

基于可解释性集成学习的 RIOHTrack 车辙 预测模型及驱动因素研究*

李 敏¹, 李卓轩^{2,3}, 时欣利^{1,2}, 曹进德^{2,3}

- (1. 东南大学 网络空间安全学院, 南京 210096;
2. 综合交通运输理论交通运输行业重点实验室(南京现代综合交通实验室), 南京 211100;
3. 东南大学 数学学院, 南京 211189)

(我刊编委曹进德来稿)

摘要: 交通基础设施是现代社会经济发展的基础, 沥青路面作为其中的关键组成部分, 扮演着重要角色。准确预测沥青路面状况对指导路面养护工作具有重要意义。车辙作为评价沥青路面健康状况的一项重要指标, 现有的沥青路面状况预测模型主要基于力学经验模型或机器学习技术, 然而, 这些方法缺乏可解释性, 无法提供相关信息来说明输入特征对车辙的影响程度。该研究通过建立可解释性集成学习框架(FI-EL-SHAP)(其中, FI 模块通过熵权法和 Pareto 分析筛选特征, EL 模块评估不同的模型性能, 并选出最优的模型, SHAP 模块对输入特征和模型输出之间的关系进行可视化分析), 揭示了不同特征对模型预测结果的影响。该研究在保证模型精确度的同时实现了对车辙形成机理的定量解析。

关键词: 沥青路面; 车辙; 集成学习; 可解释性

中图分类号: O357.41 文献标志码: A DOI: 10.21656/1000-0887.450066

Research on Driving Factors of the RIOHTrack Rutting Prediction Model Based on Interpretable Ensemble Learning

LI Min¹, LI Zhuoxuan^{2,3}, SHI Xinli^{1,2}, CAO Jinde^{2,3}

- (1. School of Cyber Science and Engineering, Southeast University, Nanjing 210096, P.R.China;
2. Key Laboratory of Transport Industry of Comprehensive Transportation Theory (Nanjing Modern Multimodal Transportation Laboratory), Nanjing 211100, P.R.China;
3. School of Mathematics, Southeast University, Nanjing 211189, P.R.China)

(Contributed by CAO Jinde, M.AMM Editorial Board)

Abstract: The transport infrastructure is the foundation of modern social and economic development, where the asphalt pavement plays an important role as a key component. Accurate prediction of asphalt pavement con-

* 收稿日期: 2024-03-12; 修订日期: 2024-11-28

基金项目: 国家重点研发计划(2020YFA0714300)

作者简介: 李敏(1999—), 男, 硕士生(E-mail: limintara@163.com);

李卓轩(1997—), 男, 博士生(E-mail: 230229338@seu.edu.cn);

时欣利(1988—), 男, 副教授(通讯作者, E-mail: xinli_shi@seu.edu.cn);

曹进德(1963—), 男, 教授(E-mail: jdcao@seu.edu.cn).

引用格式: 李敏, 李卓轩, 时欣利, 曹进德. 基于可解释性集成学习的 RIOHTrack 车辙预测模型及驱动因素研究[J]. 应用数学和力学, 2025, 46(1): 92-104.

ditions is of great significance to guide pavement maintenance work. Rutting is an important indicator for evaluating the health condition of asphalt pavement. Existing asphalt pavement condition prediction models are mainly based on mechanical experience models or machine learning technologies. However, these methods lack interpretability and cannot provide relevant information on the extent to which the input features affect rutting. Herein, an interpretable integrated learning framework (FI-EL-SHAP) was established, in which the FI module filters features with the entropy weight method and the Pareto analysis, the EL module evaluates the performances of different models and selects the optimal model, and the SHAP module performs visual analysis on the relationship between input features and model outputs to reveal the impacts of different features on model prediction results. This study realizes a quantitative analysis of the rut formation mechanism while ensuring the model accuracy.

Key words: asphalt pavement; rutting; ensemble learning; interpretability

0 引 言

交通基础设施是经济发展的基础,为现代社会提供了巨大的流动性^[1],路面作为交通基础设施的重要组成部分,对道路的安全性和可用性起着至关重要的作用.我国的铺面公路网络广泛,长度已达到 530 万 km,众多旅客和货物通过铺面公路运输.然而,随着时间的推移,路面会因为老化、交通负荷增加、恶劣天气等原因而逐渐恶化.为了保持路面处于最佳状态,必须对其进行定期维护和及时修复.有效地实施维护和修复计划,可以延长路面的使用寿命,并确保其处于安全和良好的状态.路面管理系统的核心关注点之一是如何进行及时和最佳的维护和修复处理.由于维护和修复活动通常需要投入大量的成本^[2-5],因此,精细的规划显得尤为重要.优化维护和修复计划的关键在于能够准确预测路面的未来状况.路面状况指标能够量化路面性能的衰退程度和剩余寿命^[6],可为制定更具针对性的维护和修复计划提供依据.

作为评价沥青路面结构承载能力及路面健康状况的一项重要指标,车辙对检测和评价路面结构性能至关重要,本研究选择车辙作为表征路面状况的指标.目前对于车辙深度驱动因素的研究主要有两种方法,分别是力学经验模型和机器学习.力学经验模型基于力学原理和工程经验,通过建立数学表达式来描述车辙深度的演变过程,如 Hossain 等^[7]通过基于垂直应变模型,将影响因素的影响转化为垂直应变,开发了车辙预测函数;Li 等^[8]提出了基于路面温度、有效荷载和路面层应力的车辙模型.该力学经验模型是一个指数函数,能够大致地反映特定情况下车辙的实际恶化.虽然这些力学经验模型的预测性能相对可以接受,但它们的实用性是有限的,忽略了复杂的环境和上下文相关变量,导致无法推广到不同的条件下.机器学习具有可以处理大量数据的能力.机器学习算法可以分为三类:监督学习、无监督学习和半监督学习.许多监督学习模型已被用于预测路面性能,其中人工神经网络(artificial neural network, ANN)是备受关注的一种方法^[9-12],它由多个相互连接的神经元层组成,通过学习和调整连接权重,能够对输入数据进行模式识别和复杂任务处理.由于神经网络的多层结构和权重调整机制,它能够学习和捕捉非线性关系,使其在非线性场景中表现优异^[13-17].Simpson 等^[18]和 Shafabakhsh 等^[19]将车辙的多个特征变量引入人工神经网络,包括沥青混凝土厚度、基层厚度和孔隙率,成功地实现了对车辙的预测.与传统的多元线性回归(multiple linear regression, MLR)模型相比,人工神经网络在精度上取得了显著的提升.成熟的监督学习模型可以胜任路面性能的预测任务,如 Choi 等^[3]提出了基于循环神经网络(recurrent neural network, RNN)的长短期记忆模型,使用来自韩国道路路面监测数据库的输入数据预测包括车辙在内的多个指标;Abdelaziz 等^[20]使用人工神经网络基于 506 个路段的 2 439 个观测值,预测了不同路面类型的国际平整度指数(international roughness index, IRI).这些方法通常涉及多个指标来获得准确的结果,包括车辙和 IRI 等.

