

doi: 10.11835/j.issn.1000-582X.2026.05.009

引用格式:付东雷, 芮润华, 王静怡. 基于机器学习的沥青路面国际平整度指数预测[J]. 重庆大学学报, 2026, 49(5): 118-125.



基于机器学习的沥青路面国际平整度指数预测

付东雷¹, 芮润华², 王静怡¹

(1. 新疆大学建筑工程学院, 乌鲁木齐 830046; 2. 清华大学土木工程系, 北京 100084)

摘要:基于机器学习算法, 选用路面结构因素、性能因素、环境因素和交通因素等多种影响因素作为输入变量, 对国际平整度指数进行预测。国际平整度指数和影响因素均来源于 LTPP 数据库 (long-term pavement performance, LTPP) 和中国实际道路数据, 选用路段为结构层未发生改变的沥青路段。经过筛选后的总样本数量为 3 066 个, 按照交叉验证和网格搜索相结合的方法选取最佳参数。使用神经网络、支持向量机和 XGBoost 对国际平整度指数进行预测, 比较了 3 种机器学习算法测试集的 R^2 值, 均方根误差 (RMSE) 和平均绝对误差 (MAE)。根据 3 种对比结果可知, XGBoost 的预测效果最好, R^2 值为 0.96, RMSE 的值为 0.08, MAE 的值为 0.05。使用 XGBoost 对影响因素重要性进行排序, 其中初测国际平整度值的重要性最高。结果表明, XGBoost 能够准确预测沥青路面国际平整度值, 为路面管理系统提供模型参考。

关键词:机器学习; 国际平整度指数; LTPP; 多影响因素

中图分类号: U416.221

文献标志码: A

文章编号: 1000-582X(2026)05-118-08

Application of machine learning for predicting the IRI of asphalt pavements

FU Donglei¹, GUO Runhua², WANG Jingyi¹

(1. School of Architecture and Engineering, Xinjiang University, Urumqi 830046, P. R. China; 2. Department of Civil Engineering, Tsinghua university, Beijing 100084, P. R. China)

Abstract: This study applies machine learning techniques to predict the international roughness index (IRI) of asphalt pavement using structural, performance, environmental, and traffic-related variables. Data were obtained from the long-term pavement performance (LTPP) database and Chinese pavement datasets, with 3 066 asphalt pavement sections (construction number = 1) selected for analysis. Model parameters were optimized using cross-validation combined with grid search. Considering the selected factors, three machine learning models, namely artificial neural networks (ANN), support vector machines (SVM), and XGBoost, were employed to predict IRI. Their performance was evaluated using R^2 , root mean square error (RMSE) and mean absolute error (MAE). The results show that XGBoost achieved the best predictive performance ($R^2 = 0.96$, RMSE=0.08, MAE=0.05). Feature importance analysis based on XGBoost indicates that the initial IRI is the most influential factor. These

收稿日期: 2025-12-06

基金项目: 清华大学-丰田联合研究院跨学科专项 (041911062)。

Supported by Tsinghua-Toyota Joint Research Institute Cross Discipline Program (041911062).

作者简介: 付东雷 (1995—) 男, 硕士研究生, 主要从事机器学习在路面的应用, (E-mail) 249334058@qq.com。

通信作者: 芮润华, 男, 副教授, 博士生导师, (E-mail) guorh@tsinghua.edu.cn。

results show that XGBoost can accurately predict asphalt pavement IRI and provide a reference model for pavement management systems.

