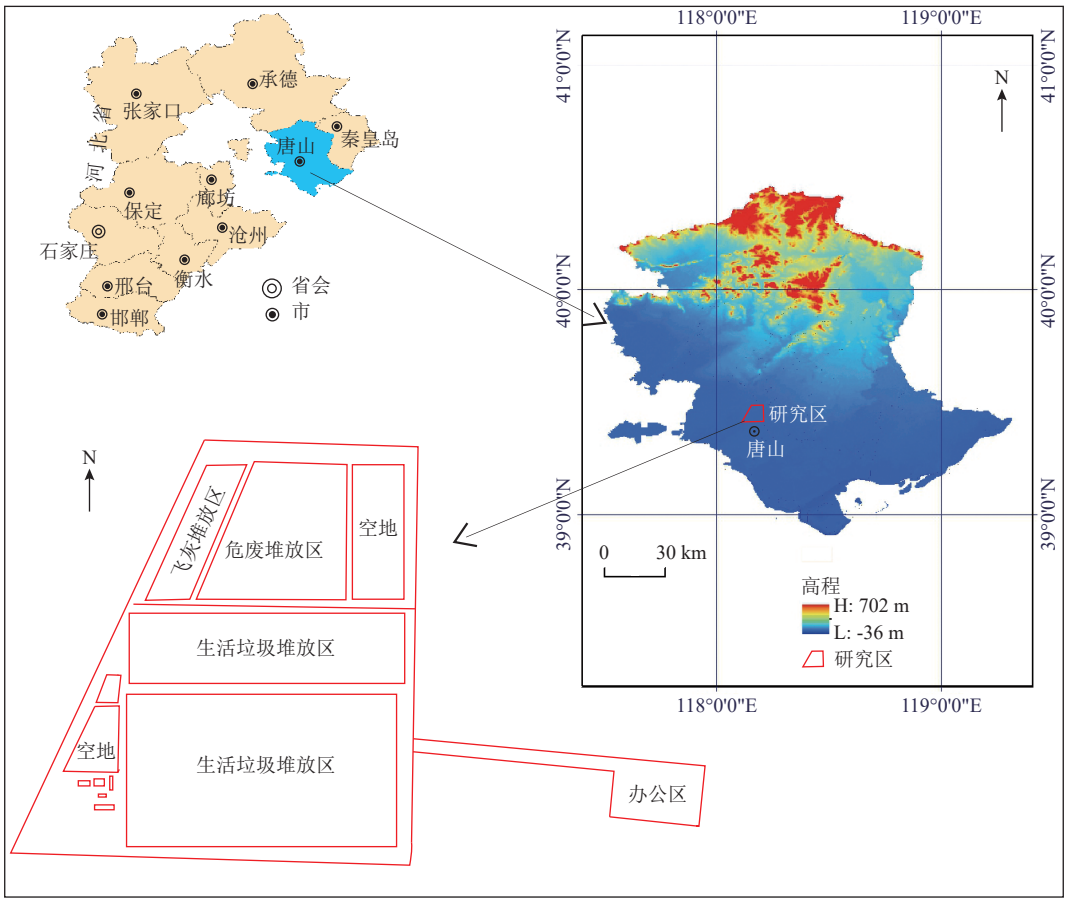


图 2　研究区位置

Fig. 2　Location map of the study area

下水导流层)、聚丙烯土工布、黏土夯实地基。

2)边坡水平防渗结构层次及材料:复合土工网格、单毛面 HDPE 膜、长纤无纺土工布、黏土夯实。

根据监测井的钻探数据(位置见图 3),在场地内获取了 1-1′和 2-2′两处水文地质剖面,该区域的地层条件如图 4 和图 5 所示。盐水层底部深度通常在 12~15 m 之间。从垂直方向看,承压层相对稳定,盐水与淡水含水层之间的水力连通性不明显。但水平方向的水文地质剖面清晰显示,淡水含水层向盐水含水层延伸,表明两者密不可分,且其水体盐度呈现明显渐变过渡。

根据浅层地下水流动场,在研究区布置监测井共 9 口,其中 S01、D01、D02、D03、D04、S02 等监测井位于填埋场垂直围护层外侧,S03、S04、S05 等监测井位于填埋场垂直围护层内侧,监测井信息见表 2。水深 28~29.5 m 的 D01、D02、D0、D04 井为深层监测井,水深 14~16 m 的 S01、S02、S03、S04、S05 井为浅层监测井,分两组进行比较分析,结果见表 3 和表 4。

S01 监测点位于垃圾填埋场北侧的浅水区域,是该区域浅水环境监测的基准点。数据显示,此处浊度、总硬度、溶解固体、氯化物及钠含量均超标。根

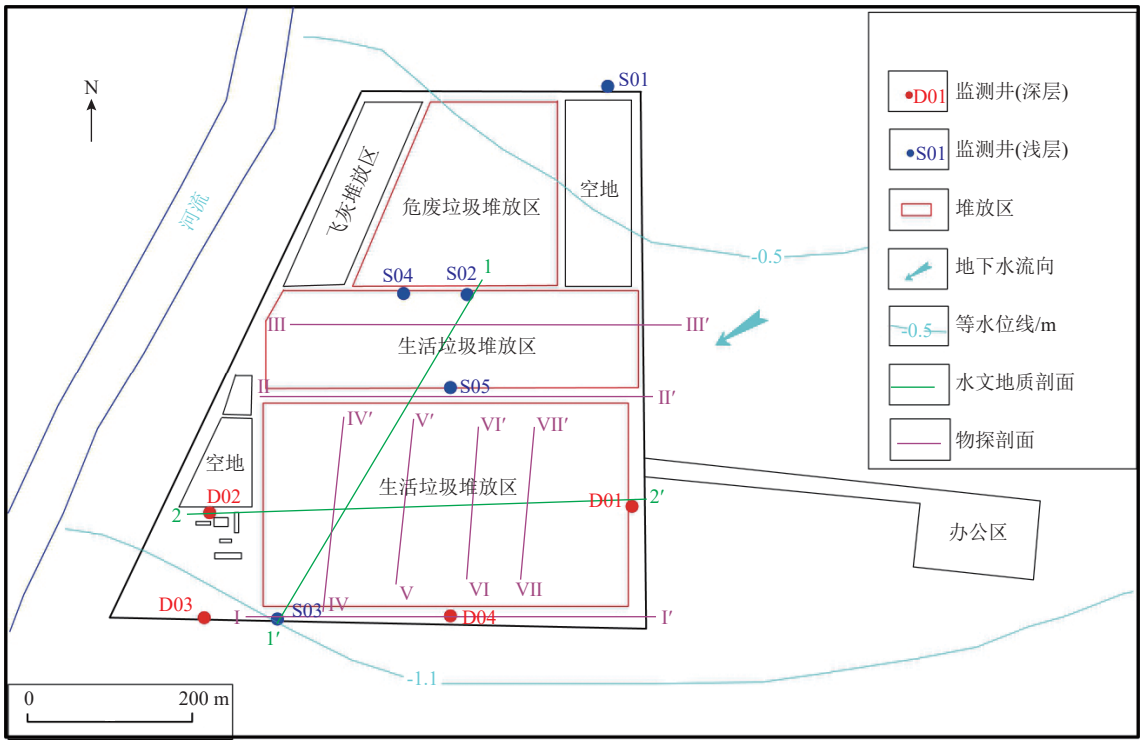


图 3　研究区域工作部署示意

Fig. 3　Study area work deployment schematic

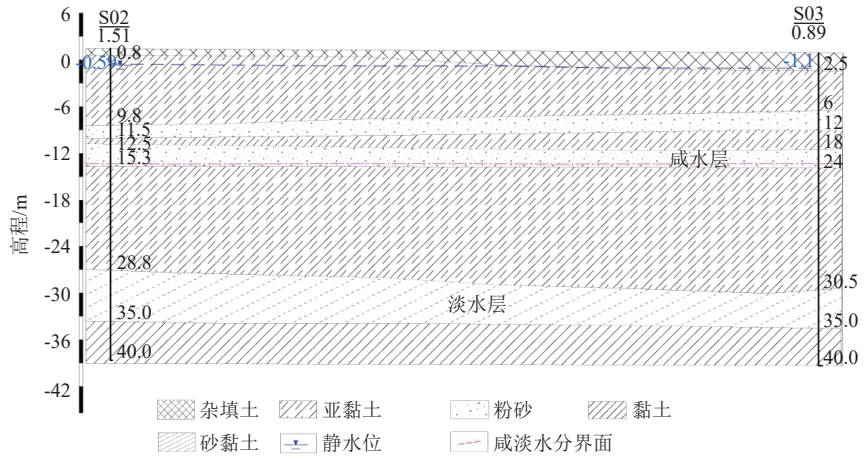


图 4　水文地质剖面(1-1′)