尽管在路面性能预测方面具有可接受的结果,但机器学习模型是黑盒模型,难以解释而且无法提供相关信息来说明输入特征对输出变量的影响程度.为了解决这一问题,本研究采用了集成学习(ensemble learning, EL)方法,其核心思想是通过结合多个弱学习器的预测结果,这些弱学习器可以是同质的,也可以是异质的.EL 的目标是通过整合各个模型的优点^[9],弥补单一模型的缺陷,从而提高整体性能.EL 的核心优势之一是其提供的可解释性,通过结合 SHAP 值来提供相关信息来说明输入特征对输出变量的影响程度.

综上所述,为了给道路管理者数据收集工作提供有效的信息^[21],从而不断改进调查和分析,本研究使用EL方法,建立了一个可解释性集成学习框架(feature importance-ensemble learning-SHAP, FI-EL-SHAP),框架由3个模块构成,分别运用熵权法和 Pareto 分析完成了特征筛选的特征重要性(feature importance, FI)模块,通过多个评价指标选出了性能最优模型的EL模块和负责可视化分析并挖掘车辙的驱动因素,提高了模型可解释性的SHAP模块.本研究通过19种沥青路面结构,验证了该方法的可行性.相比传统的机器学习方法,本研究在保证模型具有良好精确度的同时也具有良好的可解释性,为研究人员理解路面形变的机制提供了关键线索,也为路面维护决策提供了实质性的支持.

1 数据准备

研究数据来自位于北京公路交通试验场的全尺寸交通运输部路面试验环路项目.该项目旨在打造全球首个以长寿命路面服役性能验证为目标的宽刚度域基层沥青路面试验环路,被命名为RIOHTrack环道. RIOH指的是交通运输部公路科学研究院(Research Institute of Highway Ministry of Transport),环道的建设和运营管理由公路所负责,因此按照国际惯例命名为RIOHTrack环道^[22].RIOHTrack环道采用封闭式的拖挂卡车加载模式,明确了以5000万次累计标准轴载的加载总目标,每天日间连续运行12h,平均车速为40~50 km/h^[23],以收集宽刚度域基层路面多元服役性能数据.环道采用封闭式、拖挂卡车加载,它有一条2.038 km长的全尺寸现场加速路面测试跑道,设置双向二车道.全尺寸环路包括25种类型的沥青路面结构^[24],路面结构的布局如图1所示.

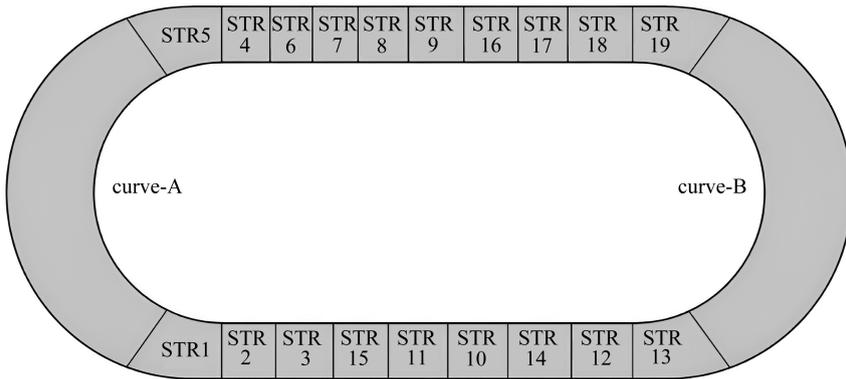


图1 路面布局

Fig. 1 The pavement layout

在试验环道上设置了19种主要的试验路面结构,以研究和比较具有不同结构刚度组合的沥青路面结构和材料的长期性能和演变.车辙作为沥青路面的关键服役性能之一,其影响因素包括路面结构材料参数、沥青层厚度以及温度等,但不同的因素与车辙的相关性大小也不同.表1展示了路面结构STR4的数据集,数据自2016年11月30日开始采集,每12d为一周期,共采集了110个周期,包含了轴载次数、平均气温、荷载水平、弯沉盆面积、中心点弯沉、IRI和激光纹理深度共计7个特征和1个本研究的预测指标车辙.

表1 STR4数据集

Table 1 The STR4 dataset

axle load	average temperature/ $^{\circ}\text{C}$	load level /kN	deflection area / mm^2	center deflection /(0.01 mm)	IRI /(m/km)	laser texture depth/ mm	rut depth /(0.1 mm)
4.45	3.8	56.47	63.75	5.11	1.88	1.01	15.56
5.02	1.2	56.47	64.51	5.34	1.82	1.03	15.85
5.47	0.9	56.47	63.58	5.09	1.87	0.99	14.95
6.92	-0.2	48.09	57.61	4.63	1.93	0.82	35.20
6.96	3.8	48.09	67.59	5.55	1.98	0.89	32.62
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
7.74	15.9	48.09	77.68	6.76	1.99	0.90	63.83

2 FI-EL-SHAP

FI-EL-SHAP 通过结合 FI 模块、EL 模块和负责可解释性的 SHAP 模块,如图 2 所示.通过评估沥青路面车辙深度影响因素,实现路面的未来状况预测并优化模型的可解释性.FI 模块通过 FI 筛选特征并结合客观赋权法(即熵权法)和 Pareto 分析,优化模型的数据一致性并提升模型的准确性,FI 模块的输出结果作为 EL 模块的输入,EL 模块应用 EL 模型来训练,并评估模型的准确性,同时结合 SHAP 模块来评估模型的可解释性,继而筛选出最佳模型.SHAP 模块计算各驱动因素对车辙深度的贡献,以及各驱动因素的交互影响,旨在为沥青路面养护工作提供理论依据.