Keywords: machine learning; IRI; LTPP; multiple factors

随着大数据时代的到来,科学的决策和资源的优化分配,越来越依靠数据挖掘和人工智能技术。在路面工程领域,结合机器学习建立一套路面综合管理系统,实现路面全生命周期各类数据的收集分析、路面性能预测以及路面养护方案和养护资金的决策方案制定,对于路面管理部门是十分重要的^[1]。在路面性能预测中,学者大多选择国际平整度指数作为研究对象。国际平整度指数(international roughness index, IRI)是世界银行于1982年组织多国参与为寻找一个标准的平整度指标并最终确定的路面粗糙度指数,代表了四分之一标准车模型在80 km/h速度下簧上和簧下质量相对位移累计值与行驶路程的比值,IRI不仅可作为评价路面性能指标之一,也可用于评价路面的驾驶舒适度和安全性。若能对IRI进行准确的预测,可节省大量使用路面激光平整度检测系统的资金以及相应的人力物力。机器学习能够综合考虑路面性能影响因素,对路面IRI值实现预测,在机器学习算法的选择上,神经网络(artificial neural networks, ANN)、支持向量机(support vector machines, SVM)、随机森林算法和梯度提升树算法以及各种前者的变体被大部分学者接受使用。

Sollazzo等^[2]使用ANN建立了等效结构数与IRI,路面厚度、路龄、交通量、温度等影响因素之间的关系。Hossain等^[3]和Zeinda等^[4]根据研究路面所处气候条件将研究数据集分为4部分并分别使用ANN对IRI进行预测。Ziari等^[5]按照时间长短将所研究数据集分为短期和长期数据集,验证了ANN在长期和短期沥青路面IRI预测中都有良好的性能。Gong等^[6]使用随机森林算法对沥青路面的IRI进行预测,通过网格搜索方法寻找最优参数值,并与线性回归算法比较,结果表明随机森林算法要明显优于线性回归算法。Barua等^[7]提出将梯度提升树算法应用于机场道面性能数据的预测中,拟合效果 R^2 大于0.85。

综上所述,现有文献少有进行不同机器学习算法预测性能的比较,也少有对路面性能影响因素排序分析。学者使用机器学习算法预测IRI的应用较少,主要原因在于我国缺乏公开的道路性能数据库。文中对美国LTPP数据库、机器学习算法进行简要介绍,以LTPP数据库和我国实际道路数据分别作为训练集和测试集,综合考虑路面多影响因素,利用多种机器学习算法,选取路面结构未发生变化的沥青路面作为研究对象,对沥青路面IRI值进行预测,再使用机器学习性能指标比较3种机器学习算法的预测性能并对IRI值的影响因素进行排序分析。

1 背景介绍

1.1 LTPP项目简介

LTPP项目(long-term pavement performance, LTPP)起始于上世纪80年代,目的在于研究路面性能在多种影响因素作用下的变化。按照研究目的不同,将LTPP项目分为2种类型,普通路面研究(GPS)项目和特殊路面研究(SPS)项目^[8],其中普通路面研究项目观测记录不同类型路面性能,而特殊路面是基于不同研究目的,例如,对新型路面材料的路用性能测试、不同养护措施或者维修措施下对路面长期性能分析等。LTPP数据库收录的数据包括建造时间、路面结构和材料信息、环境因素、交通因素、养护措施类型、路面性能因素等多种因素。基于不同的研究目的,从LTPP数据库中调取数据时,会有不同的考虑,文中选取沥青路面数据源于LTPP中路面结构未发生变化的路面,筛选条件是CONSTRUCTURE_NO=1。

1.2 机器学习算法

1.2.1 神经网络(ANN)

ANN是模拟在大脑中进行的决策过程的算法,基本运算单元为神经元,不同层的神经元构成输入层、隐藏层和输出层,其中输入层和输出层只有1层,而隐藏层个数可根据实际设置,如图1所示。神经网络运行的基本过程为:将考虑的特征置于输入层,经过神经元的运算和权重矩阵,传递处理过的特征进入隐藏层,在隐藏层运算完毕后,传到输出层,得到回归或者分类结果。每个神经元是一个激活函数,处理上一层传来的信

