

中文引用格式:卢佳乐,张念,牛萌萌,等. 基于 Stacking 集成学习的隧道突水危险预测模型[J]. 中国安全科学学报, 2025, 35(4): 137-144.

英文引用格式:LU Jiale, ZHANG Nian, NIU Mengmeng, et al. Hazard prediction model of tunnel water inrush based on stacking ensemble learning[J]. China Safety Science Journal, 2025, 35(4): 137-144.

基于 Stacking 集成学习的隧道突水危险预测模型*

卢佳乐^{1,2}, 张念^{**1,2}副教授, 牛萌萌¹, 万飞³研究员

(1 太原理工大学 土木工程学院, 山西 太原 030024; 2 北京交通大学 隧道及地下工程教育部工程研究中心, 北京 100044; 3 交通运输部公路科学研究所, 北京 100088)

中图分类号: X928.03

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2025.04.1398

基金项目: 中央引导地方科技发展资金资助(YDZJSX20231A021); 隧道及地下工程教育部工程研究中心(北京交通大学)开放研究基金资助(TUC2024-03); 中央级公益性科研院所基本科研业务费项目(2024-9006)。

【摘要】 为解决机器学习在隧道突水危险智能预测领域存在的模型较单一和预测精度不够理想等问题, 提出一种基于 Stacking 集成学习方法的预测模型。首先, 通过搜集 95 条隧道共计 232 组隧道突水灾害数据建立隧道突水灾害数据集, 并进行数据预处理; 然后, 选取 3 种基学习器和 2 种元学习器以不同组合方式训练出 8 组 Stacking 集成模型, 并筛选出 6 组较优的集成模型; 最后, 使用网格搜索调参并结合 5 折交叉验证超参数调优模型, 对比分析 6 组参数调优后的 Stacking 集成模型的预测结果, 选择出最优 Stacking 集成模型。结果表明: 采用 Stacking 集成学习方法改进最优单模型支持向量机(SVM)后得到 SVM+朴素贝叶斯(NB)+线性回归(LR)集成模型, 其精确率、召回率和 F_1 分数分别达到 0.94、0.91 和 0.92, 整体预测效果优于其他对比模型, 可准确预测隧道突水危险等级。

【关键词】 Stacking 集成学习; 隧道突水; 预测模型; 危险等级; 机器学习

Hazard prediction model of tunnel water inrush based on stacking ensemble learning

LU Jiale^{1,2}, ZHANG Nian^{1,2}, NIU Mengmeng¹, WAN Fei³

(1 College of Civil Engineering, Taiyuan University of Technology, Taiyuan Shanxi 030024, China;

2 Research Center of Tunneling and Underground Engineering of Ministry of Education, Beijing

Jiaotong University, Beijing 100044, China; 3 Research Institute of Highway Ministry of

Transport, Beijing 100088, China)

Abstract: In order to solve the problems that machine learning exists in the hazard intelligent prediction field of tunnel water inrush, such as relatively simple models and imperfect prediction accuracy, a prediction model based on the stacking ensemble learning was proposed. Firstly, the tunnel water inrush disaster dataset was established by collecting 232 groups of water inrush disaster data from 95 tunnels, and the data was preprocessed. Then, 3 base learners and 2 meta learners were selected to train 8 sets of

* 文章编号: 1003-3033(2025)04-0137-08; 收稿日期: 2024-11-15; 修稿日期: 2025-02-14

** 通信作者: 张念(1984—), 男, 湖北襄阳人, 博士, 副教授, 主要从事隧道及地下工程安全与算法优化方面的研究。E-mail: zhangnian@tyut.edu.cn。

stacking ensemble models in different combinations, and 6 sets of optimal ensemble models were selected. Finally, the optimal stacking ensemble model was selected by comparing and analyzing the prediction results of 6 groups of parameters optimized and stacking ensemble model with the grid search parameters and the 5-fold cross-validation hyperparameter optimization model. The results show that SVM (Support Vector Machine) + NB (Naive Bayes) + LR (Linear Regression) ensemble model is obtained after the optimal single model SVM is improved with the stacking ensemble learning method. Its accuracy, recall, and F_1 score are 0.94, 0.91, and 0.92, respectively. The overall prediction effect is better than that of other compative models, and it can accurately predict the hazard level of tunnel water intrush.