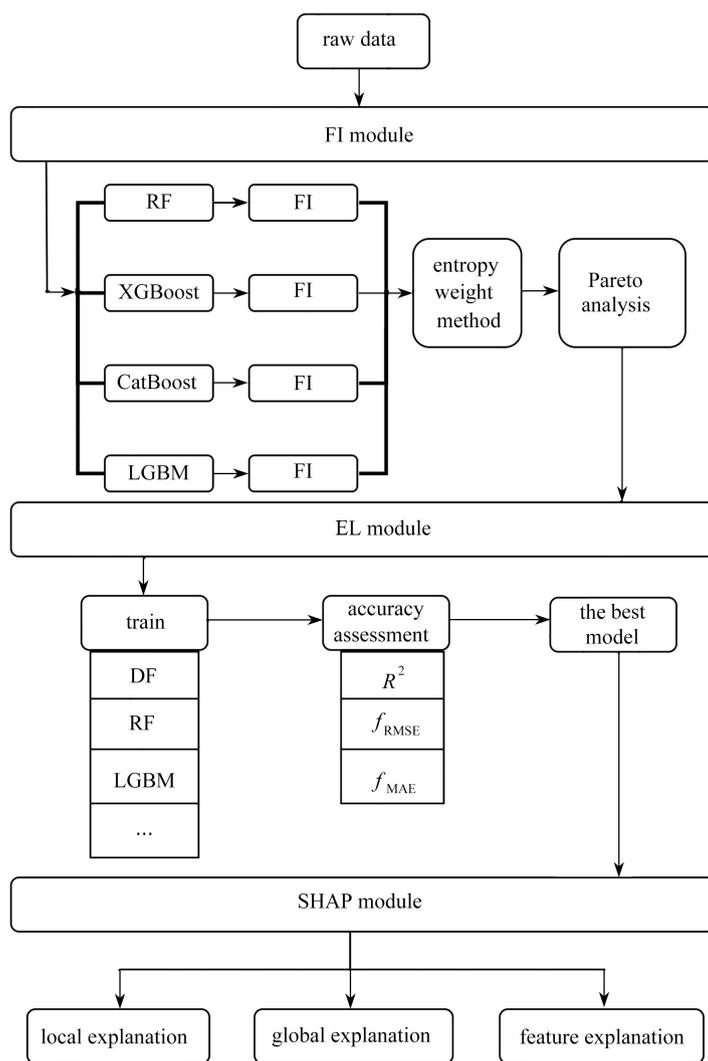


图 2 技术路线

Fig. 2 The technology roadmap

2.1 FI 模块

特征选择对于 EL 和结果分析至关重要.特征选择通过消除冗余特征来降低维度,同时可以防止过拟合,使得模型的准确性增加,模型的运行时间减少,为模型构建和进一步研究奠定基础,最终获得最佳模型^[25-27].

2.1.1 数据标准化

由于所收集的相关变量值水平差异较大,如果不进行相关处理直接用原始值进行分析,值较高的变量的作用会被放大,值较低的变量的作用则会减弱.为了消除这种影响,对原始数据进行标准化.标准化是指将数据缩放到一个小的特定区间,去除数据的单位限制,并将其转换为纯无量纲值,以便不同单位或大小的变量

可以比较和权衡,标准化公式如下:

$$Z = \frac{X - X_{\text{mean}}}{\sigma(X)}, \quad (1)$$

式中 Z 是标准化数据, X 是原始数据, X_{mean} 是原始数据的均值, $\sigma(X)$ 是原始数据的标准差。

2.1.2 特征选择

本研究通过 FI 来选择特征, EL 算法可以度量每个特征对算法预测值的贡献程度, 本研究选择了 4 种 EL 算法, 分别是随机森林 (random forest, RF)、XGBoost (eXtreme gradient boosting)、CatBoost (categorical boosting) 和 LGBM (light gradient boosting machine), 并将标准化后的数据输入, 每个算法都将输出各自的 FI, 但由于算法不一致, 输出的 FI 可能也不一致, 因此引入集成赋权, 通过客观赋权法中的熵权法^[28-29] 得出加权后具有一致性的 FI 结果。

式(2)显示了计算第 j 个算法的信息熵公式:

$$E_j = -\frac{1}{\ln m} \sum_{i=1}^m r_{ij} \ln r_{ij}, \quad (2)$$

其中 r_{ij} 表示第 j 个算法的第 i 个特征的 FI 的值, m 表示原始特征的数量。

通过式(2)得到各算法的信息熵, 再通过式(3)可以得到各算法的权重:

$$W_j = \frac{1 - E_j}{\sum_{j=1}^n (1 - E_j)}, \quad (3)$$

其中 W_j 表示第 j 个算法的权重, n 表示用来输出 FI 算法的数量。

最终的算法 FI 结果可通过式(4)加权得到:

$$F = \sum_{j=1}^n r_j W_j, \quad (4)$$

并基于此结果运用 Pareto 分析^[30] 选取 FI 排序前 80% 的特征, 达到特征选择的目的。

2.2 EL 模块

2.2.1 模型训练

在建立 EL 模型之前, 需要将数据集划分为两组, 70% 的数据作为模型训练的训练集, 30% 的数据作为测试集来检查最终模型的执行情况. EL 模型超参数的选择对模型的性能起着重要作用, 本研究使用网络搜索方法来优化模型的超参数. 网络搜索方法是一种详尽的搜索方法, 使用 10 折交叉验证优化模型的参数. 这个 10 折交叉验证的方法把数据集分成 10 个互相排斥的子集, 每个训练分层抽样以其中的 9 个子集作为训练集, 其余的子集作为测试集, 这样就可以得到 10 个不同的数据集. 将这些数据用于 10 次训练和测试, 最终结果是 10 次训练和测试的平均值. 使用 10 折交叉验证方法可以减少模型的过度拟合, 提高模型的泛化性能^[31].

采用网格搜索方法对所开发 EL 模型的超参数进行优化, 首先确定模型每个超参数的值范围, 然后生成多个超参数组合. 接下来, 将这些超参数组合应用于模型, 并通过训练集上的 10 折交叉验证进行评估. 最后, 比较了每个超参数组合的十个评估的平均值, 确定了最佳组合. 本研究选择决定系数 R^2 作为超参数优化的主要评价指标, 以选择性能最佳的超参数组合。

2.2.2 模型精确性评估

本研究选择三个指标来衡量模型的预测结果和评估方法效率, 分别是: 决定系数 R^2 、均方根误差 f_{RMSE} 和平均绝对误差 f_{MAE} . 用于计算这些指标的表达式分别在式(5)–(7)中提供:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2}, \quad (5)$$

$$f_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}, \quad (6)$$

$$f_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|, \quad (7)$$

其中 y_i 表示第 i 个样本的真实值, \hat{y}_i 表示预测值, \bar{y} 表示真实值的平均值, N 表示数据集的大小, 详细地说明: f_{RMSE} 表示真实值和预测值之间的差异, 即 f_{RMSE} 值越小, 平均差异越小; R^2 显示了模型的拟合程度; f_{MAE} 描述真实值和预测值之间误差的平均大小. 如果 f_{RMSE} 和 f_{MAE} 的值接近于 0, R^2 接近 1, 则模型的预测性能良好^[32].