息,常用的激活函数有 sigmoid 函数、tanh 函数和 relu 函数^[3],这些函数的图像如图 2 所示。




图1 神经网络组成

Fig. 1 Composition of neural network

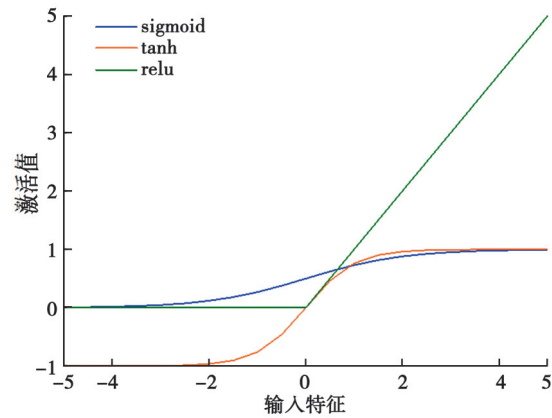


图2 3种激活函数

Fig. 2 Three activation functions

1.2.2 支持向量机(SVM)

SVM由Vapnik^[9]提出,最初用于解决线性二分类问题,引入核技巧后,可以解决非线性分类和回归问题^[10-11]。支持向量机通过核函数将特征数据进行升维操作,使得在低维空间看似无法解决的非线性问题在高维空间内转变为线性问题解决。而在核函数的选择上,比较常用的核函数包括有线性核函数、高斯核函数和多项式核函数,核函数的表达式如表1所示。

表1 常用核函数表达式

Table 1 The equations of different kernel functions

核函数	线性核函数	高斯核函数	多项式核函数
表达式	$K(x, z) = x \cdot z$	$K(x, z) = \exp\left(-\frac{\ x - z\ ^2}{2\sigma^2}\right)$	$K(x, z) = (x \cdot z + 1)^p$

注: x 为自变量; z 为输入向量; p 为多项式次数。

1.2.3 XGBoost

XGBoost是一个专注于梯度提升的集成学习算法^[12-14]。通过建立多棵“树”来进行预测,每一棵“树”相当于一个弱分类器,最后的结果为所有弱分类器的结果相加。XGBoost的目标函数为

$$Obj^{(t)} = \sum_{i=1}^n loss(y_i, \hat{y}_i^{(t-1)} + f_i(x_i)) + \Omega(f_i) + C, \quad (1)$$

式中: t 表示第 t 轮; n 表示样本总数; y_i 表示第 i 个样本的真实值; $loss$ 代表损失函数; $\hat{y}_i^{(t-1)}$ 表示第 $(t-1)$ 轮模型的预测结果; $f_i(x_i)$ 表示第 i 个样本第 t 轮新增的树结构和叶子权重; $\Omega(f_i)$ 表示对 f_i 的正则化项; C 代表常数项。通过对此目标函数进行最小化,求得最佳的模型。XGBoost最小化采用的方法是对目标函数进行泰勒二阶展开,将目标函数转化为

$$Obj^{(t)} \approx \sum_{i=1}^n \left[loss(y_i, \hat{y}_i^{(t-1)}) + g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i) \right] + \Omega(f_i), \quad (2)$$

式中: g_i 和 h_i 表示的是损失函数的一阶和二阶梯度统计,表达式为

$$g_i = \partial_{\hat{y}_i^{(t-1)}} loss(y_i, \hat{y}_i^{(t-1)}), \quad (3)$$

$$h_i = \partial_{\hat{y}_i^{(t-1)}}^2 loss(y_i, \hat{y}_i^{(t-1)}), \quad (4)$$

设置不同的损失函数, g_i 和 h_i 的值各不相同,这也是XGBoost的特色。通过对目标函数求导得到最佳的 f_i 值,使得目标函数值最小,经过多轮迭代最终获得最优模型。

1.3 交叉验证

将给定的数据集划分为训练集和测试集,在此基础上反复进行训练、测试以及模型选择。交叉验证可以分为简单交叉验证, K 折交叉验证和留一交叉验证。简单交叉验证将数据集按照比例分为训练集和测试集,在训练集中训练模型至损失最低,在测试集中测试模型的拟合效果。 K 折交叉验证为按照比例将训练数据集划分为 K 个互不相交,大小相同的子集,使用 $K-1$ 个子集进行训练,使用剩下的子集进行验证,在 K 次验证中取平均测试误差最小的模型,最终在测试集中检验模型拟合能力。而留一法为 K 折交叉验证的特殊情况,其中, $K=N$, N 为数据集样本个数; K 折交叉验证的过程如图 3 所示。