Keywords: Stacking ensemble learning; tunnel water intrush; prediction model; hazard level; machine learning

0 引言

隧道突水作为隧道施工阶段可能遭遇最严重的地质灾害之一,会造成严重的经济损失和人员伤亡。如果能在隧道设计阶段或施工早期阶段预测出突水灾害的危险性,对于后续采取相应的灾害防治措施具有重要的指导意义^[1-2]。

传统的隧道突水灾害预测方法,如层次分析法、综合评价法、专家评判法等,存在主观性强、适用性差和预测准确度低等问题,而机器学习法可避免上述问题。目前,诸多学者通过结合机器学习法智能预测隧道突水灾害,如王璐^[3]构建遗传算法-支持向量机(Support Vector Machine, SVM)模型,开展隧道涌水量预测,取得了一定成效;马天行等^[4]利用熵权法结合正态云模型预测煤层底板突水危险性,预测准确性有所提高;柏成浩^[5]通过建立决策树、SVM和随机森林(Random Forest, RF)3种机器学习模型,并基于Python语言开发出风险智能预测平

台,成功预测出特尔莫隧道的突水风险等级。现有文献在预测隧道突水灾害时,大部分只使用较为单一的传统机器学习模型,或简单模型的线性融合,导致模型整体预测精度不够理想。集成学习^[6-7]作为一种能在各种机器学习任务上提高准确率的强有力技术,组合多个学习器,共同完成学习任务,能达到比单个学习器更好的适用性能。

鉴于此,笔者拟提出基于堆栈法(Stacking)集成学习方法的预测模型,通过选取合适的机器学习模型,运用Stacking集成学习算法,集成不同类型的学习器来预测隧道突水危险等级,以期提升隧道施工智能化管控水平。

1 Stacking 算法

Stacking 算法最早由 WOLPERT^[8]于1992年提出,其使用不同类别的学习器进行第一轮学习,将得到的预测结果输入到第二轮学习器中再进行学习,得到最终预测结果。Stacking 集成学习流程如图1所示。

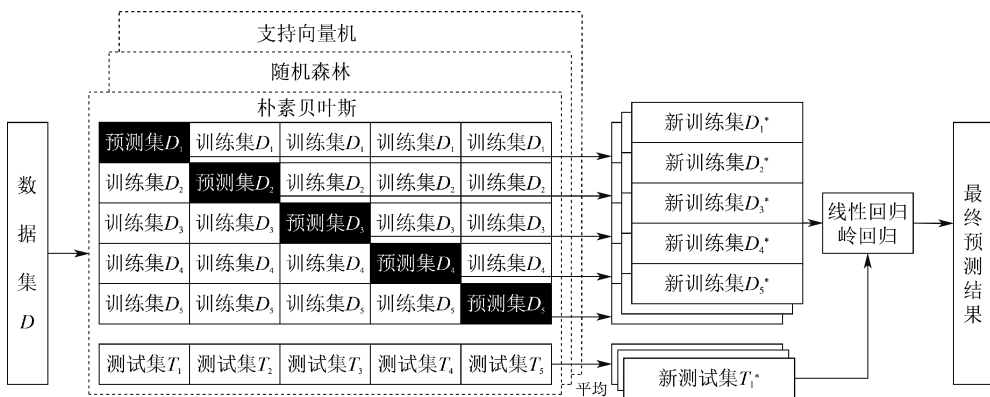


图1 Stacking 集成学习流程

Fig. 1 Flow chart of stacking ensemble learning

对于隧道突水危险预测而言,Stacking 算法的步骤如下:

1) 输入隧道突水灾害数据集 $D = \{(X_i, Y_i) | i = 1, 2, \dots, n\}$, 其中, X_i 为第 i 个样本

的特征向量, Y_i 为第 i 个样本对应的标签值。将数据集 D 平均分成 K 个子集 D_1, D_2, \dots, D_k 。一般情况下, 默认 $K = 5$ 。