Fig. 4　Hydrogeological section(1-1′)

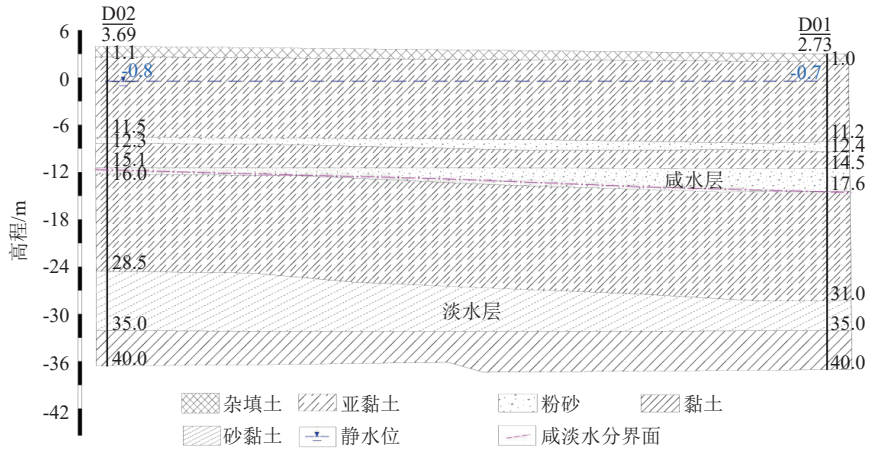


图 5　水文地质剖面(2-2′)

Fig. 5　Hydrogeological section (2-2')

表 2　监测点位信息

Table 2　Monitoring well information

编号	监测井材质	监测层位	井径/mm	成井深度/m
D01	PVC管	深层水	140	28.80
D02	PVC管	深层水	140	28.80
D03	PVC管	深层水	140	28.30
D04	PVC管	深层水	140	29.50
S01	PVC管	浅层水	140	14.00
S02	PVC管	浅层水	140	15.50
S03	PVC管	浅层水	110	16.00
S04	PVC管	浅层水	110	16.00
S05	PVC管	浅层水	110	16.00

据监测数据, 该浅水区域处于盐水入侵带, 盐水的水化学成分导致当地地下水在某些指标上呈现较高背景值。S01 监测井的水化学检测结果也是判断填埋场渗滤液是否泄漏的重要依据。检测结果显示: S03 和 S04 钻孔位置存在较大渗漏风险, 而 S05 井位则存在一定渗漏的可能性(见表 3)。

从深井的检测结果(表 4)可以看出, D01 位于垃圾填埋场东侧, 垂直围护墙外, 仅有浊度超过标准的 1.3 倍; D02 监测点位于填埋场渗滤液下游, 垂直围护墙外侧, 该区域氨氮超标值达标准限值的 9.0 倍, 五日生化需氧量超标值达标准限值的 11.05 倍。根据地球物理勘探结果, 此处存在天窗结构。在渗滤液调节池及污水管道下游区域, 若发生渗滤液调节池或管道泄漏, 可能导致氨氮和五日生化需氧量的监测值升高。

3　研究方法

地球物理勘探技术为界定含水层结构提供了一种高效且“无创”的解决方案。本研究采用电阻率层析成像技术(ERT)和探地雷达方法, 在垃圾填埋场进行了 7 条综合地球物理剖面的勘测(位置见图 3)。该技术通过检测地下目标与周围介质之间的电导率差异, 利用地表人工电场分布模式实现地下目标探测。其应用需满足 3 个前提条件: ①不同土壤质量具有差异化的电阻率; ②非饱和带电阻率随含水量变化而改变——通常含水量越高, 电阻率越低[28-29]; ③饱和带土壤电阻率随盐度升高而降低。在理论温度恒定条件下, 溶液浓度与电导率之间呈现较为严格的线性关系。同时, 大量实践研究证实, 在直流法中测得的电学参数与水文地质参数存在一定相关性, 这一结论也可通过阿奇公式及其改进版本得出[30-33]。本研究中电极间距统一设置为 3 m。采用温纳 α 阵列配置进行测量时, 需一次性布置数 10 个电极, 每个电极同时兼具电流电极和电位电极功能。通过可编程多电极切换器选择不同电极组合及间距, 从而实现快速获取现场数据。电极间距的增量通常以 'a'(电极间距)为单位。每个间距的数据采集均采用固定阵列配置从左至右移动完成, 随后增加间距继续采集下个间距区间的数据[34-36]。

根据收集的数据结果和采集的地层物理性质数据, 一般地层的电阻率值如表 5 所示。

图 6 展示了实施的 7 条 ERT 剖面测量结果。由于填埋场位于海水入侵盐渍区范围内, 采集到的电阻率数据波动范围较大, 因此对电阻率值进行了对数处理。根据该剖面的勘测数据, 7 条剖面的最大起伏幅度均小于 1 m, 因此反演计算无需考虑地形起伏。除位于不透水帷幕外侧、用于背景观测的 I 号剖面外, 其余各剖面均位于不透水帷幕内侧。

从三维剖面图 (图 6) 可以看出, 由松散填充土+粉质+粉砂层构成的 I、Ⅱ、Ⅲ三条线浅部区域, 对应 7~10 Ω·m 范围内的电阻率值, 表明含水量充

表 3　浅水区超Ⅳ因子检测与分析

Table 3　Detection and analysis of ultra-IV factor in shallow water　　mg·L^{-1}

序号	测试项		浅水				
			S01	S02	S03	S04	S05
1	浊度	监测结果	15	10.4	16	36	26
		超标倍数	1.5	1.04	1.6	3.6	2.6
2	色度	监测结果	/	/	/	300	60
		超标倍数	/	/	/	12.0	2.4
3	耗氧量	监测结果	/	/	/	90.3	25.1
		超标倍数	/	/	/	9.03	2.51
4	总硬度	监测结果	2.34×10^3	1.1×10^3	2.47×10^3	2.28×10^3	1.02×10^3
		超标倍数	3.6	1.69	3.8	3.51	1.57
5	溶解性总固体	监测结果	4.40×10^3	2.72×10^3	6.80×10^3	7.04×10^3	4.00×10^3
		超标倍数	2.20	1.36	3.4	3.52	2.0
6	硫酸盐	监测结果	/	/	374	/	/
		超标倍数	/	/	1.07	/	/
7	氯离子	监测结果	2.46×10^3	1.52×10^3	3.24×10^3	3.18×10^3	1.74×10^3
		超标倍数	7.03	4.34	9.26	9.08	4.97
8	钠	监测结果	1.15×10^3	0.608×10^3	0.542×10^3	2.47×10^3	1.17×10^3
		超标倍数	2.88	1.52	1.35	6.18	2.93
9	氨氮	监测结果	/	/	2.94	106	17.0
		超标倍数	/	/	1.96	70.67	11.33
10	锰	监测结果	/	/	2.99	/	/
		超标倍数	/	/	1.99	/	/
11	化学需氧量	监测结果	55	/	35	379	107
		超标倍数	1.38	/	1.17	12.63	3.57