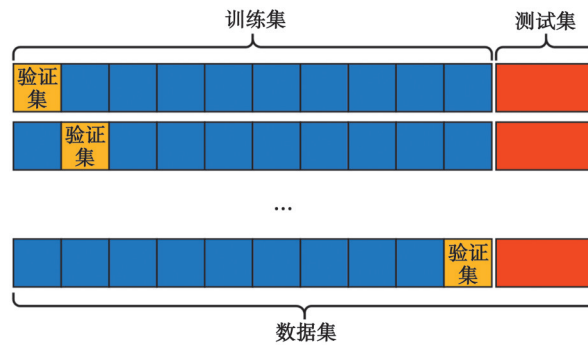


图 3 K 折交叉验证

Fig. 3 K -fold cross validation

2 数据准备

文中比较了不同机器学习算法对于 IRI 预测结果的优劣,考虑的因素包括环境因素、交通因素、结构因素、路面性能因素。从 LTPP 数据库 146 802 条 IRI 数据中筛选出符合条件的数据共 3 056 条,作为此次机器学习算法的训练集,将国内道路实际数据作为测试集。按照交叉验证的方式,划分训练集和测试集为 3 056 条和 10 条。LTPP 数据库文件为最新发布的 SDR 33,国内道路实际数据源自课题组项目收集数据,结合我国公路沥青路面设计规范^[15-16],以下简要介绍各类因素。

2.1 结构因素

路面结构数是指由沥青路面沥青层厚度、底基层厚度和基层厚度,同时结合路表面状况和各层排水系数确定。

2.2 性能因素

- 1) 初测 IRI 值:该路段第 1 次测量的左右轮迹 IRI 的平均值, m/km。
- 2) 车辙深度:轮迹处路面发生的沉陷,会导致结构损伤和积水, mm。
- 3) 初测经过时间:从该路段初次测量 IRI 时间为起点,每次测量 IRI 时间与初测 IRI 时间差值,记为初测经过时间,年。

2.3 气候因素

1) 气候分区:按照年累计降雨量、年气温最高月平均气温和年气温最低月平均气温划定气候分区,根据上述条件划分气候分区为:夏热冬温潮湿、夏热冬温半干、夏热冬温湿润、夏热冬冷湿润、夏凉冬冷干燥。将此 5 个分区按照独热码形式转化为数值变量。

2) 年日均风速:每年的风速均值, m/s。

2.4 交通因素

交通量等级:按照年累计轴载作用次数和年平均日交通量将本数据交通量划分为轻交通量、中等交通量和重交通量,同样将此 3 个交通等级按照独热码形式转换为数值变量。

2.5 数据预处理

在LTPP数据库中,对于车辙深度,因为有左右轮迹车辙之分,按照两者的平均值作为该路段的车辙深度。因为这些因素测量的时间不尽相同,一些路段某些年的数据可能存在缺失,如果直接弃之不用,将会失去大量有用信息,对于缺失值,按照K近邻算法,将缺失值填充,缺失值只出现在车辙深度处。同时,对于ANN和SVM而言,因为涉及影响因素数量多,且分布范围各不相同,如果使用原始数据,会削弱数值水平较低特征的作用,不能给模型提供足够的信息用于学习。因此,需要对数据预处理操作,同时将异常值去掉,采取z-score法进行数据预处理:

$$x_{\text{new}} = \frac{x_{\text{old}} - \bar{x}_{\text{old}}}{S}, \quad (5)$$

式中: x_{new} 为经过变化后的新数据; x_{old} 为原始数据; \bar{x}_{old} 代表原始数据的平均值; S 代表原始数据的标准差,经过变换后,新数据的均值为0,标准差为1。表2为各影响因素组成的数据集样例,其中,气候分区和交通因素为独热码转化的稀疏矩阵;表3为非独热码形式的影响因素基本数据特征。