2.3 SHAP 模块

EL 学习器 (例如 XGBoost) 根据信息增益来评估特征的重要性, 这些信息不能直接和明确地表明影响因素对路面性能 (即车辙) 的影响程度. 因此, 本研究引入了博弈论中的 SHAP 来解释预测模型的输出^[33], 与 FI 相比, SHAP 的最大优势在于它可以反映每个样本特征对目标值的影响是积极的还是消极的. SHAP 提供了一种通过博弈论和局部解释来评估不同特征贡献的替代方案. 假设 XGBoost 模型中涉及数据集 M (具有 n 个特征) 来预测目标值 N . SHAP 可用于计算每个特征 (ϕ_i 表示特征 i) 对预测值 $v(N)$ 的贡献, 基于边际贡献. 计算由式 (8) 描述:

$$\phi_i = \sum_{S \in N \setminus \{i\}} \frac{|S|! (n - |S| - 1)!}{n!} [v(S \cup \{i\}) - v(S)]. \quad (8)$$

然后, 开发一个解释模型作为二元变量的线性函数:

$$g(z') = \phi_0 + \sum_{i=1}^M \phi_i z'_i, \quad (9)$$

其中 $z' \in \{0, 1\}^M$, 当观察到特征时 $z' = 1$, 否则 $z' = 0$; M 是输入要素的数量.

SHAP 可用于确定每个特征变量对模型预测结果的影响程度. 此外, SHAP 还可用于确定每个特征变量对结果是有正影响还是有负影响.

3 结果与讨论

3.1 FI 模块结果与讨论

本研究采用决定系数 R^2 指标, 分别使用了 RF^[34]、XGBoost^[35]、CatBoost^[36] 和 LGBM^[37] 模型, 对特征进行重要性排序. 本研究使用了 19 种主要的试验路面结构来支持我们的研究结果, 分别对应着 STR1 ~ STR19, 由于篇幅限制, 本文将展示其中具有代表性的一种路面结构 STR4 的 FI 结果, 如表 2 所示.

表 2 不同算法下的 STR4 的 FI

Table 2 The FI of the STR4 under different algorithms

feature	RF	XGBoost	LGBM	CatBoost
axle load /%	67.84	61.54	49.78	44.55
average temperature /%	4.07	2.12	10.92	10.82
load level /%	0.12	0.00	0.00	4.19
deflection area /%	6.56	2.21	6.55	5.76
center deflection /%	1.95	1.86	3.49	4.92
IRI /%	7.92	4.32	18.78	7.79
laser texture depth /%	11.55	27.96	10.48	21.97

通过表 2 可以发现, FI 会随着算法的不同发生变化, 存在较大的不稳定性. 这种差异是由于每个算法各有特点, 具体来说: RF 通过构建多棵决策树来评估特征的重要性, 然而, 由于每颗树都是基于不同的随机样本和特征子集生成的, 不同的决策树在特征选择上可能存在一定的偏差; XGBoost 采用加法模型与二阶导数提升策略, 这有助于提高模型的鲁棒性, 但 XGBoost 仍然受到样本分布不平衡的影响, 这可能导致不同特征的重要性排序有所不同; CatBoost 的训练过程引入了特征的顺序打乱操作, 有助于提高模型的鲁棒性, 这种顺序打乱特点可减轻某些特征对排序的过度依赖, 从而对 FI 排序产生影响; LGBM 通过高效利用特征的梯

度信息和数据样本来确定特征的分割顺序,从而更好地挖掘样本信息,然而该特点也可能导致在特征排序上与其他模型产生不一致。

FI的不稳定是机器学习特征选择的难点所在,单一算法输出的FI难以权衡不同影响因素.为克服此难点,本研究提出了适用于综合不同算法输出FI的集成赋权法,即熵权法.熵权法是一种多标准决策的方法,用于确定每个算法输出FI的相对重要性.在这个过程中,首先为每个算法输出的FI结果计算熵值,熵值反映了算法输出FI的多样性和一致性.具有更多的多样性和较低一致性的算法将获得更高的熵值.然后,基于计算得到的熵值为每个算法分配权值,如表3所示.这些权值反映了每个算法对于综合FI的贡献程度.具有更高熵值的算法将获得更高的权值,因为它们提供了更多的信息,有助于解决不同算法输出FI的不稳定性问题.这一综合赋权过程旨在将不同算法的优点结合起来,以获得最终的FI,如表4所示.

表3 熵权法算法权值

Table 3 Entropy weight method algorithm weights

pavement	RF	XGBoost	LGBM	CatBoost	pavement	RF	XGBoost	LGBM	CatBoost
STR1	0.40	0.34	0.06	0.20	STR11	0.36	0.39	0.09	0.16
STR2	0.35	0.32	0.12	0.21	STR12	0.31	0.37	0.08	0.24
STR3	0.32	0.38	0.07	0.23	STR13	0.38	0.35	0.07	0.20
STR4	0.28	0.30	0.17	0.25	STR14	0.30	0.41	0.07	0.22
STR5	0.32	0.34	0.12	0.22	STR15	0.37	0.41	0.06	0.16
STR6	0.37	0.28	0.09	0.26	STR16	0.34	0.38	0.08	0.20
STR7	0.34	0.40	0.07	0.19	STR17	0.36	0.37	0.09	0.18
STR8	0.38	0.39	0.07	0.16	STR18	0.37	0.35	0.10	0.18
STR9	0.34	0.35	0.08	0.23	STR19	0.30	0.33	0.10	0.27
STR10	0.37	0.35	0.09	0.19					

表4 熵权法的FI

Table 4 The FI of the entropy weight method

pavement	axle load	average	load level	deflection	center	IRI	laser texture
	/%	temperature/°C	/%	area/°C	deflection/°C	/%	depth/°C
STR1	74.64	3.31	4.46	2.50	2.38	3.07	9.63
STR2	56.25	4.39	5.69	1.75	2.33	3.38	26.21
STR3	74.46	3.93	2.04	2.79	2.55	3.17	11.06
STR4	57.04	6.34	1.09	5.05	2.93	8.62	18.93
STR5	72.92	5.38	1.41	3.44	2.39	5.27	9.19
STR6	66.07	5.23	2.51	3.31	3.67	3.56	15.65
STR7	68.51	2.04	5.04	1.64	1.59	3.36	17.82
STR8	80.09	2.94	3.93	2.44	1.37	4.41	4.82
STR9	78.56	4.24	4.25	2.60	2.38	3.88	4.09
STR10	69.67	2.36	3.73	1.70	2.04	2.72	17.78
STR11	81.65	1.79	4.58	2.00	1.07	2.75	6.16
STR12	59.11	2.30	3.18	2.24	2.87	3.88	26.42
STR13	73.02	2.21	3.10	2.12	1.66	4.23	13.66
STR14	30.80	2.43	2.40	1.98	2.04	4.31	56.04
STR15	82.59	1.75	4.82	1.22	1.22	2.36	6.04
STR16	77.58	3.64	3.42	2.15	1.74	2.60	8.87
STR17	79.03	3.44	5.94	2.49	1.56	2.54	5.00
STR18	68.36	2.06	6.97	1.16	1.60	3.46	16.39
STR19	69.38	2.87	1.72	2.98	3.38	5.13	14.54