注: “/”表示未超标。

表 4　深水区超 IV 因子检测与分析

Table 4　Detection and analysis of ultra-IV factor in deep water　　mg·L^{-1}

序号	检测项目		深层水			
			D01	D02	D03	D04
1	浊度	监测结果	13	/	/	/
		超标倍数	1.3	/	/	/
2	氨氮	监测结果	/	13.5	/	/
		超标倍数	/	9.0	/	/
3	五日生化需氧量	监测结果	/	66.3	/	/
		超标倍数	/	11.05	/	/

注: “/”表示未超标。

表 5　表面常见介电电阻率范围

Table 5　Surface common dielectric resistivity range

介质	电阻率/(Ω·m)	介质	电阻率/(Ω·m)
黄土	0~200	雨水	>1 000
黏土层	1~200	河水	10~100
含水砂卵砾石层	50~500	海水	0.1~1
淤泥质砂层	5~30	浅层水	<100
杂填土	10~2 000	污水	0.1~10

足。剖面 I 的富水层相对较浅, 埋深约 5~6 m, 在 6 m 深处出现水平分层的低电阻率体。该层顶部边界埋深 6~10 m, 呈缓坡状且主要为水平分层; 推测其抗水性与塑性粉质黏土及粉砂互层对应的电阻率值在 1~5 Ω·m 之间, 是剖面的主要含水层。该层底部边界埋深约 25 m, 25 m 以下电阻率值逐渐升高, 表明存在第二含水层的活动。推测抗水性层具有良好的水平连续性且界面起伏较小。

剖面Ⅱ的电阻率分布与剖面 I 相似, 虽然波动性有所增强, 但整体仍以水平层状结构为主; 推测其中等密度的粉砂和具有良好塑性的黏土交替层对应的电阻率值在 2~8 Ω·m 之间, 这正是该剖面的主要含水层。剖面中部地层连续性较差, 表明其含水层的连续性比剖面 I 更差。在 25 m 以下区域, 电阻率呈现上升趋势, 暗示存在下伏含水层。

剖面图Ⅲ显示, 浅层松散的粉砂土与粉砂互层对应的电阻率为 5~10 Ω·m。该层底部边界埋深约 10 m, 地形起伏平缓, 主要呈水平层理; 推测 10~25 m 深度处的中等密度粉砂土互层(具有良好塑性及粉质黏土)对应的电阻率为 2~6 Ω·m, 这是剖面中的主要含水层。该层具有良好的连续性。25 m 以下区域电阻率逐渐升高, 表明存在来自下伏含水层的渗透作用。

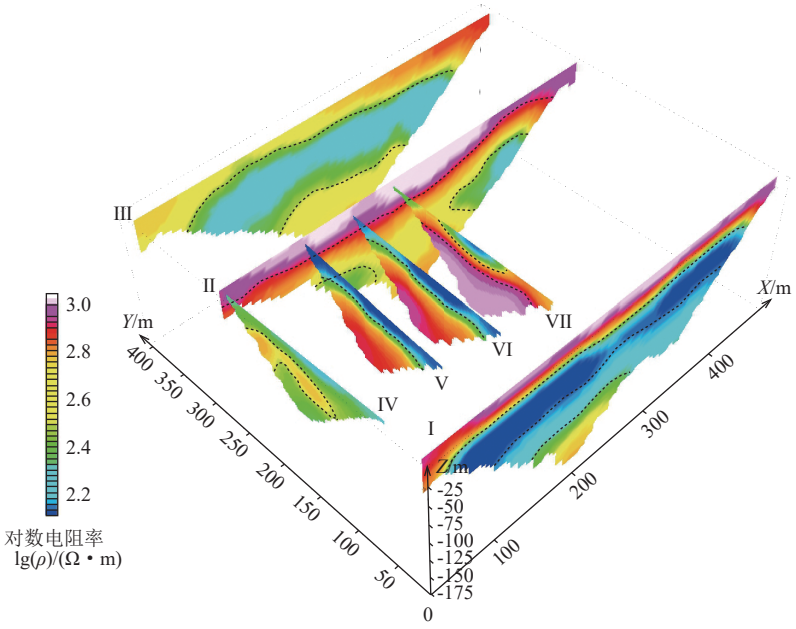


图 6　电阻率三维剖面图

Fig. 6　Log resistivity three-dimensional profiles

剖面Ⅳ的总体电阻率范围低于 500 Ω·m, 浅层 0~1 m 范围内的人工土层电阻率为 100~300 Ω·m。1 m 深度以下的高阻值区域表明存在人工不透水层, 其电阻率值超过 400 Ω·m。剖面 IV 的中部和前部未显示上述连续高阻值段, 这表明这些位置的西侧边坡存在不连续的不透水膜结构, 可能对不透水层造成损害风险。

剖面 V 的浅层区域(0~1 m 深度)以人工土壤覆盖层为特征, 其电阻率值低于 500 Ω·m。当深度超过 1 m 时, 高电阻率区表明存在人工不透水层, 其电阻率值超过 500 Ω·m。在 15 m 深度范围内, 电阻率急剧上升超过 600 Ω·m, 这表明存在多层叠加的不透水结构。该现象既反映出对多层叠加不透水结构的响应, 也显示出各层间连续性逐渐增强时, 电阻率值也持续升高。

剖面Ⅵ中人工回填层的电阻率值低于 500 Ω·m, 表明埋深不足 1 m。1 m 以上区域的高电阻率是人工不透水层的反映, 其电阻率值超过 500 Ω·m。在 15 m 以内的埋深范围内, 电阻率急剧上升超过 1 000 Ω·m, 这表明存在多层叠加的不透水层, 且随着各层之间的连续性逐渐增强, 电阻率也持续升高。

剖面Ⅶ的总体电阻率高于 1 000 Ω·m, 而人工土层的电阻率低于 500 Ω·m, 表明埋深不足 1 m。深度超过 1 m 的高阻区电阻值超过 500 Ω·m, 推测是塑料薄膜引起的反映。在 15 m 埋深范围内, 电阻率突然增加至 1 000 Ω·m 以上, 整体电阻值偏高, 说明存在多层互不透水的叠加结构。整个剖面由这些高阻区构成, 表明不透水层保持完整。

整体来看, 该区域地下水流向 EN 至 WS 方向。Ⅰ、Ⅱ、Ⅲ这 3 个剖面呈近 E—W 走向, 与地下水流向形成较大夹角。地下介质为天然沉积岩层, 电阻率范围在 1~10 Ω·m 之间。通过电阻率垂直分布特征分析, 0~10 m 浅层呈现较高电阻值; 5~10 Ω·m 区间则为中等电阻值, 推测该区域由含水粉砂与粉砂互层构成, 20 m 深处处于低电阻区中心。1~100 Ω·m 区间电阻值较高, 推测为优质全粉质黏土层, 具有一定的防污扩散能力。25 m 以下 3 个剖面电阻率较高(1~100 Ω·m), 推测为第二含水层的反映。浅层平面电阻值在 EN 方向较低。Ⅳ、Ⅴ、Ⅵ、Ⅶ剖面位于填埋场中部, 填埋层下部为填埋层, 各层均覆膜处理, 坑体覆盖后的最后一层膜则用土覆盖并种植草坪。由于该薄膜具有典型的绝缘特性, 形成了强大的电流屏蔽层, 导致Ⅳ、Ⅴ、Ⅵ和Ⅶ线的电阻率显著增加, 从Ⅳ到Ⅶ段的电阻值越来越高, 且电阻率等值线也变得越来越平缓, 这表明靠近Ⅶ段填埋层的完整性更好。

探地雷达通过发射天线向地下发射高频宽带短脉冲电磁波。当这些电磁波在介质中传播时, 若遇到与周围介质介电常数存在显著差异的地下界面, 就会产生反射。接收天线可捕捉到这些来自地下界面的反射波[37]。反射波的传播路径、电磁场强度及波形特征会因介质的电磁特性与几何形态而异。因此, 通过分析电磁波在介质中的传播时间(往返时间)、振幅、波形特征及传播速度等参数, 即可推断