表2 数据集样例
Table 2 Data set example

路号	初测 IRI	初测经过时间	结构数	车辙深度	年日均风速	夏热冬温潮湿	夏热冬温半干	夏热冬温湿润	夏热冬冷湿润	夏热冬冷干燥	轻交通量	中等交通量	重交通量
1	1.76	3.16	7.37	5.67	4.20	0	0	1	0	0	1	0	0
2	1.75	4.10	3.36	5.50	3.95	1	0	0	0	0	0	1	0
3	1.79	1.38	8.03	3.00	4.20	0	0	1	0	0	1	0	0
4	1.38	2.14	6.85	4.50	3.90	1	0	0	0	0	1	0	0
5	1.74	0.67	6.87	6.58	3.92	0	0	1	0	0	1	0	0

表3 影响因素原始数据基本描述
Table 3 The description of original influential factors

参数	平均值	方差
初测 IRI/(m·km ⁻¹)	1.03	0.38
年日均风速/(m·s ⁻¹)	3.86	0.78
初测时间/a	5.06	3.72
结构数	6.12	3.23
车辙深度/mm	11.78	7.21

常用的评价回归模型指标有均方根误差RMSE,平均绝对误差MAE和拟合 R^2 ,计算公式为

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

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

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2}, \quad (8)$$

式中: y_i 代表第*i*个样本的IRI真实值; \hat{y}_i 代表第*i*个样本的IRI预测值; \bar{y} 代表*N*个样本的IRI平均值。RMSE和MAE的值越接近0,表明预测性能越好; R^2 的值接近1,表明拟合程度越好,越低表明拟合程度越差。

3 拟合结果

3.1 各算法预测性能比

通过交叉验证和网格搜索方法结合,在训练集上训练模型,确保数据充分利用的同时,找到最优的模型参数。确定最优超参数设置,ANN 隐藏层神经元个数为 24,学习率为 1,SVM 拟合度 $\gamma=0.1$,惩罚参数 $C=3$,XGBoost 最大深度为 8,学习率为 0.1。训练集和测试集的各个模型评价指标结果如表 4 所示。

表 4 模型预测性能比较

Table 4 Comparison of predicted performance by different models

参数	训练集			测试集		
	ANN	SVM	XGBoost	ANN	SVM	XGBoost
R^2	0.77	0.77	0.99	0.90	0.91	0.96
RMSE	0.24	0.19	0.02	0.11	0.12	0.08
MAE	0.15	0.14	0.01	0.08	0.10	0.05