2) 选择一种基学习器, 将数据集 D 中 $K - 1$ 份作为训练集, 剩下的 1 份作为预测集。利用 D_2, D_3, D_4, D_5 中样本建立模型, 分别预测预测集 D_1 和测试集 T_1 , 得到预测结果 1 和测试结果 1, 将预测结果 1 作为第二层元学习器的新训练集 T_i^* ($i = 1, 2, 3$), 以此类推得到 5 组新训练集 D_i^* ($i = 1, 2, \dots, 5$)。将得到的 5 组测试结果 T_i ($i = 1, 2, \dots, 5$) 取平均值作为第二层元学习器的新测试集 T_i^* ($i = 1, 2, 3$)。

3) 选择其他基学习器, 重复步骤 2), 分别得到其预测结果, 将新训练集 D_i^* ($i = 1, 2, \dots, 5$) 和新测试集 T_i^* ($i = 1, 2, 3$) 输入到第二层元学习器中进行训练, 得到的预测结果作为最终预测结果。

4) Stacking 集成学习模型训练完毕, 最终预测结果即为隧道突水危险预测结果, 实现综合学习器的学习能力。

2 突水数据预处理及模型评价指标

2.1 隧道突水数据集描述

通过中国知网和科学网, 以及 Google 学术、各省应急管理厅公布的新闻事故报告、百度文库和百度学术等, 统计与收集隧道突水灾害相关文献以及案例, 得到原始数据。主要记录已发生突水灾害的隧道案例, 数据集文件类型为 .xlsx, 共计 95 条隧道, 232 组断面数据。隧道突水灾害变量信息包括隧道概况、水文地质条件和施工扰动因素 3 个方面, 涵盖隧道突水灾害发生的孕灾环境和致灾因子, 对于后续选取特征变量以及模型的计算和优化有重要的指导意义。数据集中各危险等级下的样本分布情况如图 2 所示。




图 2 各危险等级下的样本分布

Fig. 2 Distribution of samples under each hazard level

由图 2 可知: 数据集中各危险等级 (I、II、III、IV) 下的样本个数依次为 17、17、52 和 146, 总计 232 个。其中, 危险等级 IV 下收集到的断面数据最多, 说明大多数隧道突水危险程度极高, 极易造成严重损失。危险等级 I 和 II 下的样本量, 与危险等级 III 和 IV 下的样本量差异较大, 为保证后续模型训练以及优化的准确性, 对数据集的预处理方法和模型选取及优化方法合理选用。

2.2 隧道突水数据预处理

预处理数据集, 主要包括数值化处理、离群值检测与替换、缺失数据补充以及数据集的标准化等, 具体操作过程及内容如下:

1) 统计分析选取特征变量。隧道突水的危险性主要由隧道所处的水文地质条件决定。通过统计数据集中各致灾因子的出现频率和总结学者们研究成果^[5,7], 得出地质条件中地层岩性、不良地质、岩层倾角和围岩级别影响较大; 水文条件中, 负地形面积比和水动力分带影响较大。因此, 决定选取 6 个致灾因子作为隧道突水危险预测模型所输入的特征变量。

2) 采用文献[9]中的隧道突水灾害相关分级标准数值化处理数据集。数据集中的定性变量与定量变量, 其数值化过程按照突水危险致灾因子划分标准所对应的数值取值即可。其中, 定性变量包括地层岩性、不良地质、水动力分带和围岩级别; 定量变量包括岩层倾角和负地形面积比。

3) 采用箱线图法检测数据集的离群值。对于同一变量在不同危险等级下的离群值替换过程, 定性变量取其当前危险等级下的数据众数作为替换值; 定量变量取当前危险等级下数据平均值作为替换值。

4) 对于数据集中缺失数据的补充方法, 采用同步步骤 3) 所述操作。

5) 数据集的标准化采用最大最小归一化公式^[5]进行处理。

预处理后, 得到标准化数据集, 见表 1, 由表 1 可知: 对于断面 2, 缺失变量为岩层倾角、负地形面积比和水动力分带, 依据数据预处理方法, 分别取其当前危险等级下的平均值、众数和众数进行补充, 经标准化处理后分别为 0.46、0.56 和 0.67; 对于断面 232, 缺失变量为负地形面积比, 依据上述数据预处理方法, 取其当前危险等级下的众数进行补充, 经标准化处理后分别为 0.52 和 0.52。对于未列出的其他断面, 采取上述方法完成原始数据集的预处理工作, 由此得到完整的标准化后的隧