地下异常的空间位置和深度[38-39]。

GPR 剖面与 ERT 剖面基本吻合。雷达反射波能量较强的区域，其反射波形图会与周边波形产生明显差异，这表明界面处各层之间的含水量或岩性存在显著差异。详细分析结果见表 6 及图 7，图中强反射异常区域用红色虚线圈定，表中包含 GPR 与

表 6　探地雷达剖面与 ERT 剖面分析

Table 6　Analysis of geological radar profiles and ERT profiles

剖面号	雷达反射波特征	地质构造	ERT 特征
1	呈水平层状，两端存在强反射区	含水层顶板埋深局部变浅区域	电阻率呈水平层状，由上至下呈高、低、高分布
2	呈水平层状，东部存在强反射区	含水层顶板埋深局部变浅区域	电阻率呈水平层状，剖面两段出现低阻异常区
3	不作描述	位于垃圾填埋区之外，反应不明显	呈水平层状，电阻率由上至下呈高、低、高分布
4	无明显强反射区域	—	呈水平层状，电阻率由上至下呈低、高、低分布
5	北部3 m深位置有层状反射区	局部含水区域	呈水平层状，电阻率由上至下呈低到高分布
6	中部出现杂乱反射波形	地下介质浅层密实度不均	呈水平层状，电阻率由上至下呈低到高分布
7	大部区域为层状强反射波形	地下垃圾填埋层反映	含水率较低

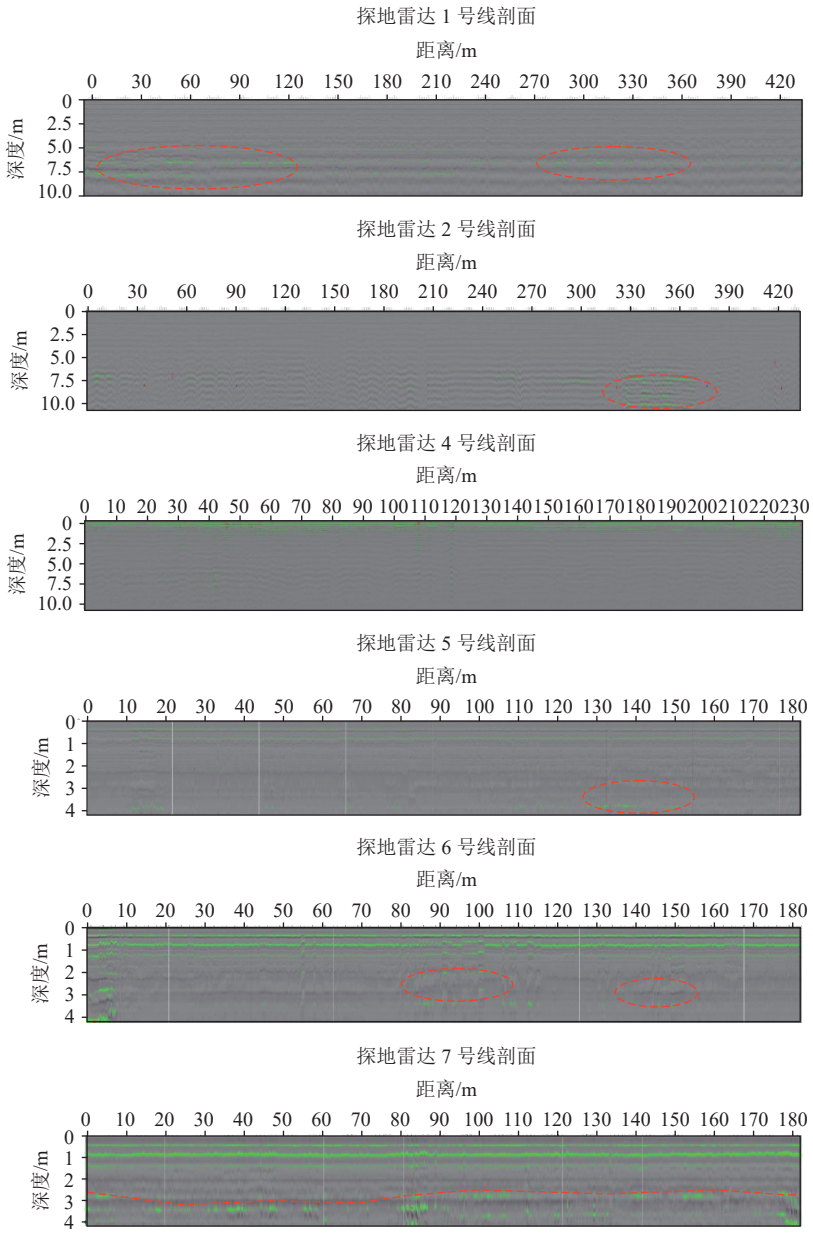


图 7　探地雷达反射剖面

Fig. 7　Geophysical radar reflection profile

ERT 剖面的对比分析。由于剖面 3 位于垃圾填埋场区域外且响应不明显, 此处不再赘述该剖面。

两种物探方法的测量结果均反映了堆放区的中间区域防渗层较为完好, 说明填埋场在进行垃圾堆放工作时比较注意对中间区域的防渗膜的保护, 可能会采取缓铺慢行的方式减少对防渗膜的损坏, 但在堆放区的边界地区, 也就是防渗膜的边缘地带, 防渗层有一定的破损。

由于研究区域地势平坦、地形起伏微弱且场地形状规整, 非常适合开展 GIS 网格化工作。因此, 我们采用 ArcGIS 软件将研究区域填埋场划分为 5 m×5 m 的网格单元(图 8), 每个网格均作为独立单元处理。整个研究区域共划分出 10 982 个网格单元, 并为每个网格单元标注了坐标位置信息。根据参考钻孔数据和水文化学指标选取了若干已知采样点, 其中约 80% 作为训练样本(包括泄漏风险区外的采样点), 约 20% 作为验证样本用于模型构建[40-41]。

由于渗滤液的渗漏会导致周边环境的化学和物理性质发生变化, 例如: 地下水化学成分、土壤电阻率、极化率、电磁波衰减等各类变化。同时, 渗滤液的扩散过程也会受到水文地质条件、地质构造、岩性、地形以及人类活动等因素的影响。因此, 本文主要选取了 7 个影响因素。①在场地区域开展地表地球物理勘探工作后, 对采集的原始数据进行反演处理, 在约 10 m 深度处的电阻率 ρ 和极化率 η(经研究区水文地质数据分析认为, 该深度的电值具有代表性, 下文简称电阻率、极化率)、地下水位深度 h(通过电测反演曲线获得)以及雷达反射波形图的同相轴异常情况(1 表示异常, 0 表示无异常); ②通过现有监测井的水质化学检测指标及井水样本, 确定发生渗漏的异常井(高风险、中风险、低风险)和未渗漏的正常井(极低风险)的位置信息, 并将监测井周围 50 m 范围内的采样点(网格单元)及其与流场的直线距离和上下游关系作为影响因素之一; ③通过现有监测井及其他数据选取 880 个已知采样点作为训练样本, 选取 220 个已知采样点作为验证样本; ④将上述每个采样点的各影响因素代入神经网络模型进行训练, 输出结果即为各网格单元的渗漏风险等级; ⑤将可疑渗漏风险区域内的未知采样点影响因素输入已训练完善的模型, 即可获得各网格单元防渗膜的预测渗漏风险等级。为判断影响因子是否满足建模要求, 需对其进行多重共线性检验。具体采用方差膨胀因子 *VIF* 和容差值 *TOL* 作为评估指标。若 *VIF*>10 或 *TOL*<0.1, 则表明各影响因子间存在强相关性, 则不符合建模要求。通过 BP 神经网络权重分析步骤: 提取模型输入层→隐藏层的连接权重, 通过归一化处理得到每个因子的权重系数(反映因子对模型输出的直接贡献)。经验证, 本研究选取的 7 个影响因子均符合建模要求(见表 7)。同时, 采用证据权重分析法确定各影响因素的相关性和重要性。各个检验系数均可由 SPSS 或 MATLAB 等软件获得。