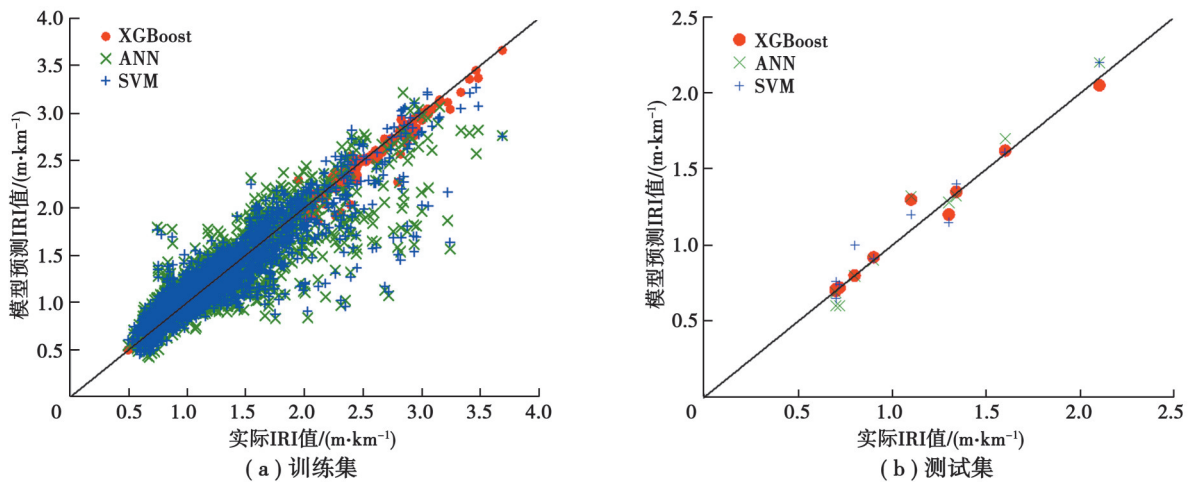


图 4 ANN、SVM、XGBoost 的预测性能

Fig. 4 Predicted IRI for three models in training and testing data sets

由表 4 可知,在训练集和测试集中,XGBoost 的 R^2 值最大,同时 RMSE 和 MAE 值也最小,说明相较于 ANN 和 SVM 而言,XGBoost 对于 IRI 的预测效果最好。对于 ANN 和 SVM,训练集和测试集拟合优度 R^2 有较大差异,说明这 2 种算法对于数据集敏感性要高于 XGBoost,鲁棒性不强。而 XGBoost 在训练集和测试集中 R^2 均大于 0.95,说明 XGBoost 针对 LTPP 数据和国内数据都有很好的拟合能力。

由图 4 可知,在训练集中 XGBoost 的点与 45° 直线距离较近,ANN 和 SVM 离散程度较大,呈带状分布。说明对于 LTPP 数据,ANN 和 SVM 不能取得很好的学习效果。在测试集中,3 种机器学习模型的预测性能接近,但是 XGBoost 相较于 ANN 和 SVM,散点群中与 45° 线重叠数为 8 个,说明模型预测值与真实值完全一致。而 ANN 和 SVM 虽然与 45° 线接近,但是点重叠数量明显少于 XGBoost,且 SVM 点重叠数大于 ANN,从侧面说明了 SVM 对小样本的预测能力要好于 ANN。

3.2 特征重要性

通过 XGBoost 得出各个因素的重要性,如图 5 所示。在性能因素中,对于路面 IRI 值,初测 IRI 值是最重要的影响因素,此影响因素接近沥青路面初始粗糙度,且路面 IRI 值在此基础上增加^[17]。车辙深度和初测经过时间对于路面 IRI 值也很重要。车辙是沥青路面在横向发生的不可恢复变形,车辙深度大小决定了路面纵向是否有明显的高差,而根据 IRI 的定义,IRI 会受到车辙的影响,且程度取决于车辙深度。路面 IRI 值会随

随着时间的增加逐渐增加,但根据重要性排名,初测经过时间对 IRI 值影响有限。对于气候因素,从排名可以看出,与其他气候分区相比,沥青路面 IRI 值对夏热冬温潮湿和夏热冬温半干气候显然更敏感。另外,年日均风速的重要性仅次于车辙深度。风速不同,路面与空气的热量交换大小也不同,进而影响路面温度对路面 IRI 产生影响。在交通因素中,从排名可以看出,交通量等级越高,对路面 IRI 的影响越大。高交通量会加快路面磨损和老化,增加路面 IRI 值,使得路面性能降低。在结构因素中,结构数排名比较靠后,原因可能在于研究的对象为结构未发生变化的路面,而结构数在一定程度上反映了路面结构。




图5 各影响因素重要性排序

Fig. 5 Importance permutation of influential factors

4 结 论

1) XGBoost是一种多因素、鲁棒性高的机器学习算法,相较于ANN和SVM,更加准确地预测了沥青路面IRI值。

2) XGBoost对影响因素重要性作出了排序分析,为道路数据挖掘与分析提供依据。

3) 不同因素对沥青路面IRI值影响程度不同,对重要因素进行针对性收集,以达到数据和所获信息之间的平衡。

综上所述,机器学习算法能够考虑多因素对LTPP和国内沥青路面IRI值做出预测,但不同机器学习算法预测性能存在差异。XGBoost作为集成学习的代表性算法,不仅实现了IRI值的准确预测,也实现了特征的重要性分析,能够为路面管理系统的建立提供模型参考。