使用熵权法获得的FI反映了各特征的相对重要性,而引入冗余和非关键特征可能会导致模型过拟合.为了避免这一问题,本研究采用Pareto分析法对特征进行选择,其思想是,大多数效果往往只由少数关键因

素造成,即二八法则.Pareto 分析法通过 FI 降序排序,并计算特征的累计贡献率,选取达到累计贡献率阈值的特征子集.Pareto 分析法可以有效地保留主要特征并过滤掉冗余和非关键特征,同时也减少了计算量和过拟合风险.图 3 展示了 STR4 的 Pareto 分析筛选特征子集的过程,特征按照 FI 降序排序,图中的蓝色直方图显示了各个特征的重要性,并在直方图的上方显示了具体的 FI 数值,图中的黄色实线为特征的累计贡献率,本研究设置累计贡献率阈值为 80%,即选择前 80% 贡献特征作为特征子集.通过 Pareto 分析法筛选得到的特征子集如表 5 所示,可以为后续建立精简而有效的预测模型提供支持.

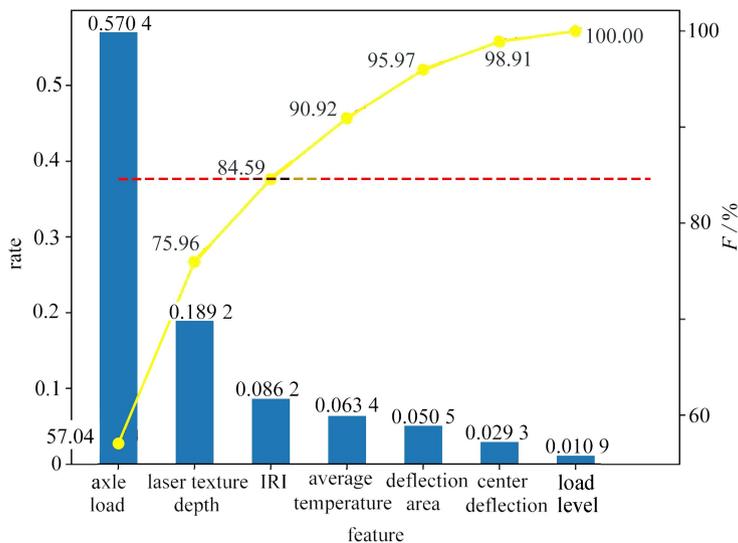


图 3 Pareto 分析筛选特征的过程

Fig. 3 The process of pareto analysis for feature selection

注 为了解释图中的颜色,读者可以参考本文的电子网页版本,后同.

表 5 Pareto 分析筛选特征

Table 5 Pareto analysis for feature selection

pavement	feature
STR1, STR2, STR3, STR5, STR6, STR7, STR10, STR12, STR13, STR16, STR18, STR19	axle load, laser texture depth
STR4	axle load, laser texture depth, IRI
STR8, STR11, STR15	axle load
STR9, STR17	axle load, load level
STR14	laser texture depth, axle load

综上所述,本研究针对每一种路面结构均按以下顺序进行操作:

- ① 使用 RF、XGBoost、CatBoost 和 LGBM 四种算法分别输出对应的 FI 结果;
- ② 运用熵权法综合不同算法的 FI,得到加权后的 FI 结果,并进行降序排序;
- ③ 使用 Pareto 分析筛选累积特征贡献率达到 80% 的特征子集;
- ④ 使用筛选后的特征子集建立预测模型.

3.2 EL 模块结果与讨论

本研究评估了深度森林(deep forest, DF)^[38]、RF、XGBoost、XGB_RF、CatBoost、LGBM、最近邻(K-nearest neighbor, KNN)^[39]、支持向量机(support vector machine, SVM)^[40]、决策树(decision tree, DT)^[41]和多层感知机(multilayer perception, MLP)^[42]十种算法在 19 种代表性路面结构上的学习效果,旨在找出最优的模型进行路面车辙预测.其中 XGB_RF 是以 XGBoost 方式建树,但以 Bagging 方式构建 RF 的模型,模型的主要思想是将 XGBoost 的梯度提升框架与 RF 的随机样本采样策略相结合,以提高模型的性能和鲁棒性.每种模型在 19 种路面结构上的综合表现效果如表 6 所示.

表6 模型评价指标结果

Table 6 Model evaluation index results

model	R^2	f_{RMSE}	f_{MAE}
DF	0.916	4.53	3.42
RF	0.933	4.20	2.96
XGBoost	0.922	4.62	3.33
XGB_RF	0.918	4.83	3.49
CatBoost	0.933	4.22	3.07
LGBM	0.750	8.47	6.31
KNN	0.910	4.80	3.68
SVM	0.491	12.95	9.39
DT	0.894	5.29	3.71
MLP	-7.644	51.57	48.32

本研究主要采用决定系数 R^2 来评估不同机器学习模型在本研究问题上的拟合程度和预测能力。 R^2 值越接近 1, 模型表现越佳。实验结果表明, 在所有 19 种路面结构类型中, RF 模型得分最高, 达到 0.933, 这表明 RF 具备较强的路面识别能力。CatBoost 和 XGBoost 次之, 平均准确率分别为 0.933 和 0.922。相比之下, KNN 和 DT 等方法的平均效果略逊, 整体较差约 2%~4%, 在这里 MLP 的预测结果甚至为负数, 这可能与本研究的样本量有限有关, 使得 MLP 模型欠拟合。

综合不同模型在 19 种路面结构上的表现可知, RF 模型在捕捉路面特征、学习非线性信息和抵御过拟合等方面有较强的能力。RF 通过构建多个决策树, 每个树都可以捕捉不同的路面特征和不同的非线性模式, 集成多个决策树并采用平均的方式来减少过拟合的风险。这种集成方法有助于综合各种特征信息, 提高对路面车辙预测的准确性, 从而获得更高的路面车辙预测精度。另一方面, RF 模型可以提供有关决策树的信息, 使模型的预测结果更具可解释性。因此, 本研究选择 RF 模型作为路面车辙预测的最佳模型, 并将该模型输出到 SHAP 模块, 对其进行可解释性分析, 从而为路面维护和改进提供有力的支持。