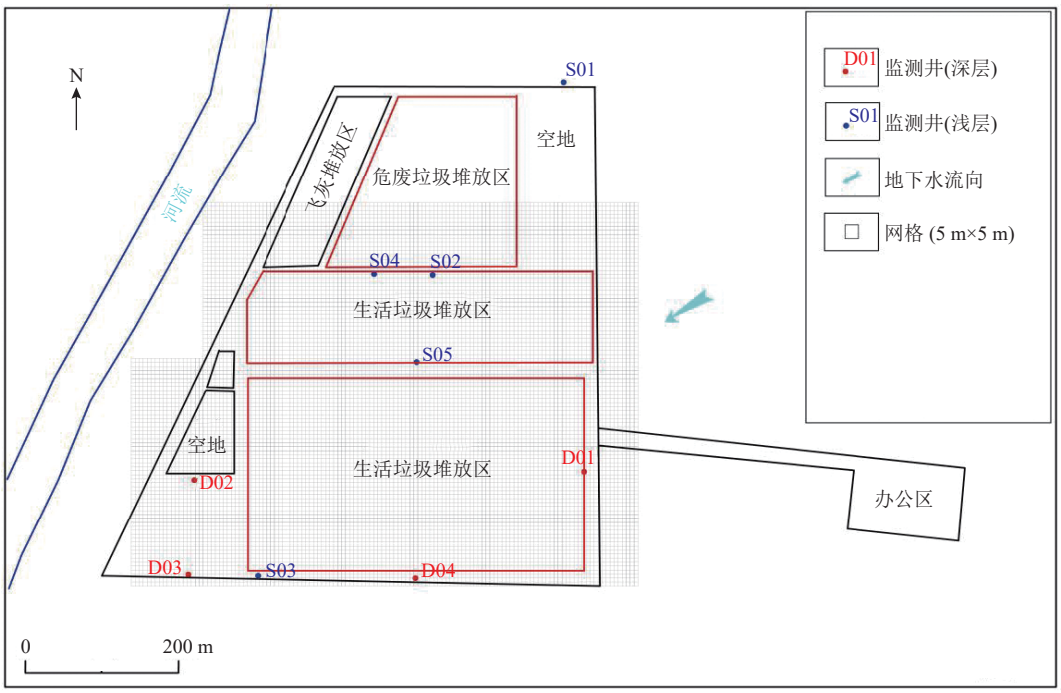


图 8　网格化研究区

Fig. 8　Study area after gridding

表 7 影响因子相关指标综合分析

Table 7 Comprehensive analysis of indicators related to impact factors

影响因子	获取方法	*VIF*	*TOL*	相关性*r*	显著性系数*p*	训练样本数
电阻率 ρ	电阻率测深, ERT	1.315	0.760	0.882	0.946	770
极化率 η	激发极化电测深	1.518	0.659	0.808	0.912	460
半衰时*Th*	激发极化电测深	1.665	0.601	0.726	0.826	460
雷达波形*R*	探地雷达(GPR)	1.333	0.750	0.826	0.866	800
距上游监测井距离*d*	现场测量和数据收集	1.414	0.707	0.896	0.992	40
距下游监测井距离*d'*	现场测量和数据收集	1.358	0.736	0.611	0.668	40
含水层深度*h*	物探采集数据反演解释	1.212	0.825	0.818	0.898	660

4 结果与讨论

由于 BP 神经网络具有无需建立精确数学模型即可实现输入空间到输出空间非线性映射的优势，通过实验和统计方法，利用多个线性(非线性)回归模型，确定了电阻率 ρ、极化率 η、半衰期 *Th*、雷达波形 *R*、上游监测井距离 *d*、下游监测井距离 *d'*和地下水深度 *h* 的集合，输出结果 ***P*** 即为泄漏风险等级 *p* 的集合。通过预测网格单元的泄漏风险等级，在研究区域内划定了极低风险、低风险、中风险和高风险区域[42-44]。

通过调试上述模型，我们发现其传递函数采用了 S 型正切函数 tansig 和纯线性函数 purelin。训练函数使用 trainlm 函数，并采用全值优化算法——莱文贝格—马夸特法来训练输入数据与目标向量。该算法具有训练速度快、预测精度高的特点。在研究区域中，选取 9 个已知监测井区及其内部 1 100 个已知采样点的数据作为训练集和验证集，最终得到如图 9 所示的误差收敛曲线。数据显示，在第 282 步达到误差目标后，模型停止运行，此时误差已控制在理想范围内。实验结果表明，该模型的误差收敛效果非常理想。

本研究采用 BP 神经网络构建了垃圾填埋场渗滤液泄漏风险预测模型。预测结果如表 8 所示，通过詹克斯自然分段法将结果划分为 4 个风险等级：很低、低、中、高。该自然分段法核心在于根据数据内在规律进行分组，既确保组间差异最大化，又保持组内相似性[45-46]。

通过运用 ArcGIS 叠加各影响因子的后验概率，获得了 BP 神经网络模型预测渗滤液渗漏概率等级的区域分布，如图 10 所示。渗滤液中等渗漏风险区域占总面积的 11.12%，高风险区域占 1.29%。高风险区域内有 144 个测试样本。

本研究采用接受者操作特性曲线(receiver operating characteristic curve，简称 ROC 曲线)评估各模型的预测效果。ROC 曲线作为评估模型分类与预测性能的经典指标，最初用于衡量雷达信号接收性能，后在医疗和机器学习领域得到广泛应用。该曲线与横轴围成的面积即为曲线下面积(area under the curve, AUC)。当 *AUC* 值越接近 1 时，表明模型预测准确度越高。为验证 BP 神经网络模型的准确性，采用相同影响因子作为输入神经元构建 RBF 径向基神经网络模型进行对比。结果显示：RBF 模型 *AUC*

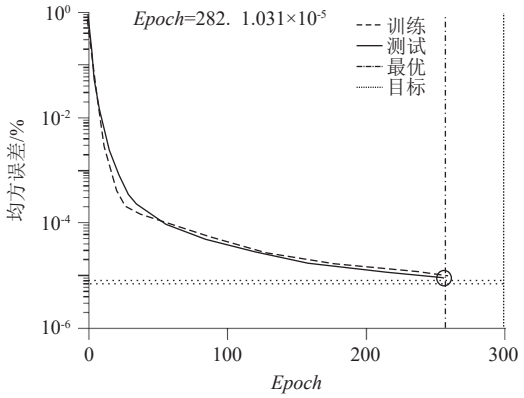


图 9 误差收敛曲线

Fig. 9 Error convergence curve

表 8 机器学习模型预测结果

Table 8 Prediction results of machine learning model

风险等级	BP神经网络模型					
	概率/%	面积占比/%	样本数	颜色	训练样本数	验证样本数
Ⅰ(很低)	0.00~1.00	61.80	6 780	白	400	100
Ⅱ(低)	1.00~20.00	25.79	2 832	蓝	280	70
Ⅲ(中等)	20.00~50.00	11.12	1 226	橙	160	40
Ⅳ(高)	50.00~100.00	1.29	144	红	40	10