参考文献

- [1] Piryonesi S M, El-Diraby T E. Data analytics in asset management: cost-effective prediction of the pavement condition index [J]. *Journal of Infrastructure Systems*, 2020, 26: 04019036.
- [2] Sollazzo G, Fwa T F, Bosurgi G. An ANN model to correlate roughness and structural performance in asphalt pavements[J]. *Construction and Building Materials*, 2017, 134: 684-693.
- [3] Hossain M, Gopiseti L S P, Miah M S. Artificial neural network modelling to predict international roughness index of rigid pavements[J]. *International Journal of Pavement Research and Technology*, 2020, 13(3): 229-239.
- [4] Zeiada W, Dabous S A, Hamad K, et al. Machine learning for pavement performance modelling in warm climate regions[J]. *Arabian Journal for Science and Engineering*, 2020, 45(5):4091-4109.
- [5] Ziari H, Sobhani J, Ayoubinejad J, et al. Prediction of IRI in short and long terms for flexible pavements: ANN and GMDH methods[J]. *International Journal of Pavement Engineering*, 2016, 17(9): 776-788.

- [6] Gong H R, Sun Y R, Shu X, et al. Use of random forests regression for predicting IRI of asphalt pavements[J]. *Construction and Building Materials*, 2018, 189: 890-897.
- [7] 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.
- [8] Jia Y S, Dai X W, Wang S Q, et al. Evaluation of long-term effectiveness of preventive maintenance treatments using LTPP SPS-3 experiment data[J]. *Construction and Building Materials*, 2020, 247: 118585.
- [9] Vapnik, Vladimir. *The nature of statistical learning theory*[M]. Springer science & business media, 2013.
- [10] 赵静,王选仓,丁龙亭,等. 基于灰色关联度分析和支持向量机回归的沥青路面使用性能预测[J]. *重庆大学学报(自然科学版)*, 2019(4): 72-81.
Zhao J, Wang X C, Ding L T, et al. Performance prediction of asphalt pavement based on grey relational analysis and support vector machine regression[J]. *Journal of Chongqing University*, 2019(4): 72-81. (in Chinese)
- [11] 李巧茹,郭知洋,王耀军,等. 基于PCA-SVM的高速公路沥青路面使用性能评价[J]. *北京工业大学学报*, 2018, 44(2): 283-288.
Li Q R, Guo Z Y, Wang Y J, et al. Evaluation of freeway asphalt pavement performance based on PCA-SVM[J]. *Journal of Beijing University of Technology*, 2018, 44(2): 283-288. (in Chinese)
- [12] Chen T Q, Guestrin C. XGBoost: a scalable tree boosting system[C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, 2016: 785-794.
- [13] Parsa A B, Movahedi A, Taghipour H, et al. Toward safer highways, application of XGBoost and SHAP for real-time accident detection and feature analysis[J]. *Accident Analysis & Prevention*, 2020, 136: 105405.
- [14] Zhang M M, Gong H R, Jia X Y, et al. Analysis of critical factors to asphalt overlay performance using gradient boosted models [J]. *Construction and Building Materials*, 2020, 262: 120083.
- [15] JTG D50—2017 公路沥青路面设计规范[S].
JTG D50—2017 Specifications for Design of Highway Asphalt Pavement[S]. (in Chinese)
- [16] JTG F40—2004 公路沥青路面施工技术规范[S].
JTG F40—2004 Technical Specifications for Construction of Highway Asphalt Pavements[S]. (in Chinese)
- [17] Marcelino P, de Lurdes Antunes M, Fortunato E, et al. Machine learning approach for pavement performance prediction[J]. *International Journal of Pavement Engineering*, 2021, 22(3): 341-354.

(编辑 陈移峰)