3.3 SHAP 模块结果与讨论

本研究使用 SHAP 来提升模型的可解释性, 对包括 STR1~STR19 在内的 19 种不同路面结构进行了可解释性分析。由于篇幅限制, 本研究将重点阐述代表性路面结构 STR4 的可解释性分析结果, 包括局部解释 SHAP、全局解释 SHAP 以及全局特征平均 SHAP。这三种 SHAP 分析方法相互补充, 构成了对模型可解释性的全面理解。局部解释 SHAP 帮助研究人员深入理解模型在个别样本上的细节决策过程, 全局解释 SHAP 展示了模型在整个数据集上的整体行为趋势, 而全局特征平均 SHAP 则提供了更稳健的 FI 评估。这种综合的可解释性分析有助于研究人员更好地理解模型, 并为进一步的研究和改进提供重要的指导。其中局部解释 SHAP 图如图 4 所示。

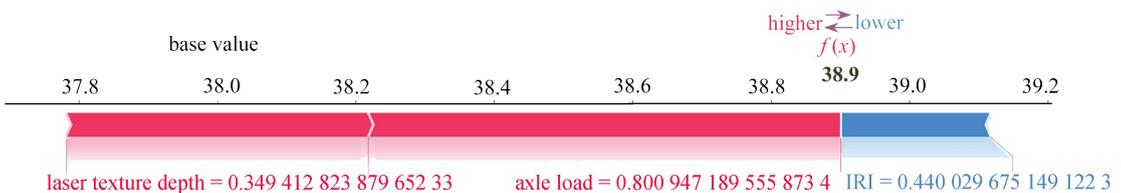


图4 STR4-局部解释 SHAP

Fig. 4 STR4-local interpretation SHAP

本研究随机选取了 STR4 测试集中的 20 个样本, 然后计算每个特征的 Shapley 值的平均值, 以规避随机性的影响。Shapley 值反映了每个特征对于模型输出的贡献程度, 从而揭示了模型对于每个样本的预测结果是如何形成的。在图 4 中展示了每个特征值对于本研究采用的最佳模型, RF 的预测贡献。这些特征值的变动分别对模型的预测产生正向或负向的影响。图 4 中的粗体字体表示模型输出的车辙深度预测值为 38.9, 而实际值为 38.0, 导致预测的车辙比真实的车辙深这一现象的原因是由特征值约为 0.80 的轴载次数和特征值约为 0.35 的激光纹理深度的推动, 在图 4 中以红色线条显示, 代表对预测值产生了正向影响, 从而导致预测值

增加;而特征值约为 0.44 的 IRI 为蓝色线条,这表明在局部解释层面,IRI 的变动对于模型的车辙深度预测产生了负向影响,会减少模型的预测值。

全局解释以 SHAP 值散点图形式展示,并根据特征对目标值即车辙的相对重要性,按降序显示了特征的贡献,如图 5 所示。模型的 FI 与每个因子的绝对平均 SHAP 值的大小成正比。如果一个特征在列出的特性中排名靠前,这意味着这个特性的重要性很高。然后,如颜色条所示,如果一个点是红色的,则意味着对应于该点的特征值高。此外,当这些点位于零线的右侧时,这些点的 SHAP 值是正的,与颜色无关。根据式(8),具有正 SHAP 值的特征意味着该特征将使预测值增加,而负 SHAP 值表示相反的效果。

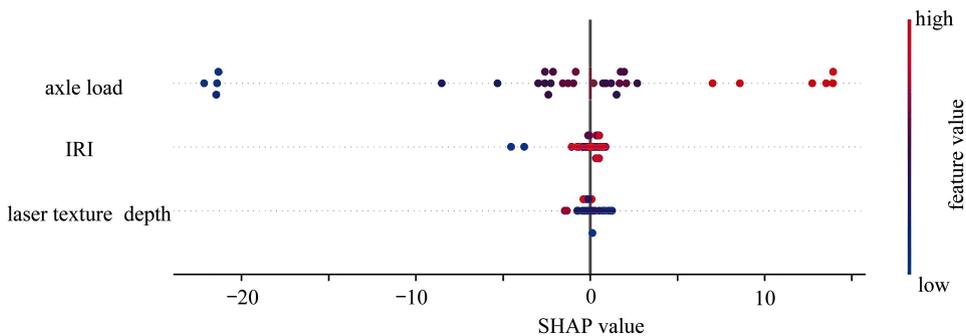


图 5 STR4-全局解释 SHAP

Fig. 5 STR4-global interpretation SHAP

图 6 按降序排序显示了全局特征平均 SHAP 值,正如本研究在 FI 模块输出的 FI 排序结果,轴载次数是预测车辙深度模型的最重要特征,并且该特征对应的 SHAP 值也是正值,平均 SHAP 值达到了显著的 5.5。轴载次数是指车辆通过路段的次数,轴载次数的增加意味着更频繁的车辆通行,进而显著加深车辙深度。造成这一现象的原因是,随着轴载次数的增加,路面将持续承受更频繁和更强烈的荷载作用,从而导致路面结构各层产生剪应力和变形。特别是在车辆通过时,轮胎的水平 and 垂直荷载会引起沥青路面复杂的应力分布。这种应力分布激发了路面结构的塑性变形,最终形成了可观的车辙。这与一些研究人员提供的结果一致。

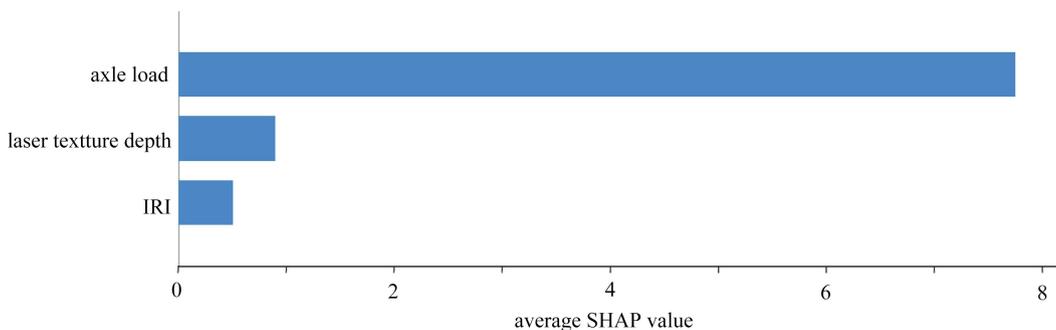


图 6 STR4-全局特征平均 SHAP

Fig. 6 STR4-global feature average SHAP

平均 SHAP 值排名第二和第三的特征分别是激光纹理深度和 IRI,均与车辙深度呈正相关,且对应的 SHAP 值均为正值,都小于 1。IRI 和激光纹理深度的变化在一定程度上反映了路面车辙的发展,但它们并非车辙形成的直接原因。车辙主要是由路面的磨损和形变所导致的,而 IRI 和激光纹理深度的变化则是这种磨损和形变的表现之一。IRI 作为国际平整度指数,用于描述路面的平整度,其数值的升高意味着路面的不平整度增加。不平整的路面会导致车辆对路面的冲击力增加,使得路面结构或性能出现损伤和衰变,导致使用性能下降。在相同水平的车辆荷载作用下,这种损伤和衰变会加速路面的老化,进而促进车辙的发展。激光纹理深度是指路面表面的微观凹凸程度,其数值的提高代表着路面表面的不规则度增加。车辆行驶过程中,较大的激光纹理深度会引起车轮与路面之间更频繁的相互作用。在频繁刹车和制动的情况下,车辆轮胎与路面之间产生的水平力会引起路面材料的剪切推移和拥包,进而形成车辙。