表1 隧道突水灾害数据集
Table 1 Data set of tunnel water inrush

序号	预处理	地层岩性	不良地质	岩层倾向/ (°)	负地形 面积比	围岩级别	水动力 分带	危险等级
断面 1	原始数据集	白云岩、页岩、泥岩	F11 断层主断裂带	58~60	低中山区	V 级	暗河管道水	IV 级
	数值化	3	4	59	50	4	4	4
	标准化	0.67	1.00	0.66	0.53	1.00	1.00	4
断面 2	原始数据集	灰岩	褶皱翼部	—	—	V 级	—	III 级
	数值化	4	3	—	—	4	—	3
	标准化	1.00	0.67	0.46	0.56	1.00	0.67	3
∴	∴	∴	∴	∴	∴	∴	∴	∴
断面 232	原始数据集	石英砂岩	背斜核部	60°	—	II 级	交替带	IV 级
	数值化	1	4	60	—	1	3	4
	标准化	1.00	1.00	0.67	0.52	0.00	0.67	4

道突水灾害数据集。

2.3 隧道突水危险预测分类评价指标

隧道突水危险预测在机器学习中属于分类问题,拟用的评价指标^[10]有精确率 P 、召回率 R 和 F_1 分数。

3 突水危险预测模型的建立与对比

选用 4 种不同类型的机器学习模型,分别为朴素贝叶斯^[11] (Naive Bayes, NB)、RF^[12]、SVM^[13] 和自适应算法^[14] (Adaptive Boosting, AB)。隧道突水危险预测流程如图 3 所示。

3.1 单模型构建与分析

为提高 Stacking 集成模型的分类预测效果,在进行 Stacking 模型组合预测隧道突水危险等级前,先训练选取的单模型,进行超参数调优,并对比参数调优后的单模型分类预测效果。

3.1.1 超参数调优前

将数据集按 8 : 2 比例划分为训练集和测试集,得到 185 份训练集和 47 份测试集。输入数据,训练 NB、RF、SVM 和 AB 这 4 种模型,得到隧道突水危险预测结果如图 4 所示。

由图 4 可知:超参数调优前各单模型的 P 、 R 和 F_1 值差异较大。SVM 各值较其他 3 种单模型最高;AB 模型各值最低,在未进行超参数调优的情况下表现较差;NB 模型和 RF 模型预测性能相近,但 NB 模型的预测精确性稍好。综上所述,在未进行超参数调优的情况下,SVM 在此次预测的所有单模型中表现最好。