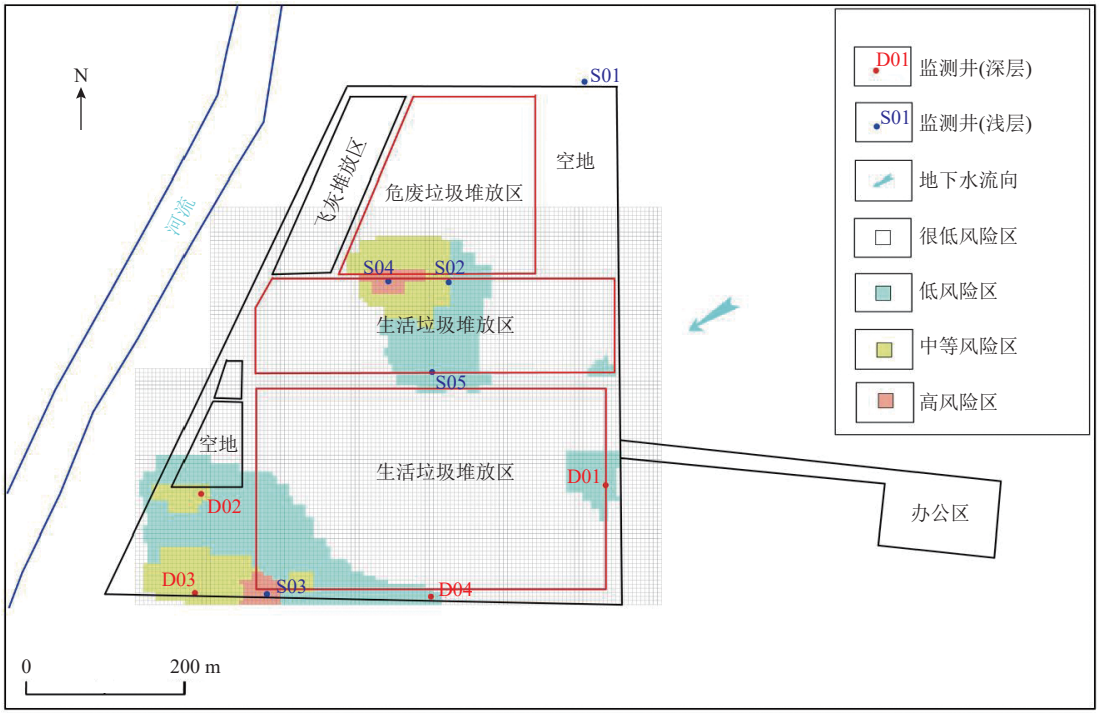


图 10　研究区渗漏概率风险区域划分

Fig. 10　The risk area division for leakage probability in the study area

值为 0.77, BP 模型 *AUC* 值达 0.82(图 11), 表明 BP 神经网络模型具有更优预测性能。值得注意的是, 在使用神经网络时, 7 个影响因子中有 3 个指标预测膜泄漏风险表现最佳[47-50]。

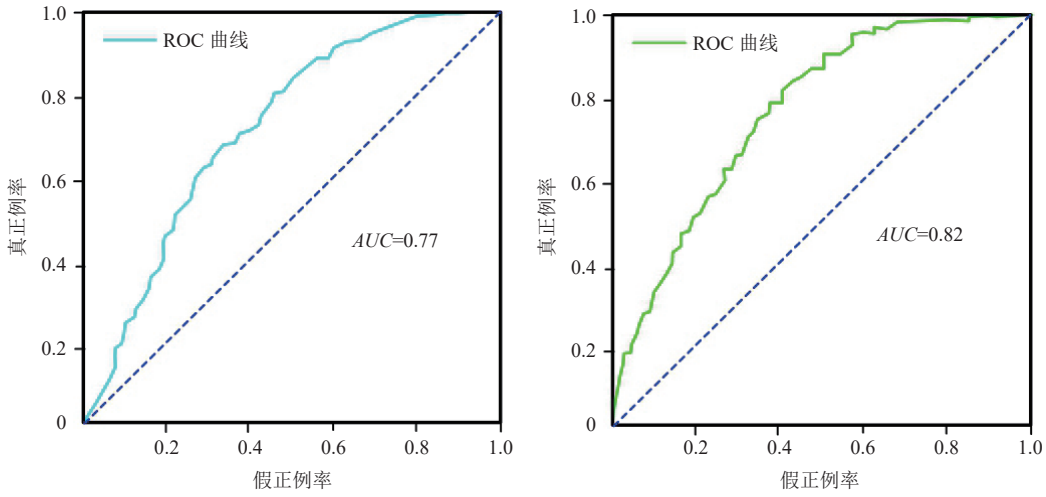


图 11　两种不同模型的 ROC 曲线评价

Fig. 11　ROC curve evaluation of two different models

5　结论

1)该研究区域因海水入侵导致地下水盐度高, 对依赖地质电差异的地球物理探测技术提出了严峻挑战。但这种特殊环境也使其成为渗滤液调查的典型试验场。研究结果表明垃圾填埋场的边缘地区, 也就是防渗层的边界是一个容易被忽视的区域, 容易出现防渗层磨损过快、易遭破坏的情况, 应做好与周围地质环境隔离防护的工作。

2)ROC 曲线评估表明, 神经网络模型表现优异。值得注意的是, 影响因素的选择和原始数据质量直接影响机器学习模型的性能。因此, 在应用此类模型时, 必须谨慎筛选影响因素并进行数据过滤。未来研究可着重引入先进建模方法、优化预测算法, 并探索影响因素的权重分配, 从而进一步提升

预测精度。

3)地球物理勘探、地理信息系统(GIS)与机器学习的结合,显著提升了监测工作的数据驱动特性。通过将研究区域划分为网格单元,并将点位数据整合到区域评估中,实现了量化监测。然而,单纯依赖一两种地球物理方法进行建模,可能受限于地球物理数据的多解特性。未来的发展方向应着重通过引入更多地球物理方法来获取相关参数,从而实现数据来源的多元化,进而增强模型的适用性和稳健性。

参考文献(References):

[1] 能昌信,张弦,刘景财,等. 受 HDPE 膜影响下的垃圾填埋场渗滤液水位探测方法研究 [J]. 环境工程技术学报, 2023, 13(1): 325−331.
Neng C X, Zhang X, Liu J C, et al. Study on detection method of landfill le achate level affected by HDPE membrane[J]. Journal of Environmental Engineering Technology, 2023, 13(1): 325−331.

[2] 王丹齐. 高盐渍化地区渠道渗漏电阻率法探测正演模拟 [D]. 湘潭: 湖南科技大学, 2022.
Wang D Q. Forward modeling of resistivity detection of channel leakage in high salinization area[D]. Xiangtan: Hunan University of Science and Technology, 2022.

[3] 王迪,尉斌,闫永利,等. 垃圾填埋场地下环境污染检测方法技术研究 [J]. 地球物理学报, 2012, 55(6): 2115−2119.
Wang D, Yu B, Yan Y L, et al. Study of detecting technology for landfill underground environmental pollution[J]. Chinese Journal of Geophysics, 2012, 55(6): 2115−2119.

[4] 何畅,曾晓岚,张存款,等. 纳米银与微塑料在模拟垃圾填埋柱中的共迁移特征 [J]. 中国环境科学, 2022, 42(8): 3788−3795.
He C, Zeng X L, Zhang C K, et al. Characteristics of silver nanoparticles and microplastics co-migration in simulated landfill columns[J]. China Environmental Science, 2022, 42(8): 3788−3795.

[5] Li Z H, Li J F, Zhu Y C, et al. Anthropogenic influences on the hydrochemical characteristics of the groundwater in Xiamen City, China and their evolution[J]. Water, 2022, 14(21): 3377.

[6] 刘豪睿,能昌信,王聪,等. 基于介电特性获取污染土壤中污染物含量的研究 [J]. 地球物理学进展, 2010, 25(6): 2184−2192.
Liu H R, Neng C X, Wang C, et al. Review on detection of Pollutant content in the contaminated soil based on dielectric character[J]. Progress in Geophysics, 2010, 25(6): 2184−2192.

[7] 马媛媛,郭秀军,朱大伟,等. 生活垃圾渗滤液污染砂土电阻率变化机制实验研究 [J]. 地球物理学进展, 2010, 25(3): 1098−1104.
Ma Y Y, Guo X J, Zhu D W, et al. Investigation on electrical resistivity of soils by contaminated domestic landfill-leachate[J]. Progress in Geophysics, 2010, 25(3): 1098−1104.