可解释性分析不仅为研究人员理解路面磨损和形变的机制提供了关键线索,也为制定切实可行的防护

措施提供了有力支持.考虑到实际路面维护的成本和可持续性,本研究提出了以下综合性的防护措施:

① 轴载次数控制.采取措施限制车辆通行频率,特别是重载车辆的通行,以减缓车辙深度的增加.

② 路面维护.定期对路面进行维护和修复,降低 IRI 值,保持路面的平整度,减少车辆在行驶中受到的颠簸和振动,从而减缓车辙的形成.

③ 激光纹理深度控制.通过科学的路面设计和选用合适的路面材料,控制激光纹理深度,减缓路面的磨损和塑性变形,降低车辙深度的发展速度.

这些防护措施的制定直接基于对模型输出的深入理解,从而能更有效地延缓车辙的形成和深化,提高路面的耐久性和使用寿命.因此,本研究所提出的建议不仅仅是理论性的,更是根据可解释性分析的实际指导,可为路面维护决策提供实质性的支持.

4 结 论

本研究使用 EL 方法,建立了一个 FI-EL-SHAP,实现了对车辙深度的预测,在保证高准确性的同时又具有良好的可解释性.其中 FI 模块通过引入熵权法将不同模型输出的 FI 进行加权综合,以减轻个别算法可能引发的误导性结果,并在此结果的基础上运用 Pareto 分析,筛选出关键特征子集作为 EL 模块的输入;EL 模块使用 10 种 EL 算法并进行比较,以找到最准确的预测结果.本研究的实验结果表明,RF 模型获得了最高的决定系数 R^2 得分,为 0.933,在均方根误差 f_{RMSE} 和平均绝对误差 f_{MAE} 上也有优异表现,分别达到了 4.20 和 2.96,表明车辙深度可以被 RF 模型准确地预测,从而选择 RF 模型作为路面车辙预测的最佳模型作为 SHAP 模块的输入;可解释性 SHAP 模块对 STR1 至 STR19 在内的共计 19 种不同路面结构进行了可解释性分析.本研究可解释性的分析结果表明,轴载次数是影响车辙深度模型的最关键特征,随着轴载次数的增加,车辙深度呈现显著增加的趋势.这一发现不仅为道路管理者提供了宝贵的指导,也为道路维护和修复工作提供了有力的依据.通过更有效地管理和控制高轴载次数车辆的通行,可以降低车辙的形成速度,延长路面的使用寿命^[43].这些措施有望改善道路的耐久性,提高交通安全性,并降低长期的维护成本.我们未来的工作将在本研究的基础上继续拓展,考虑扩大数据集的规模,并将气候和环境因素,材料性能参数等纳入数据集,从而进行更广泛的验证.这有助于验证模型的鲁棒性和可靠性,尤其是有助于更好地适应不同气候条件下的路面设计和维护策略.

致谢 本文作者衷心感谢综合交通运输理论交通运输行业重点实验室(南京现代综合交通实验室)开放课题(MTF2023004)对本文的资助.

参考文献(References):

- [1] ZHANG N, ALIPOUR A. A two-level mixed-integer programming model for bridge replacement prioritization [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2020, **35**(2): 116-133.
- [2] LI Z, ZHANG J, LIU T, et al. Using PSO-SVR algorithm to predict asphalt pavement performance[J]. *Journal of Performance of Constructed Facilities*, 2021, **35**(6): 04021094.
- [3] CHOI S, DO M. Development of the road pavement deterioration model based on the deep learning method [J]. *Electronics*, 2019, **9**(1): 3.
- [4] DAMIRCHILO F, HOSSEINI A, PARAST M M, et al. Machine learning approach to predict international roughness index using long-term pavement performance data [J]. *Journal of Transportation Engineering (Part B): Pavements*, 2021, **147**(4): 04021058.
- [5] HOSSEINI S A, SMADI O. How prediction accuracy can affect the decision-making process in pavement management system [J]. *Infrastructures*, 2021, **6**(2): 28.
- [6] NASERI H, SHOKOOHI M, JAHANBAKHS H, et al. Evolutionary and swarm intelligence algorithms on pavement maintenance and rehabilitation planning [J]. *International Journal of Pavement Engineering*, 2022, **23**(13): 4649-4663.
- [7] HOSSAIN E I N, SINGH D, ZAMAN P E M. Dynamic modulus-based field rut prediction model from an instrumented pavement section [J]. *Procedia-Social and Behavioral Sciences*, 2013, **104**: 129-138.