3.1.2 超参数调优后

4 种模型中,NB 模型不需要进行模型训练,也

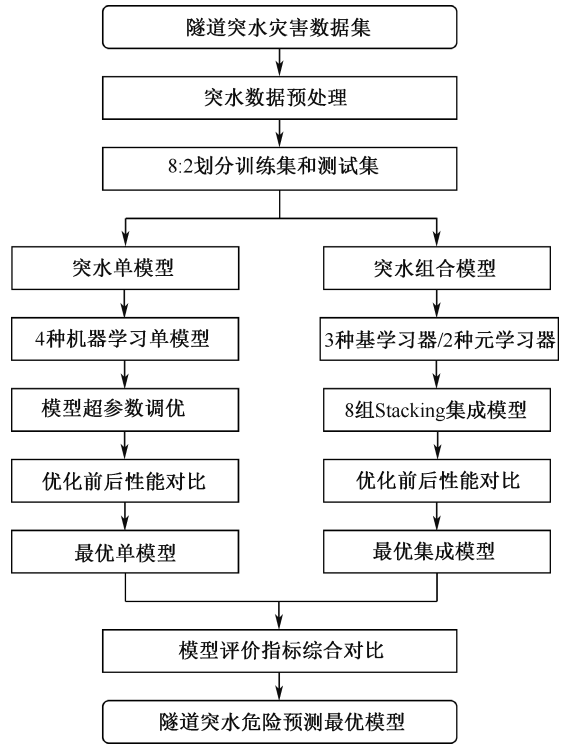


图3 突水危险预测流程

Fig. 3 Water inrush hazard prediction process

无需调整超参数,其余 3 种模型均采用网格搜索结合 K 折交叉验证 ($K=5$) 进行超参数调优。RF、SVM 和 AB 这 3 种模型的最佳超参数取值见表 2。其中,对于 RF 模型,max_depth 为决策树的最大深度,控制着树的复杂程度;n_estimators 代表决策树的数量。对于 SVM 模型,C 为惩罚系数,表示模型对误差的容忍程度。gamma 代表核函数的宽度,决定数据点之间影响程度的衰减速度;kernel 表示核函数,通常用于处理非线性数据拟合;RBF 代表径向基函数。对于 AB 模型,learning_rate 为学习率,表示模




图 4 超参数调优前单模型各评价指标

Fig. 4 Evaluation metrics of each single model before hyper-parameters optimization

型更新过程所采用的梯度下降或提升的方向和幅度。

表 2 3 种模型的最佳超参数取值

Table 2 Optimal hyper-parameters for three models

模型	超参数选取范围	最佳超参数
RF	max_depth:[1-10] n_estimators:[1-10]	max_depth:[8] n_estimators:[10]
SVM	C:[0.1, 1, 10, 100] gamma:[0.001, 0.01, 0.1, 1] kernel:[linear, RBF, poly]	C:[1] gamma:[1] kernel:[RBF]
AB	learning_rate:[0.01, 0.1, 1] n_estimators:[50, 100, 150]	learning_rate:[0.1] n_estimators:[50]

输入 3 种模型的最佳超参数并重新训练模型,得到各单模型优化后(除 NB 外)的 P、R 和 F₁ 值。表 3 为超参数调优前后的单模型各评价指标对比。

表 3 优化前后单模型各评价指标对比

Table 3 Comparison of each evaluation metric of single model before and after optimization

模型		RF	SVM	AB
优化前	P	0.81	0.91	0.73
	R	0.81	0.89	0.70
	F ₁	0.80	0.90	0.70
优化后	P	0.84 ↑	0.83 ↓	0.80 ↑
	R	0.79 ↓	0.81 ↓	0.79 ↑
	F ₁	0.80 △	0.81 ↓	0.79 ↑

注:△表示优化后值不变。

由表 3 可知:经超参数调优,RF 模型精确性提高,全面性下降,F₁ 值不变,可知 RF 模型经超参数调优后性能无明显变化;SVM 模型总体性能下降,推测原因为数据量较少,模型存在过拟合风险;AB 模型性能有所提高,但其各值仍较其他模型低。综上所述,此次隧道突水危险预测单模型优化前后模型性能表现最好的为超参数优化前的 SVM 模型。

3.2 Stacking 模型构建与分析

3.2.1 基学习器的选择

由上述分析可知:超参数优化前的 SVM 模型在 4 种单模型中表现最好,AB 模型调优前后的各评价指标值均较低,其精确性和全面性较差,可能不适用于此次预测,故排除。因此,选取 NB、RF 和 SVM 模型作为此次预测的 Stacking 集成模型的第一层基学习器。

3.2.2 元学习器的选择

为降低模型的过拟合风险,第二层的元学习器选择较为简单的模型。线性回归 (Linear Regression, LR) 可配合 L1、L2 正则化进一步防止模型过拟合,选为第一种元学习器;另选择泛化能力较好,可配合 L2 正则化的岭回归作为第 2 种元学习器加以对比。同样,为得到学习能力较好的元学习器,对 LR 和岭回归 (Ridge) 采取超参数调优方法,2 种元学习器的最佳超参数取值见表 4。其中,对于 LR 模型,Penalty 为正则化项,用于控制模型的复杂度;Solver 代表所用的优化策略。对于 Ridge 模型,alpha 为正则化参数。

表 4 2 种元学习器的最佳超参数取值

Table 4 Optimal hyper-parameters for two meta learners

模型	超参数选取范围	最佳超参数
LR	C:[0.1, 1, 10, 100] Penalty:[L1, L2] Solver:[liblinear, saga]	C:[1] Penalty:[L1] Solver:[saga]
Ridge	alpha:[0.01, 0.1, 1.0, 10.0]	alpha:[0.1]