[8] 侯晓冬,郭秀军,贾永刚,等. 基于探地雷达回波信号获取污染土壤中污染物含量的研究进展 [J]. 地球物理学进展, 2008, 23(3): 962−968.
Hou X D, Guo X J, Jia Y G, et al. Progress on detection of contamination content in the contaminated soilbased on Ground Penetrating Radar[J]. Progress in Geophysics, 2008, 23(3): 962−968.

[9] 李奔,刘汉乐,李培华,等. 碳酸盐岩石裂隙中 DNAPL 污染物迁移过程的电阻率成像 [J]. 地球物理学进展, 2023, 38(6): 2704−2713.
Li B, Liu H L, Li P H, et al. Electrical resistivity tomography of DNAPL contaminant migration process in carbonate rock fractures[J]. Progress in Geophysics, 2023, 38(6): 2704−2713.

[10] 刘国辉,徐晶,王猛,等. 高密度电阻率法在垃圾填埋场渗漏检测中的应用 [J]. 物探与化探, 2011, 35(5): 680−683, 691.
Liu G H, Xu J, Wang M, et al. The application of high-density resistivity method to landfill leakage detection[J]. Geophysical and Geochemical Exploration, 2011, 35(5): 680−683, 691.

[11] 刘宗辉,谭海涛,刘毛毛,等. 锌污染土探地雷达频散衰减特性与正演模拟研究 [J]. 地球物理学进展, 2022, 37(5): 2180−2187.
Liu Z H, Tan H T, Liu M M, et al. Study on dispersion attenuation characteristics of ground penetrating radar reflected wave in zinc contaminated soil[J]. Progress in Geophysics, 2022, 37(5): 2180−2187.

[12] 王莹莹,郭秀军,邵帅,等. 土壤毛细带内油污染区探地雷达异常特征分析及状态评价 [J]. 地球物理学进展, 2018, 33(5): 2172−2180.
Wang Y Y, Guo X J, Shao S, et al. Abnormal features analysis and status evaluation for oil contaminated site in capillary zone based on ground penetrating radar[J]. Progress in Geophysics, 2018, 33(5): 2172−2180.

[13] Shamsuddin M K N, Sulaiman W N A, Suratman S, et al. Groundwater and surface-water utilisation using a bank infiltration technique in Malaysia[J]. Hydrogeology Journal, 2014, 22(3): 543−564.

[14] Bharti A K, Singh S K, Pal S K, et al. Electrical resistivity tomography technique coupled with numerical modelling: A case study for stability analysis[J]. Geophysical Prospecting, 2023, 71(7): 1368−1384.

[15] Duragasi A R, Sukumaran J V. Geo-electrical resistivity–based study to estimate the aquifer parameters—A study in parts of Yamuna Nagar District, Haryana State, North India[J]. Arabian Journal of Geosciences, 2023, 16(10): 584.

[16] Cameron E P, Giorgio Stella, Fabio A. Application of influence diagrams for well contamination risk management: a case study in the Po plain, northern Italy[J]. Hydrogeology Journal, 2019, 27(1): 273-289. doi:10.1007/s10040-018-1860-9

[17] Pedrazas M N, Cardenas M B, Hosain A, et al. Application of electrical resistivity to map the stratigraphy and salinity of fluvio-deltaic aquifers: Case studies from Bangladesh that reveal benefits and pitfalls[J]. Hydrogeology Journal, 2021, 29(4): 1601−1610.

[18] Song H w, Xia F, Mu H D, et al. 2020. Study on detecting spatial distribution availability in mine goafs by ultra-high density electrical method[J]. Journal of Groundwater Science and Engineering, 8(3): 281-286. doi:10.19637/j.cnki.2305-7068.2020.03.008

[19] Sirieix C, Riss J, Rey F, et al. Electrical resistivity tomography to characterize a karstic Vauclusian spring: Fontaine d'Orbe (Pyrénées, France)[J]. Hydrogeology Journal, 2014, 22(4): 911−924.

[20] 李慧香,潘云,宫辉力,等. 机器学习方法在预测泉水潜在出露位置中的应用 [J]. 地球信息科学学报, 2021, 23(6): 1028−1039.

Li H X, Pan Y, Gong H L, et al. Application of machine learning method in prediction of potential exposure position of spring water [J]. Journal of Geo-Information Science, 2021, 23(6): 1028−1039.

[21] 尚敏, 马锐, 张英莹, 等. 基于 GIS 的证据权重法的崩塌敏感性分析研究 [J]. 工程地质学报, 2018, 26(5): 1211−1218.
Shang M, Ma R, Zhang Y Y, et al. GIS based weights of evidence method for rock fall susceptibility[J]. Journal of Engineering Geology, 2018, 26(5): 1211−1218.

[22] 汪维东, 黄晓康, 朱大勇, 等. 管线渗漏对地铁盾构影响的模型试验研究 [J]. 合肥工业大学学报: 自然科学版, 2021, 44(5): 666−671.
Wang W D, Huang X K, Zhu D Y, et al. Model test of the effect of pipeline leakage on metro shield construction[J]. Journal of Hefei University of Technology: Natural Science, 2021, 44(5): 666−671.

[23] Shafaei F, Ramazi H, Jodeiri Shokri B, et al. Detecting the source of contaminant zones down-gradient of the alborz sharghi coal washing plant using geo-electrical methods, northeastern Iran[J]. Mine Water and the Environment, 2016, 35(3): 381−388.

[24] Hiskiawan P, Chen C C, Ye Z K. Processing of electrical resistivity tomography data using convolutional neural network in ERT-NET architectures[J]. Arabian Journal of Geosciences, 2023, 16(10): 581.

[25] Abdaki M, Al-Ozeer A Z, Alobaydy O, et al. Predicting rainfall in Nineveh Governorate in northern Iraq using machine learning time-series forecasting algorithm[J]. Arabian Journal of Geosciences, 2023, 16(12): 655.

[26] Melouah O, Zerrouki H, Lopez Steinmetz R L. Characterization of processes and mechanisms controlling ground water salinization in the Algerian Sahara[J]. Arabian Journal of Geosciences, 2020, 13(18): 927.

[27] 高硕阳. 基于 BP 神经网络的填埋场渗漏量研究 [D]. 烟台: 山东工商学院, 2023.
Gao S Y. Study on landfill leakage based on BP neural network[D]. Yantai: Shandong Technology and Business University, 2023.

[28] 能昌信, 孙晓晨, 徐亚, 等. 基于深度卷积神经网络的场地污染非线性反演方法 [J]. 中国环境科学, 2019, 39(12): 5162−5172.
Neng C X, Sun X C, Xu Y, et al. A site pollution nonlinear inversion method based on deep convolutional neural network[J]. China Environmental Science, 2019, 39(12): 5162−5172.

[29] Revil A, Karaoulis M, Johnson T, et al. Some low-frequency electrical methods for subsurface characterization and monitoring in hydrogeology[J]. Hydrogeology Journal, 2012, 20(4): 617−658. doi:10.1007/s10040-011-0819-x

[30] Song H W, Mu H D, Xia F, et al. 2018. Analyzing the differences of brackish-water in the Badain Lake by geophysical exploration method[J]. Journal of Groundwater Science and Engineering, 6(3): 187-192. doi:10.19637/j.cnki.2305-7068.2018.03.004

[31] 尚浩, 郭秀军, 王仙丽, 等. 垃圾填埋场渗漏污染三维分布式电学监测系统研制及应用 [J]. 地球物理学进展, 2010, 25(4): 1485−1491.
Shang H, Guo X J, Wang X L, et al. Design and experiment of the 3-D electrical resistivity detecting system for monitoring underground soil contaminated by landfill leachate[J]. Progress in Geophysics, 2010, 25(4): 1485−1491.