- [8] LI Y, LIU L, XIAO F, et al. Effective temperature for predicting permanent deformation of asphalt pavement [J]. *Construction and Building Materials*, 2017, **156**: 871-879.
- [9] 张承焯, 李卓轩, 曹进德. 基于随机 k -近邻集成算法的网络流量入侵检测[J]. 南通大学学报(自然科学版), 2023, **22**(3): 26-32. (ZHANG Chengye, LI Zhuoxuan, CAO Jinde. Network intrusion detection based on random k -nearest neighbor ensemble algorithm[J]. *Journal of Nantong University (Natural Science Edition)*, 2023, **22**(3): 26-32. (in Chinese))
- [10] MIRABDOLAZIMI S M, SHAFABAKHSH G. Rutting depth prediction of hot mix asphalts modified withforta fiber using artificial neural networks and genetic programming technique[J]. *Construction and Building Materials*, 2017, **148**: 666-674.
- [11] ZIARI H, AMINI A, GOLI A, et al. Predicting rutting performance of carbon nano tube (CNT) asphalt binders using regression models and neural networks[J]. *Construction and Building Materials*, 2018, **160**: 415-426.
- [12] SHAN A, HAFEEZ I, HUSSAN S, et al. Predicting the laboratory rutting response of asphalt mixtures using different neural network algorithms[J]. *International Journal of Pavement Engineering*, 2022, **23**(6): 1948-1956.
- [13] QADIR A, GAZDER U, CHOUDHARY K U N. Artificial neural network models for performance design of asphalt pavements reinforced with geosynthetics[J]. *Transportation Research Record: Journal of the Transportation Research Board*, 2020, **2674**(8): 319-326.
- [14] WANG S C. *Interdisciplinary Computing in Java Programming*[M]. Boston, MA: Springer, 2003.
- [15] MISHRA M, SRIVASTAVA M. A view of artificial neural network[C]//*2014 International Conference on Advances in Engineering & Technology Research (ICAE/ETR-2014)*. Unnao, India; IEEE, 2014; 1-3.
- [16] MAIND S B, WANKAR P. Research paper on basic of artificial neural network[J]. *International Journal on Recent and Innovation Trends in Computing and Communication*, 2014, **2**(1): 96-100.
- [17] SHANMUGANATHAN S A S. *Artificial Neural Network Modelling*[M]. Cham: Springer, 2016.
- [18] SIMPSON A L, DALEIDEN J F, HADLEY W O. Rutting analysis from a different perspective[J]. *Transportation Research Record*, 1995, **1473**: 9-16.
- [19] SHAFABAKHSH G H, ANI O J, TALEBSAFA M. Artificial neural network modeling (ANN) for predicting rutting performance of nano-modified hot-mix asphalt mixtures containing steel slag aggregates[J]. *Construction and Building Materials*, 2015, **85**: 136-143.
- [20] ABDELAZIZ N, ABD EL-HAKIM R T, EL-BADAWY S M, et al. International roughness index prediction model for flexible pavements[J]. *International Journal of Pavement Engineering*, 2020, **21**(1): 88-99.
- [21] BARUA L, ZOU B, NORUZOLIAEE M, et al. A gradient boosting approach to understanding airport runway and taxiway pavement deterioration[J]. *International Journal of Pavement Engineering*, 2021, **22**(13): 1673-1687.
- [22] 王旭东. 从试验环道看长寿命路面的“中国制造”[J]. 中国公路, 2020(14): 30-32. (WANG Xudong. Viewing the “Made in China” of long life road surface from the experimental ring road [J]. *China Highway*, 2020 (14): 30-32. (in Chinese))
- [23] 张蕾, 周兴业, 王旭东. 基于 RIOHTrack 足尺加速加载试验的长寿命沥青路面行为研究进展[J]. 科学通报, 2020, **65**(30): 3247-3258. (ZHANG Lei, ZHOU Xingye, WANG Xudong. Research progress of long-life asphalt pavement behavior based on the RIOHTrack full-scale accelerated loading test[J]. *Chinese Science Bulletin*, 2020, **65**(30): 3247-3258. (in Chinese))
- [24] LI Z, SHI X, CAO J, et al. CPSO-XGBoost segmented regression model for asphalt pavement deflection basin area prediction[J]. *Science China Technological Sciences*, 2022, **65**(7): 1470-1481.
- [25] ZEIADA W, HAMAD K, OMAR M, et al. Investigation and modelling of asphalt pavement performance in cold regions[J]. *International Journal of Pavement Engineering*, 2019, **20**(8): 986-997.
- [26] BOMMERT A, SUN X, BISCHL B, et al. Benchmark for filter methods for feature selection in high-dimensional classification data[J]. *Computational Statistics & Data Analysis*, 2020, **143**: 106839.
- [27] NASERI H, WAYGOOD E O D, WANG B B, et al. How to predict climate change stage of change accurately: proposing a new feature selection technique [C]//*Transportation Research Board 101st Annual Meeting*.

Washington DC, 2022.

- [28] LIU L, ZHOU J, AN X, et al. Using fuzzy theory and information entropy for water quality assessment in Three Gorges region, China[J]. *Expert Systems With Applications*, 2010, **37**(3): 2517-2521.
- [29] ZOU Z H, YUN Y, SUN J N. Entropy method for determination of weight of evaluating indicators in fuzzy synthetic evaluation for water quality assessment[J]. *Journal of Environmental Sciences*, 2006, **18**(5): 1020-1023.
- [30] KIREMIRE A R. The application of the Pareto principle in software engineering[Z/OL]. 2021[2024-11-28]. <https://studylib.net/doc/8372157/the-application-of-the-pareto-principle-in-software>.
- [31] REFAEILZADEH P, TANG L, LIU H. Cross-validation[C]//*Encyclopedia of Database Systems*. Boston, MA: Springer, 2009: 532-538.
- [32] NGARAMBE J, IRAKOZE A, YUN G Y, et al. Comparative performance of machine learning algorithms in the prediction of indoor daylight illuminances[J]. *Sustainability*, 2020, **12**(11): 4471.
- [33] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions[C]//*31st Conference on Neural Information Processing Systems*. Long Beach, CA, 2017.
- [34] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, **45**: 5-32.
- [35] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. San Francisco: ACM, 2016: 785-794.
- [36] PROKHORENKOVA L, GUSEV G, VOROBEV A, et al. CatBoost: unbiased boosting with categorical features [C]//*Advances in Neural Information Processing Systems 31*. 2018: 6138-6148.
- [37] KE G L, MENG Q, FINLEY T, et al. LightGBM: a highly efficient gradient boosting decision tree[C]//*Advances in Neural Information Processing Systems 30*. 2017: 3147-3155.
- [38] ZHOU Z H, FENG J. Deep forest[J]. *National Science Review*, 2019, **6**(1): 74-86.
- [39] PETERSON L. K-nearest neighbor[J]. *Scholarpedia*, 2009, **4**(2): 1883.
- [40] HEARST M A, DUMAIS S T, OSUNA E, et al. Support vector machines[J]. *IEEE Intelligent Systems and Their Applications*, 1998, **13**(4): 18-28.
- [41] MYLES A J, FEUDALE R N, LIU Y, et al. An introduction to decision tree modeling[J]. *Journal of Chemometrics*, 2004, **18**(6): 275-285.
- [42] GARDNER M W, DORLING S R. Artificial neural networks (the multilayer perceptron): a review of applications in the atmospheric sciences[J]. *Atmospheric Environment*, 1998, **32**(14/15): 2627-2636.
- [43] 李卓轩, 林凯迪, 郭建华, 等. 基于车联网数据的运输车辆安全评价模型[J]. 南通大学学报(自然科学版), 2020, **19**(1): 26-32. (LI Zhuoxuan, LIN Kaidi, GUO Jianhua, et al. Transportation vehicle safety evaluation model based on vehicle network data[J]. *Journal of Nantong University (Natural Science Edition)*, 2020, **19**(1): 26-32. (in Chinese))