3.2.3 模型组合方式

设计试验观测不同组合方式下的 Stacking 集成模型的分类预测效果。以不同组合方式对比 3 种基学习器和 2 种元学习器,共计 8 组集成模型组合。选取的 8 组 Stacking 集成模型组合及命名见表 5。

表 5 8 组 Stacking 集成模型

Table 5 8 groups of Stacking ensemble models

组合	模型名称	基学习器	元学习器
1	RNL	RF+NB	LR
2	RNR		Ridge
3	RSL	RF+SVM	LR
4	RSR		Ridge
5	SNL	SVM+NB	LR
6	SNR		Ridge
7	RNSL	RF+NB+SVM	LR
8	RNSR		Ridge

3.2.4 较优 Stacking 集成模型筛选

将数据集按 8 : 2 比例划分为训练集和测试集。

输入数据,训练 8 组 Stacking 集成模型,得到隧道突水危险预测结果,如图 5 所示。




图 5 8 组 Stacking 集成模型评价指标对比

Fig. 5 Comparison of evaluation metrics of 8 groups of Stacking ensemble models

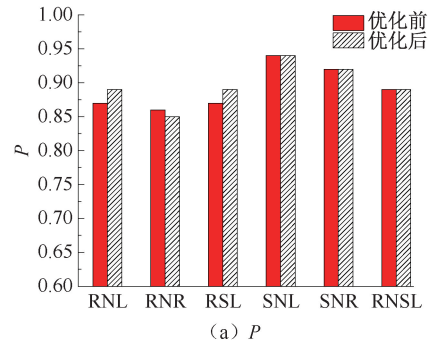
由图 5 可知:不同组合方式下的 Stacking 集成模型的预测效果差异显著。其中,SNL 模型各值较其他集成模型得分最高,表明 SNL 模型预测更精确、误判漏判更少;RSR 模型各值较其他集成模型最低;RNL 和 RNR 模型的各值较 NB 和 RF 单模型变化不大;RNSL 模型各值较最优单模型 SVM 的低,预测效果不够理想;RNSR 模型各值较单模型和其他集成模型最低。综上所述,在未进行超参数优化的条件下,SNL 模型为此次预测的所有集成模型中的较优模型。且 Stacking 集成模型中,第一层的基学习器模型组合并非复杂程度越高,预测效果就越好,基学习器和元学习器的正确选择与组合才是提升模型性能的关键。

RSR 和 RNSR 模型在超参数调优前的模型性能较其他 6 组集成模型差距大,决定舍弃。仅对优化前集成模型的 P、R 和 F₁ 值均在 0.80 以上的 6 组集成模型输入最佳超参数,并进行模型训练,得到超参数优化前后 6 组 Stacking 集成模型的评价指标对比,如图 6 所示。

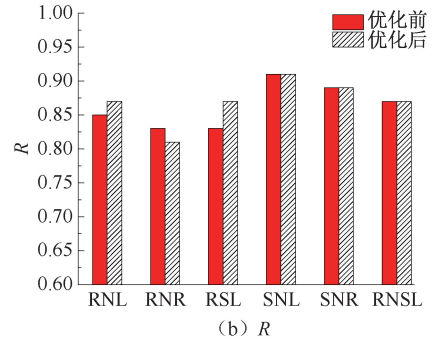
由图 6 可知:经超参数调优后,SNL 模型各值无明显提高,但其值依旧较其他 6 组集成模型最高;RNL 和 RSL 模型整体提升较小;RNR 模型经优化后略有下降。此外,SNR 和 RNSL 模型优化前后各值未发生改变,表明模型已接近最好表现。综上所述,在超参数优化前后的所有集成模型中,SNL 模型为此次隧道突水危险预测模型中的最优 Stacking 集成模型。