[32] Xia F, Song H W, Wang M, et al. Analysis of prospecting polymetallic metallogenic belts by comprehensive geophysical method[J]. Journal of Groundwater Science and Engineering, 2019, 7(3): 237-244. doi:10.19637/j.cnki.2305-7068.2019.03.004

[33] 徐兴倩, 蔡波, 屈新, 等. 土体电阻率模型研究现状综述 [J]. 地球物理学进展, 2022, 37(5): 2205−2217.
Xu X Q, Cai B, Qu X, et al. Review of soil resistivity model[J]. Progress in Geophysics, 2022, 37(5): 2205−2217.

[34] 朱银侠, 刘汉乐, 杨登波, 等. PFAS 污染砂土的电阻率特性试验 [J]. 地球物理学进展, 2023, 38(4): 1912−1918.
Zhu Y X, Liu H L, Yang D B, et al. Electrical resistivity experiment of sand contaminated by PFAS[J]. Progress in Geophysics, 2023, 38(4): 1912−1918.

[35] Razafindratsima S, Guérin R, Bendjoudi H, et al. Hydrogeological modeling constraints provided by geophysical and geochemical mapping of a chlorinated ethenes plume in northern France[J]. Hydrogeology Journal, 2014, 22(6): 1433−1446.

[36] Xu L M, Green E C R. Inferring geological structural features from geophysical and geological mapping data using machine learning algorithms[J]. Geophysical Prospecting, 2023, 71(9): 1728−1742.

[37] Tigrine C D A, Boutiba M. Salinization risk assessment of irrigated soils in the Souf Valley (South-East Algeria) using chemical analysis, multivariate statistics, and GIS[J]. Arabian Journal of Geosciences, 2023, 16(7): 438.

[38] Waheed U B, Di H B, Sun J J, et al. Introduction to special issue on machine learning applications in geophysical exploration and monitoring[J]. Geophysical Prospecting, 2024, 72(1): 3−6.

[39] 张宝一, 徐坤, 宋磊, 等. 证据权重法在黑龙江省三合屯地区三维金矿远景区建模中的应用 [J]. 地质找矿论丛, 2023, 38(4): 522−531.
Zhang B Y, Xu K, Song L, et al. Application of weight of evidence model in 3D gold mineral prospectivity modeling in the Sanhetun area, Heilongjiang Province[J]. Contributions to Geology and Mineral Resources Research, 2023, 38(4): 522−531.

[40] 李洪丽, 鹿琪. 探地雷达在 LNAPL 污染土壤探测中的应用进展研究 [J]. 地球物理学进展, 2020, 35(3): 1141−1148.
Li H L, Lu Q. Progress in application of ground penetrating radar in LNAPL contaminated soil detection of LNAPL[J]. Progress in Geophysics, 2020, 35(3): 1141−1148.

[41] Ghosh R, Sutradhar S, Das N, et al. A comparative evaluation of GIS based flood susceptibility models: A case of Kopai river basin, Eastern India[J]. Arabian Journal of Geosciences, 2023, 16(11): 591.

[42] Pourtaghi Z S, Pourghasemi H R. GIS-based groundwater spring potential assessment and mapping in the Birjand Township, southern Khorasan Province, Iran[J]. Hydrogeology Journal, 2014, 22(3): 643−662.

[43] Liu P F, Zhang G H, Cui S J, et al. Effects of groundwater level control on soil salinity change in farmland around wetlands in arid areas: A case study of the lower reaches of the Shiyang River Basin, China[J]. Water, 2023, 15(7): 1308.

[44] Mnasri M, Amiri A, Nasr I H, et al. Integrated geophysical ap-

proach for ore exploration: Case study of Sidi Bou Aouane–Khadhkhadha Pb-Zn province-Northern Tunisia[J]. Geophysical Prospecting, 2023, 71(9): 1772−1791.

[45] Persico R. Introduction to the special issue on 'Advanced techniques, methods and applications for an integrated approach to the geophysical prospecting'[J]. Geophysical Prospecting, 2023, 71(9): 1693−1695.

[46] Corsini A, Cervi F, Ronchetti F. Weight of evidence and artificial neural networks for potential groundwater spring mapping: An application to the Mt. Modino area (Northern Apennines, Italy)[J]. Geomorphology, 2009, 111(1-2): 79−87.

[47] 郭秀军, 魏丽, 贾永刚, 等. 垃圾填埋场渗滤液污染地下含水层及修复过程的三维动态监测实验 [J]. 地球物理学进展, 2006, 21(2): 637−642.
Guo X J, Wei L, Jia Y G, et al. Experiment of monitoring underground aquifers contaminated by leachate of landfill and remation with 3-D electrical method[J]. Progress in Geophysics, 2006, 21(2): 637−642.

[48] Naseri M H, Shataee Jouibary S. Improvement of forest canopy density mapping of sparse forests using RS/GIS-based classification approach[J]. Arabian Journal of Geosciences, 2023, 16(9): 525.

[49] Pilla G, Torrese P. Hydrochemical-geophysical study of saline paleo-water contamination in alluvial aquifers[J]. Hydrogeology Journal, 2022, 30(2): 511−532.

[50] Song H W, Xia F, Wang W Q, et al. ANN-based prediction model for single-hole water inflow from piedmont to Inland Plain Areas of Hebei Province, North China Plain[J]. Journal of Groundwater Science and Engineering, 2025, 13(4): 434−448.

Investigation of landfill leakage points using geophysical exploration and machine learning methods

SONG Hong-Wei[1], XIA Fan[2], LI Hong-Chao[3], YANG Chao[4], GUI Jian-Ye[1]

(1. *Key Laboratory of Groundwater Science and Engineering under Ministry of Nature Resources*, *Institute of Hydrogeology and Environmental Geology*, *Chinese Academy of Geological Sciences* (*CAGS*), *Shijiazhuang* 050061, *China*; 2. *Hebei Provincial Laboratory of Water Environmental Science*, *Hebei Provincial Academy of Ecological and Environmental Sciences*, *Shijiazhuang* 050031, *China*; 3. *Hebei Provincial Geological Environment Monitoring Institute*, *Shijiazhuang* 050021, *China*; 4. *No. 5 Geological Team*, *Hebei Bureau of Geology and Minerals Resources Exploration*, *Tangshan* 063000, *China*)

Abstract: The compression and settlement of waste deposits in landfills may cause the deformation failure of leachate collection pipelines in municipal solid waste treatment facilities. This failure will further lead to the rupture of the impermeable layers and subsequent leakage of landfill leachates. Primary methods for monitoring damage to leachate impermeable layers include: laboratory chemical analysis of the pollutant levels of soil and water samples from landfills, and surface geophysical exploration. Building upon the above traditional environmental geological exploration methods, this study achieved effective prediction of landfill leachate leakage using geographic information system (GIS) technology combined with machine learning and influencing factor prediction. Specifically, the landfill area was divided into grid cells with resolution of 5 m × 5 m, which were then assigned corresponding spatial coordinates. A machine learning approach was employed to establish artificial neural network (ANN) models for predicting landfill leakage points. Based on a field investigation of a landfill in North China, 880 test samples and 220 validation samples were selected. The data obtained from these samples, including groundwater table depth, resistivity, polarizability, anomalies of seismic events in radar reflection waveforms, spatial relationships between seismic events and adjacent monitoring boreholes, and half-life information, were used as the input for the models. The output provided the leakage probabilities of all grid cells. Finally, the prediction results of two machine learning methods, the back-propagation (BP) and radial basis function (RBF) neural networks, were comparatively analyzed. The findings indicate that the BP neural network model showed higher prediction performance. The groundwater table depth, resistivity, and the relationship between resistivity and monitoring borehole positions served as the dominant factors influencing the seepage probability prediction of the impermeable layer. By superimposing the posterior probabilities of various influencing factors, the prediction model generated a classification map for leakage risk zones, achieving the objective of graded monitoring of leachate leakage risks within the landfill area.

Key words: artificial neural network (ANN); resistivity; landfill; geographic information system(GIS); leachate

(本文编辑: 叶佩)