3.3 综合对比分析

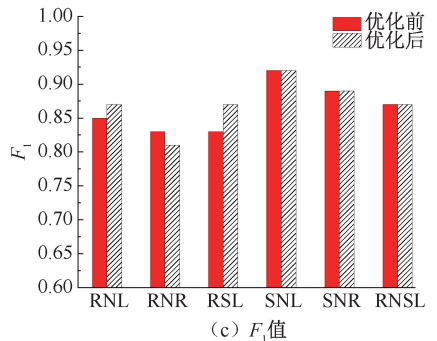
由对比分析可知:此次预测中最优单模型为



(a) P



(b) R



(c) F₁值

图 6 优化前后 6 组 Stacking 集成模型评价指标对比
Fig. 6 Comparison of evaluation metrics of 6 groups of Stacking ensemble models before and after optimization

SVM,最优 Stacking 集成模型为 SNL。为得到最优隧道突水危险预测模型,还需要更深入地对比 2 个模型,主要包括评价指标、混淆矩阵、被试工作特征曲线(Receiver Operating Characteristic Curve, ROC)。

图 7 为 SVM 和 SNL 模型的评价指标对比,由图 7 可知:SVM 作为单模型中最优模型,但其各值与 SNL 集成模型相比,SNL 模型的值均更高,表明在此次隧道突水危险预测的所有样本中,SNL 集成模型对于样本的预测精确性更高。

图 8 为 2 个模型的混淆矩阵对比,由图 8 可知:在测试集样本总数为 47 份的条件下,SVM 与 SNL 模型的预测正确个数分别为 42 和 43,预测准确率分别为 89.36% 和 91.49%。SNL 集成模型在危险等级 I、II 和 III 的样本下表现最好,全部预测正确;但在危险等级为 IV 下与 SVM 模型相比,多将 1 份




图 7 SVM 与 SNL 评价指标对比

Fig. 7 Comparison of evaluation metrics for SVM and SNL






图 8 SVM 与 SNL 的混淆矩阵对比

Fig. 8 Confusion matrix comparison of SVM and SNL



(a) SVM模型



(b) SNL模型

图 9 SVM 与 SNL 的 ROC 曲线对比

Fig. 9 ROC curve comparison of SVM and SNL

真实危险等级为 IV 的样本预测为危险等级 II,防治措施可能不足。导致这类预测错误的主要原因是数据集样本量欠缺,且样本分布不均衡。期待在数据集更完善、模型更优化的情况下改善此类预测错误。

图 9 为 2 个模型的 ROC 曲线对比,由图 9 可知:2 个模型在此次预测中性能均较好,但 SNL 集成模型的性能更好。其中,SNL 集成模型在危险等级 I、III 和 IV 下的预测效果明显优于 SVM 模型,且在危险等级 I 下的曲线下面积(Area Under the Curve, AUC)值达到 1.000,即第一临界点,完美分类,样本无误判无漏判;而 SVM 模型仅在危险等级 II 下的 AUC 值高出 SNL 组合模型 0.006,差距不大。此外,SVM 模型过拟合风险较 SNL 集成模型更高,第二临界点数有 4 个,分别为危险等级 II 下 1 个,危险等级 IV 下 3 个;而 SNL 集成模型仅在危险等级 II 下存在 1 个第二临界点,模型过拟合风险远小于 SVM 模型。

综上所述,SNL 集成模型综合性能优于 SVM 模型,模型优化更合理,预测更准确。可知:以 SVM 和 NB 作为基学习器,LR 作为元学习器的 Stacking 集成模型 SNL 是此次研究中的最优预测模型,同时,说明采用 Stacking 集成学习方法改进最优单模型 SVM 并进行预测是切实可行的。

4 结 论

1) 确定了 4 个机器学习模型的 6 个输入变量,分别为地层岩性、不良地质、岩层倾角、负地形面积比、围岩级别和水动力分带;预处理这些数据,并训练 4 组单模型和 8 组 Stacking 集成模型。

2) 筛选得到预测最优单模型 SVM 和最优 Stacking 集成模型 SNL,并进行对比分析,SNL 集成模型是此次隧道突水危险预测的最优模型。

3) 基于 Stacking 集成学习的 SNL 模型在预测隧道突水危险等级时,综合性能较其他模型最好,模型更加合理,对于高风险等级的隧道突水灾害适用性更强。采用 Stacking 集成学习方法对最优单模型 SVM 的改进是成功的,可实现准确预测隧道突水危险等级。

4) 鉴于模型训练样本较少,且样本分布不够均衡,导致模型在低等级样本下的预测情况较差。后续工作如果能收集到更多更全面的隧道突水信息,并结合 Python 语言开发出隧道突水智能预测系统,则可进一步提升隧道施工智能化管控水平。

参 考 文 献

- [1] 白明洲,许兆义,王连俊,等. 复杂岩溶地区隧道施工突水地质灾害研究[J]. 中国安全科学学报, 2006, 16(1): 114-118.
BAI Mingzhou, XU Zhaoyi, WANG Lianjun, et al. Study on water outburst geological disaster of tunnel construction at complicated karst zone[J]. China Safety Science Journal, 2006, 16(1): 114-118.
- [2] XUE Yiguo, KONG Fanmeng, LI Shucui, et al. Water and mud inrush hazard in underground engineering: genesis, evolution and prevention[J]. Tunnelling and Underground Space Technology, 2021, 114: DOI: 10.1016/J. TUST. 2021. 103987.
- [3] 王璐. 基于遗传算法和支持向量机的西南岩溶越岭隧道涌水量预测[D]. 成都:成都理工大学, 2019.
WANG Lu. Prediction of water inflow in southwest karst crossing-mountain tunnel based on genetic algorithm and support vector machine[D]. Chengdu: Chengdu University of Technology, 2019.
- [4] 马天行,林允,周晓斌,等. 煤层底板突水危险性预测的熵权-正态云模型[J]. 中国安全科学学报, 2022, 32(增1): 171-177.
MA Tianxing, LIN Yun, ZHOU Xiaobin, et al. Entropy weight-normal cloud model for water inrush risk prediction of coal seam floor[J]. China Safety Science Journal, 2022, 32(S1): 171-177.
- [5] 柏成浩. 基于机器学习的岩溶隧道突水突泥灾害风险智能预测方法研究[D]. 济南:山东大学, 2021.
BO Chenghao. Research on intelligent prediction method of hazard risk of water and mud inrush in karst tunnel based on machine learning[D]. Jinan: Shandong University, 2021.
- [6] 周志华. 机器学习[M]. 北京:清华大学出版社, 2016: 171-190.
- [7] GUO Wangda, ZHANG Jinxi, MURTAZA M, et al. An ensemble learning with sequential model-based optimization approach for pavement roughness estimation using smartphone sensor data[J]. Construction and Building Materials, 2023, 406: DOI: 10.1016/J. CONBUILDMAT. 2023. 133293.
- [8] WOLPERT D H. Stacked generalization[J]. Neural Networks, 1992, 5(2): 241-259.
- [9] ZHANG Nian, NIU Mengmeng, WAN Fei, et al. Hazard prediction of water inrush in water-rich tunnels based on random forest algorithm[J]. Applied Sciences, 2024, 14(2): DOI: 10.3390/APP14020867.
- [10] YAN Tao, SHEN Shuilong, ZHOU Annan, et al. Prediction of geological characteristics from shield operational parameters by integrating grid search and K-fold cross validation into stacking classification algorithm[J]. Journal of Rock Mechanics and Geotechnical Engineering: English Edition, 2022, 14(4): 1292-1303.
- [11] XU Ying. Research on cooling load estimation through optimal hybrid models based on naive bayes[J]. Journal of Engineering and Applied Science, 2024, 71(1): DOI: 10.1186/S44147-024-00396-9.
- [12] LI Yanlong, YIN Qiaogang, ZHANG Ye, et al. Deformation prediction model of concrete face rockfill dams based on an improved random forest model[J]. Water Science and Engineering, 2023, 16(4): 390-398.
- [13] NIE Xiaobo, LI Haibin. Structural reliability analysis based on support vector machine and dual neural network direct integration method[J]. Journal of Donghua University: English Edition, 2021, 38(1): 51-56.
- [14] SOHEILA K, CHENG Bin, JOSE T. Structural performance assessment of GFRP elastic gridshells by machine learning interpretability methods[J]. Frontiers of Structural and Civil Engineering, 2022, 16(10): 1249-1266.

作者简介: 卢佳乐 (1998—),男,山西运城人,硕士研究生,主要研究方向为隧道工程安全与算法优化。E-mail: lujiale0477@link.tyut.edu.cn。

